

INTRODUÇÃO AO PROCESSAMENTO DE IMAGENS DE SENSORIAMENTO REMOTO

Paulo Roberto Meneses

Tati de Almeida

(Organizadores)

PAULO ROBERTO MENESES

TATI DE ALMEIDA

(Organizadores)

INTRODUÇÃO AO PROCESSAMENTO
DE IMAGENS DE SENSORIAMENTO REMOTO

BRASÍLIA 2012

Autores

Paulo Roberto Meneses (organizador)

Professor Titular do Instituto de Geociências da Universidade de Brasília, graduado em Geologia pela Universidade de Brasília (1973), com mestrado em Sensoriamento Remoto pelo INPE (1976) e doutorado em Geologia pela USP em 1986.

e-mail pmeneses@unb.br

Tati de Almeida (organizadora)

Professora Adjunta do Instituto de Geociências da Universidade de Brasília, graduada em Geologia pela Universidade Estadual Paulista Júlio de Mesquita Filho (1998), com mestrado em Geociências pela Universidade Estadual de Campinas (2000) e doutorado em Geologia pelo Instituto de Geociências da UnB em 2009.

e-mail tati@unb.br

Antonio Nuno de Castro Santa Rosa

Professor Associado do Instituto de Geociências da Universidade de Brasília, graduado em Matemática na Universidade da Amazônia (1984), com mestrado em Geofísica pela Universidade Federal do Pará (1989), doutorado em Geofísica pela Universidade Federal do Pará (1996) e pós-doutorado em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais (2001).

e-mail nuno@unb.br

Edson Eyji Sano

Pesquisador Senior da Empresa Brasileira de Pesquisa Agropecuária, graduado em Geologia pela Universidade de São Paulo (1983), com mestrado em Sensoriamento Remoto pelo INPE (1987) e doutorado em Ciências do Solo pela Universidade do Arizona, EUA (1997).

e-mail sano@cpac.embrapa.br

Edilson Bias de Souza

Professor Adjunto do Instituto de Geociências da Universidade de Brasília, graduado em Geografia pelo Centro Universitário de Brasília (1994), com mestrado em Geociências e Meio Ambiente pela Universidade Estadual Paulista Júlio de Mesquita Filho (1998) e doutorado em Geografia pela Universidade Estadual Paulista Júlio de Mesquita Filho (2003).

e-mail edbias@unb.br

Gustavo Macedo de Mello Baptista

Professor Adjunto do Instituto de Geociências da Universidade de Brasília, graduado em Geografia pela Universidade de Brasília (1994), com mestrado em Tecnologia Ambiental e Recursos Hídricos pela Faculdade de Engenharia Civil da Universidade de Brasília (1997) e doutorado em Geologia pelo Instituto de Geociências da UnB (2001).

e-mail gbaptista@unb.br

Ricardo Seixas Brites

Professor Adjunto do Instituto de Geociências da Universidade de Brasília, graduado em Engenharia de Agrimensura pela Universidade Federal de Viçosa (1981), com mestrado em Ciências Florestal pela Universidade Federal de Viçosa (1990) e doutorado em Ciência Florestal pela Colorado State University / Universidade Federal de Viçosa (1995).

e-mail brites@unb.br

APRESENTAÇÃO

No decorrer das últimas quatro décadas o nosso planeta Terra começou a ser olhado e vistoriado por sensores imageadores que, praticamente, capturam tudo que está presente na superfície terrestre ou que nela está se modificando. E isso está sendo feito com o explícito objetivo de se obter imagens periódicas que possibilitem a monitoração do meio ambiente numa escala global e a obtenção de melhores informações acerca dos recursos naturais renováveis e não renováveis. Nessa tarefa, o engajamento de pesquisadores nos estudos do uso e aplicação do sensoriamento remoto, logo no início dos anos de 1970, quando essa nova tecnologia foi apresentada, foi decisivo para tornar o Brasil num dos maiores usuários do sensoriamento remoto do mundo. Iniciada por um grupo de jovens pesquisadores do INPE e incorporada, logo a seguir, pelas universidades brasileiras, hoje o ensino do sensoriamento remoto é componente de vários cursos universitários, num espectro amplo que vai das ciências naturais da Terra, à computação, urbanismo, engenharia civil, geotecnia, cartografia, ordenamento territorial, agricultura, geologia, defesa civil e muitas outras. Por ter essa marcante característica de multidisciplinaridade, tornou-se comum nas salas de aulas de disciplinas que abordam o sensoriamento remoto, o convívio de alunos de vários cursos de graduação ou de pós-graduação.

Mas, independente de qual seja o uso das imagens devemos, obrigatoriamente, passar pela experiência de como ler os dados digitais das imagens e processá-los. O incrível aumento na acessibilidade a computadores, combinado com o desenvolvimento de programas amigáveis e de interfaces gráficas versáteis com o usuário, tornou essa tarefa bem mais fácil do que quando as primeiras imagens de satélites só podiam ser lidas por especialistas em computação, em computadores que tomavam o espaço de uma sala. Hoje em dia, os atuais programas para processamentos de imagens de sensoriamento remoto não requerem dos usuários habilidades em computação. O que se tornou mais importante é o entendimento a respeito da formulação matemática ou estatística do algoritmo, dos vários métodos para o processamento das imagens e das transformações que nelas são processadas, para que possamos melhor extrair todo o conteúdo de informação contida nas imagens, que nem sempre é facilmente percebida pelo intérprete.

Esse é o objetivo deste livro, escrito numa linguagem técnica simples, direcionada a estudantes de graduação ou àqueles que estão iniciando no sensoriamento remoto, qualquer que seja a área de sua formação. Por isso, os autores se preocuparam mais em demonstrar, para cada tipo de técnica de processamento, como o operador transforma a imagem para realçar a sua visualização na tela do computador ou como ordenar e classificar os dados para construir um mapa digital temático, com o mínimo necessário da compreensão das funções matemáticas e estatísticas. Pretendemos que este livro contribua para orientar o trabalho de preparação de aulas dos professores que se dedicam ao ensino de sensoriamento remoto, bem como, possa cumprir a função de ser um material de consulta e estudo a todos os estudantes que se interessam por essa área.

Embora seja um livro de processamento de imagens, os primeiros quatro capítulos abordam fundamentos de sensoriamento remoto e descrições dos tipos de sensores que operam nas faixas espectrais do visível às micro-ondas. Assim foi feito, porque antes de se iniciar o processamento de uma imagem, é necessário que saibamos sobre uma série de informações de como as imagens são obtidas e de alguns detalhes de suas características. Esses capítulos são apenas uma pequena síntese sobre o sensoriamento remoto, com um conteúdo focado nas informações mais relevantes para o processamento da imagem.

A principal intenção dos autores, de colocar essa obra no formato de *e-book*, foi a de possibilitar aos estudantes o livre acesso, sem custos, a uma fonte de publicação para o acompanhamento de suas aulas nas disciplinas de processamento de imagens de

sensoriamento remoto. Esperamos que este livro possa inspirar o interesse e o entusiasmo desses estudantes.

Os autores são profundamente agradecidos à Prof^a. Maria Ana Bretanha Junker Menezes pela revisão ortográfica do texto.

Paulo Roberto Meneses

Tati de Almeida

Conteúdo

1. Princípios do Sensoriamento Remoto	
1.1 História Inicial	1
1.2 Definição de Sensoriamento Remoto	3
1.3 Natureza da Radiação Eletromagnética	4
1.3.1 Modelo ondulatório	4
1.3.1.1 Interação macroscópica da radiação eletromagnética com os objetos	6
1.3.2 Modelo corpuscular	8
1.3.2.1 Interação microscópica da radiação eletromagnética com os objetos	9
1.3.3 Manifestação conjunta das interações macroscópicas e microscópicas	10
1.4 Fontes de Radiação Eletromagnética	11
1.5 Interferências Atmosféricas	14
1.6 Espectro Eletromagnético	18
1.7 Conceitos de Radiância e de Reflectância	21
1.8 Resoluções das Imagens	24
1.8.1 Resolução espacial	25
1.8.2 Resolução espectral	27
1.8.3 Resolução radiométrica	30
1.8.4 Resolução temporal	31
2. Sensores Imageadores Multiespectrais na Faixa Óptica (0,45 – 2,5µm)	
2.1 Das Fotos Aéreas às Imagens Multiespectrais	34
2.2 Mecanismos de Imageamento Multiespectral	36
2.2.1 Sensores de varredura mecânica (<i>whiskbroom</i>)	36
2.2.2 Sensores de varredura eletrônica (<i>bushbroom</i>)	38
2.3 As Informações Contidas nas Imagens Multiespectrais da Faixa Óptica	39
2.3.1 Interação da luz solar com os materiais	41
3. Sensores Imageadores na Faixa Termal (8 – 14 µm)	
3.1 Temperatura e Calor	47
3.2 Leis Físicas da Radiação Termal	49
3.3 Emissividade	51
3.4 Temperatura Cinética <i>versus</i> Temperatura Radiométrica	54
3.5 As Imagens do Termal	55
4. Sensor Radar de Abertura Sintética	
4.1 Imageamento Lateral	57
4.2 Polarização da Onda	61
4.3 Geometria de Iluminação	62
4.4 Resolução Espacial	63
4.4.1 Resolução em alcance (<i>range</i>)	63
4.4.2 Resolução azimutal	64
4.5 Radar de Abertura Sintética	66
4.6 Distorções Geométricas	67
4.7 Ruído Speckle	69
4.8 Interação do Pulso de Radar com as Superfícies dos Objetos	70

4.8.1 Em relação ao comprimento de onda	70
4.8.2 Em relação à direção de visada	73
4.8.3 Em relação ao ângulo de incidência local	74
4.9 Constante Dielétrica	74
4.10 Interferometria	76
5. Formatos de Imagens de Sensoriamento Remoto	
5.1 Imagem Digital	77
5.2 Formatos de Arquivos	79
5.3 Formatos de Salvamento	80
6. Distorções e Correções dos Dados da Imagem	
6.1 O que é Processamento de Imagens	82
6.2 Pré-processamento de Imagens Digitais	84
6.2.1 Eliminação de ruídos	85
6.2.2 Correção atmosférica	87
6.2.2.1 Subtração do escuro (<i>dark subtraction</i>)	88
6.2.3 Correções das distorções geométricas	89
6.2.3.1 Correção geométrica	90
6.2.3.2 Georreferenciamento	94
6.2.3.3 Avaliação dos erros da transformação polinomial	96
6.2.3.4 Reamostragem	100
7. Ampliação Histogramática de Contraste	
7.1 Introdução	103
7.2 Representação Histogramática da Imagem Digital	105
7.3 Expansão Linear por Saturação	108
7.4 Expansão Linear por Partes	111
7.5 Expansão por Equalização	113
7.6 Expansão Gaussiana	117
7.7 Função Raiz Quadrada	118
8. Modelos de Cores Aplicados às Imagens	
8.1 Cor	121
8.2 Fatiamento de Histograma	123
8.3 Espaço de Cor RGB	123
8.4 Espaço de Cor IHS	129
8.5 Fusão de Imagens	134
9. Aritmética de Bandas	
9.1 As Operações Aritméticas	138
9.2 Soma	139
9.3 Multiplicação	141
9.4 Subtração	142
9.5 Divisão	
9.5.1 Índice de vegetação	147
9.5.2 Índice de água	150
9.5.3 Índice de minerais	152

10. Transformação por Rotação Espectral.	
10.1 Correlações de Bandas	154
10.2 Transformações por Principais Componentes	155
10.3 Descorrelação de Bandas	164
11. Filtragem	
11.1 Introdução	168
11.2 Filtro Passa-Alta	172
11.3 Filtro Passa-Baixa	174
11.3.1 Filtro passa-baixa de média	174
11.3.2 Filtro de mediana	175
11.4 Filtros de Bordas Direcionais	176
11.4.1 Linear	177
11.4.2 Primeira derivada	177
11.5 Operadores Laplacianos	179
11.6 Filtros Morfológicos	181
11.7 Filtro de Textura	182
11.8 Filtragem no Domínio da Frequência	185
11.8.1 Amostragem	186
12. Classificação Pixel a Pixel de Imagens	
12.1 Introdução	191
12.2 Princípio Básico de Classificação de Imagens	193
12.3 Classificação Não-supervisionada	195
12.3.1 Isodata	195
12.3.2 K-médias	197
12.4 Classificação Supervisionada	198
12.4.1 Paralelepípedo	198
12.4.2 Distância mínima	201
12.4.3 Máxima-Verossimilhança	202
12.4.4 Distância Mahalanobis	202
12.5 Validação da Classificação	206
13. Classificação por Região	
13.1 Segmentação de Imagens	209
13.2 Como se dá a Classificação por Região	213
13.3 Descrições dos Tipos de Classificadores	215
13.3.1 Iseseg	215
13.3.2 Bhattacharayya	216
13.3.3 Clatex	217
13.4 Classificação Usando o Algoritmo Bhattacharyya	217
14. Processamento de Dados Hiperespectrais	
14.1 Introdução	221
14.2 Correção Atmosférica dos Dados	222
14.3 Bibliotecas Espectrais	225
14.4 Identificação de <i>Endmembers</i>	231
14.5 Medições de Intensidade das Feições Espectrais	234

15. Imagens de Alta Resolução Espacial	
15.1 Introdução	239
15.2 Implicações da Resolução Espacial nas Análises do Espaço Urbano	239
15.3 A Título de Exemplo	243
15.4 Imagens de Alta Resolução e Possibilidades para o Mapeamento Cartográfico	248
15.4.1 O Mercado Atual de Imagens de Alta Resolução	249
15.5 Erro Gráfico e Escala	254
15.6 Relação entre Erro Gráfico e Escala	254
15.7 Custo da Geração de uma Base Cartográfica	255
Referências Bibliográficas	258
Índice Alfabético	264

PREFÁCIO

A disseminação do conhecimento em muitas áreas da ciência enfrenta uma dificuldade histórica em nosso país. Trata-se da existência limitada, ou até mesmo da ausência, de livros-texto com conteúdo atualizado em língua portuguesa. É nesse cenário que surge esta importante obra, organizada por Paulo Roberto Meneses e Tati de Almeida, ambos docentes da Universidade de Brasília, enfocando o processamento de imagens de sensoriamento remoto.

Escrita em conjunto com outros especialistas no tema, da UnB e da Embrapa, a obra vem preencher essa lacuna com brilhantismo, oferecendo a estudantes de graduação e de pós-graduação, assim como a docentes e pesquisadores, o acesso a conceitos, princípios e métodos do processamento de imagens de sensoriamento remoto. A opção dos autores por uma linguagem simples, porém sempre rigorosa quanto aos aspectos técnico-científicos das técnicas abordadas, tem a grande vantagem de torná-lo acessível a esses públicos diversos. Com isso, os autores buscam transmitir o conhecimento sobre a aplicação das técnicas digitais de processamento para a geração de informações a partir da análise de imagens de sensoriamento remoto.

O livro abrange desde os fundamentos do sensoriamento, passando pela descrição de como operam os sensores e como são adquiridas as imagens, e chegando aos vários conjuntos de técnicas empregadas na extração de informações a partir de imagens coletadas pelos sensores nas diversas regiões do espectro eletromagnético. Por meio de capítulos dedicados, o livro aborda técnicas específicas de processamento de imagens geradas por sensores que empregam tecnologias de alta resolução espacial e espectral.

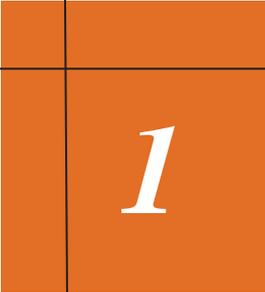
Outro aspecto do livro digno de destaque é o seu formato eletrônico (e-book). Essa inovação, plenamente compatível com o momento em que vivemos, possibilita o acesso livre e gratuito à obra. Essa atitude louvável dos autores terá certamente impacto significativo para a disseminação dos conhecimentos contidos na obra, levando-os diretamente para as salas de aula, laboratórios, bibliotecas e ambientes de trabalho.

Por todos esses aspectos, parabênizo os organizadores e autores da obra, expressando a certeza de que ela será uma referência de fundamental importância para a comunidade de língua portuguesa do sensoriamento remoto.

Álvaro Penteado Crósta

PRINCÍPIOS DE SENSORIAMENTO REMOTO

Paulo Roberto Meneses



1

1.1 **História Inicial**

Sensoriamento remoto, termo cunhado no início dos anos de 1960 por Evelyn L. Pruitt e colaboradores, é uma das mais bem sucedidas tecnologias de coleta automática de dados para o levantamento e monitoração dos recursos terrestres em escala global.

Atualmente, a resolução espectral das imagens obtidas pelos sensores imageadores já ultrapassa centenas de bandas, e a resolução espacial de muitas imagens já é maior que 1 metro, possibilitando suas aplicações nas áreas de levantamentos de recursos naturais e mapeamentos temáticos, monitoração ambiental, detecção de desastres naturais, desmatamentos florestais, previsões de safras, cadastramentos multifinalitários, cartografia de precisão, defesa e vigilância, entre outras. O acelerado avanço com que o sensoriamento remoto se desenvolveu em poucas décadas deve-se à revolução nos meios de se observar à Terra numa escala global e periódica, e na rapidez da monitoração dos fenômenos dinâmicos e das mudanças das feições terrestres. É uma tecnologia empregada em escala mundial e que, talvez, reúna a maior diversidade de pesquisadores e usuários, em torno de uma tecnologia de aplicação.

O Instituto Nacional de Pesquisas Espaciais - INPE teve uma ação decisiva na consolidação do sensoriamento remoto como uma tecnologia de uso em escala nacional, projetando o Brasil como a nação pioneira no hemisfério sul a dominar essa tecnologia. Mesmo antes do lançamento do primeiro satélite de sensoriamento remoto em 1972, o INPE se destacava como uma das primeiras instituições, na área espacial, a investir em pesquisas de sensoriamento remoto, como é exemplo a Missão 96, um projeto executado em colaboração com a NASA, que realizou um levantamento experimental aerotransportado com diversos tipos de sensores imageadores na região do Quadrilátero Ferrífero, em Minas Gerais. Formador na década de 1970 dos primeiros pesquisadores especializados em sensoriamento remoto, contribuiu decisivamente para o desenvolvimento das metodologias de interpretação de imagens e de processamento digital, e na disseminação do uso de imagens de satélite por todo o território nacional.

A origem do sensoriamento remoto nos anos de 1960 deve-se ao espetacular desenvolvimento da área espacial nesses anos, que ficou conhecida como a década da corrida espacial. Foi nesse período que se viu o mais rápido desenvolvimento de foguetes lançadores de satélites, que possibilitou colocar no espaço satélites artificiais para várias finalidades. Os satélites meteorológicos foram os pioneiros e, por meio deles, quase que de uma maneira acidental é que o sensoriamento remoto deu os seus primeiros passos. O primeiro desses satélites meteorológicos foi o TIROS-1 (*Television IR Operational Satellite*), lançado em 1960 pelos Estados Unidos. Além dos padrões de cobertura de nuvens, as imagens do TIROS mostravam, embora com pouca nitidez, algumas feições da superfície da Terra, que pela primeira vez demonstraram ser possíveis de serem vistas do espaço. Melhoramentos dos subsequentes sensores dos satélites meteorológicos deram a oportunidade para iniciar os

primeiros estudos mais detalhados de feições terrestres de áreas de coberturas de neves, gelos polares, águas oceânicas e cadeias de montanhas.

A década de 1960 foi, também, a década em que o homem pôde ir ao espaço em satélites tripulados e de lá observar a Terra e tomar as primeiras fotos da superfície terrestre, usando câmeras fotográficas manuais. Foram essas experiências realizadas pelos programas espaciais tripulados Mercury, Gemini, e Apollo, que asseguraram o futuro do sensoriamento remoto. A missão GT-4 do programa Gemini foi o primeiro programa fotográfico espacial com o objetivo específico para estudos geológicos. Interpretações dessas fotos em preto e branco e coloridas, na escala de 1:350.000, descobriram novas feições geológicas que não constavam nos mapas geológicos em escalas maiores, de 1:250.000. A partir do sucesso da missão GT-4 foram incluídos no programa Apollo experimentos controlados envolvendo a aquisição de fotografias multiespectrais, usando um conjunto de quatro câmeras Hasselblad, munidas cada uma de filmes pancromáticos com filtros vermelho e verde e filmes infravermelhos. Foi dessa maneira que se obteve a primeira imagem multiespectral da Terra. O satélite americano Corona e o soviético Zenit, lançados no final dos anos de 1960, foram as últimas missões espaciais fotográficas.

Os excelentes resultados desses programas espaciais impulsionaram as pesquisas para a construção de novos equipamentos capazes de fotografar à Terra, mas não com o uso de câmeras fotográficas, visto que a substituição de filmes no espaço seria algo impossível de se fazer. Esses equipamentos deveriam ter a capacidade de recobrir a superfície terrestre e de armazenar ou transmitir para à Terra os dados coletados. A única possibilidade para fazer isso era obter os dados em formatos digitais, usando-se equipamentos eletrônicos.

Da metade para o final da década de 1960 esses equipamentos começaram a ser testados em aeronaves como programas de simulação, para serem posteriormente instalados a bordo de satélites. Eles receberam o nome de sensores imageadores, em razão do processo de cobertura do terreno ser feito na forma de varredura linear do terreno e não por um mecanismo de tomada instantânea de área, em quadro, como é feito com câmeras fotográficas. Por isso, o produto gerado por esses novos sensores recebeu a denominação de imagem, a fim de diferenciá-lo pelo seu processo de aquisição, das tradicionais fotos aéreas. Outra importante diferença dos sensores imageadores foi a capacidade de obterem imagens simultâneas em várias faixas do espectro eletromagnético.

A despeito das diferenças dos mecanismos de aquisição entre as imagens de satélite e as fotos aéreas, notamos que são produtos que guardam muitas semelhanças, pelo fato de terem a mesma finalidade, que é a de retratar os objetos ou fenômenos da superfície terrestre. As vantagens de um sobre o outro são várias, mas apenas para justificar o que impulsionou o uso dos sensores imageadores por satélites, pode-se citar a sua capacidade de imagear em curto espaço de tempo toda a superfície do planeta e de uma maneira sistemática, dado que um satélite fica continuamente orbitando à Terra. Essa forma de cobertura repetitiva, obtendo imagens periódicas de qualquer área do planeta, propicia detectar e monitorar mudanças que acontecem na superfície terrestre. Essa é a principal razão pela qual as imagens de satélites passaram a ser a mais eficiente ferramenta para uso nas aplicações que envolvem análises ambientais dos diversos ecossistemas terrestres.

A perfeita combinação dessas duas tecnologias, satélites artificiais e sensores imageadores, talvez tenha sido um dos maiores benefícios até hoje presenciado pelo desenvolvimento tecnológico a serviço do levantamento dos recursos naturais terrestres.

Um marco importante que deu início à era do sensoriamento remoto moderno foi o lançamento pelos Estados Unidos, do primeiro satélite de sensoriamento remoto, ERTS-1, posteriormente renomeado para Landsat 1, colocado em órbita em 1972 a cerca de 919 km de altura. O sensor imageador multiespectral desse primeiro satélite de sensoriamento remoto possibilitava a obtenção simultânea de quatro imagens nas faixas do espectro do visível e do

infravermelho próximo e uma imagem no termal, portanto além do que era possível com o uso de filmes fotográficos. A largura da área imageada na Terra por cada órbita do satélite era de 185 km, o que permitia uma visão sinótica, até então, impossível de ser obtida com as câmeras fotográficas aéreas. A cada 18 dias uma nova imagem com resolução espacial de 76 metros era obtida de qualquer área do planeta.

Do programa americano Landsat seguiram-se outros, europeus, canadenses, asiáticos e sul americanos, cada um procurando atender, cada vez mais, necessidades específicas, quer sejam em função das características geográficas das diversas regiões terrestres ou em função das suas aplicações. Atualmente, há em circulação no espaço dezenas de sensores orbitais imageando a superfície da Terra em todas as faixas espectrais possíveis, com os mais variados parâmetros de resolução espacial e temporal. De um lado há os sensores hiperespectrais com centenas de bandas espectrais (centenas de imagens) e do outro, há os sensores de alta resolução espacial, capazes de detectar objetos na superfície da Terra, menores que 50 cm. E para atravessar a opacidade das nuvens, muito frequente em regiões como a Amazônia, há os sensores de radar com as suas fontes artificiais de radiação eletromagnética que fazem das nuvens um objeto transparente.

1.2

Definição de Sensoriamento Remoto

Historicamente, reconhece-se que o termo Sensoriamento Remoto foi criado para designar o desenvolvimento dessa nova tecnologia de instrumentos capaz de obterem imagens da superfície terrestre a distâncias remotas. Por isso, a definição mais conhecida ou clássica de sensoriamento remoto é: *Sensoriamento remoto é uma técnica de obtenção de imagens dos objetos da superfície terrestre sem que haja um contato físico de qualquer espécie entre o sensor e o objeto.*

A condição principal imposta por essa definição clássica, que é o sensor estar a uma distância remota do objeto, estabelece a base para definir o sensoriamento remoto numa concepção um pouco mais científica, que é regida segundo os seguintes preceitos:

- i) *exigência*: ausência de matéria no espaço entre o objeto e o sensor;
- ii) *consequência*: a informação do objeto é possível de ser transportada pelo espaço vazio;
- iii) *processo*: o elo de comunicação entre o objeto e o sensor é a radiação eletromagnética, a única forma de energia capaz de se transportar pelo espaço.

Com base nesses preceitos, uma definição mais científica que se pode dar ao Sensoriamento Remoto seria: *Sensoriamento Remoto é uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.*

Essa definição de sensoriamento remoto é explícita em afirmar que o objeto imageado é registrado pelo sensor por meio de medições da radiação eletromagnética, tal como a luz solar refletida da superfície de qualquer objeto. Nenhum outro tipo de sensor que obtenha imagens que não seja pela detecção da radiação eletromagnética deve ser classificado como sensoriamento remoto. A confusão mais comum é feita com os sensores geofísicos aerotransportados, tais como os magnetômetros, que geram uma imagem a partir medições de campos de força do campo magnético da superfície terrestre, portanto sem nenhuma relação com a energia eletromagnética.

Por outro lado existe a errônea concepção de apenas considerar como sensoriamento remoto as imagens obtidas de satélites, visto que o termo foi criado quando a era espacial deu início. As fotografias aéreas, que por mais de um século vêm sendo usadas como uma forma

de observar a Terra são, obrigatoriamente, uma classe de sensores remotos. O filme fotográfico foi o primeiro material construído pelo homem capaz de registrar a radiação eletromagnética e de transformá-la na imagem do objeto fotografado.

A partir da definição de sensoriamento remoto fica óbvio que só se pode entender o processo de aquisição e de análise das imagens, se conhecermos primeiro o que é a radiação eletromagnética - REM.

1.3

Natureza da Radiação Eletromagnética

A explicação do que é a radiação eletromagnética (REM) começa com o entendimento da dualidade do comportamento da sua natureza: *onda e energia*. Isso quer dizer que a REM que se propaga pelo espaço vazio, como a luz solar, é, ao mesmo tempo, uma forma de onda e uma forma de energia. Esse conceito de dualidade é extremamente importante para o sensoriamento remoto, pois sempre que alguém estiver analisando qualquer tipo de imagem de sensoriamento remoto, a coexistência da radiação eletromagnética na forma de onda e na forma de energia deverá ser considerada para que se possa explicar tudo o que se observa nas imagens com referência às características dos objetos. A dualidade do comportamento da radiação eletromagnética, onda e energia, é formulada pelos modelos denominados de ondulatório (onda) e corpuscular (energia).

1.3.1

Modelo Ondulatório

Segundo o modelo ondulatório, a REM pode ser explicada como uma forma de onda senoidal e harmônica. De acordo com as formulações de Maxwell, uma partícula carregada eletricamente gera um campo elétrico em torno de si e o movimento dessa partícula gera, por sua vez, um campo magnético. Ambos os campos, elétrico e magnético, atuam vibrando ortogonalmente entre si e possuem as mesmas amplitudes, isso é, alcançam os seus máximos ao mesmo tempo. As variações do campo são causadas pelas vibrações da partícula. Quando essa partícula é acelerada, as perturbações entre os dois campos se propagam repetitivamente no vácuo em uma direção ortogonal à direção dos campos elétricos e magnéticos, como é mostrado na Figura 1.1. Essas perturbações dos campos elétrico (E) e magnético (M) são chamadas de ondas eletromagnéticas. O comprimento da radiação eletromagnética depende de quanto tempo a partícula é acelerada, e a frequência ν da radiação depende da frequência de vibração da partícula. Assim, define-se uma onda eletromagnética como a oscilação dos campos E e M , segundo um padrão harmônico de ondas, isso é, ondas espaçadas repetitivamente no tempo. Esses campos dinâmicos sempre ocorrem juntos como padrões inseparáveis, de modo que nem campo elétrico puro, nem campo magnético puro de ondas irradiadas ocorrerão separadamente um do outro.

As ondas eletromagnéticas propagam-se no vácuo na velocidade da luz ($c=299.292,46$ km/s ou aproximadamente 300.000 km/s). Se for medida a distância entre dois picos sucessivos de ondas (Figura 1.1), determina-se o comprimento ou tamanho da onda, que é simbolizado pela letra grega λ e expresso no sistema de unidades métricas. As ondas podem ter comprimentos da ordem de bilionésimo de metro (raios cósmicos), até dimensões de quilômetros (ondas de rádio).

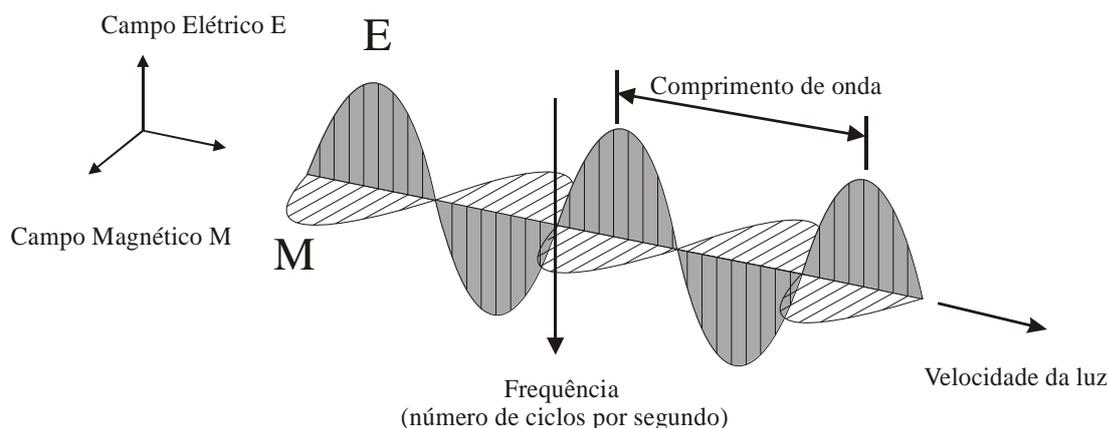


Fig. 1.1- Direção de propagação da radiação eletromagnética na forma de uma onda, em função das oscilações ortogonais dos campos magnético (M) e elétrico (E).

Se medirmos o número de picos de ondas que passa por um ponto fixo de referência no espaço, podemos determinar a sua frequência ν . Como a velocidade de propagação da onda é constante, as ondas com comprimentos menores têm frequências maiores, ou seja, um maior número de ondas passa pelo ponto de referência num dado tempo. Inversamente, as de comprimentos maiores têm frequências menores. Da física clássica a seguinte relação entre o comprimento de onda λ e a frequência ν exprime a lei do comportamento ondulatório:

$$\lambda = \frac{c}{\nu}$$

eq.1.1

Por costume de uso, em sensoriamento remoto sempre nos referimos à radiação eletromagnética pelo seu comprimento e não pela sua frequência. Por exemplo, a radiação eletromagnética equivalente à luz solar azul é de comprimento de onda de 0,455 micrômetros ou μm (1micro ou μ é igual a 10^{-6}m) e a luz solar vermelha é de comprimento de onda de 0,617 μm .

Como por definição o sensoriamento remoto é uma medida da interação da radiação eletromagnética com a superfície dos objetos, segundo o modelo ondulatório as características das imagens são explicadas tendo-se em conta a relação entre o tamanho da onda e o tamanho do objeto. Esse modo de interação é denominado de interação macroscópica, que adiante será discutido com mais detalhes.

Um bom exemplo para explicar esse comportamento são as interações da radiação eletromagnética que ocorrem com as nuvens. As radiações eletromagnéticas das ondas do visível e do infravermelho da luz solar, que são de comprimentos de 0,4 a 2,5 μm , possuem em média, tamanhos menores que o tamanho médio das moléculas de vapor de água que compõem uma nuvem, que é da ordem de 30 μm . Devido a essa enorme diferença entre o tamanho das ondas do visível e do infravermelho com o tamanho das moléculas de vapor de água das nuvens, a REM incidente nas nuvens é barrada por essas moléculas e refletida de volta ao espaço. Elas não conseguem atravessar a nuvem. Então, o sensor registrará a intensidade da reflectância da nuvem, formando uma imagem da nuvem e não dos objetos que estão sobre a superfície terrestre. Um dos sensores mais conhecidos que operam nos comprimentos de onda do visível e do início do infravermelho próximo é a câmera

fotográfica. É conhecido de todos que se no dia do levantamento aéreo houver alguma presença de nuvens, na foto a nuvem estará presente.

E o que acontece se o comprimento da onda for maior que o diâmetro das partículas gasosas das nuvens, como é o caso das ondas eletromagnéticas de comprimentos das micro-ondas, com tamanhos da ordem de 1 a 100 cm? Para entender isso devemos considerar que uma nuvem nada mais é do que um amontoado de partículas de vapor, ou seja, um gás. Neste caso, apenas uma mínima fração da dimensão da onda de tamanho centimétrico é barrada pelo correspondente tamanho da partícula, o resto da onda passando por ela. Portanto, a nuvem não é capaz de barrar fisicamente a passagem da onda. Assim, a onda atravessa a nuvem e incide nos objetos da superfície terrestre, sendo por eles refletida de volta para o sensor, que registra as imagens desses objetos. Neste caso, pode-se dizer que as nuvens são transparentes aos comprimentos de onda relativamente grandes das micro-ondas. Os sensores que trabalham com as micro-ondas são denominados de radar. Em imagens de radar, mesmo que o céu esteja totalmente coberto por nuvens, a imagem formada é uma imagem limpa, aparecendo nela toda a superfície do terreno. Daí, a grande utilidade dos sensores radares nas áreas com frequentes coberturas de nuvens, como é o caso da região amazônica brasileira.

1.3.1.1

Interação macroscópica da radiação eletromagnética com os objetos

Os exemplos que acabou-se de apresentar são elucidativos para mostrar que quando a interação da radiação eletromagnética com os objetos é controlada pelas relações do tamanho da onda com o tamanho dos objetos, as informações que se apresentam nas imagens dizem respeito às características das dimensões ou formas dos objetos. Neste caso, é dito que o processo de interação da onda com os objetos é uma interação macroscópica. Na prática, nas imagens de sensoriamento remoto a interação macroscópica é a resposta da intensidade com que um objeto reflete a radiação eletromagnética em razão do tamanho da onda e a textura da superfície do objeto. A textura representa a rugosidade topográfica da superfície. Ela pode ser estimada pelas variações verticais de altura da superfície de um material e se mostra muito eficiente para explicar as diferenças observadas nas imagens entre as diversas formas de relevo, os tipos de dosséis da vegetação, ou da superfície lisa de um corpo d'água calmo ou com ondas revoltas.

Em sensoriamento remoto as texturas das superfícies dos objetos vistas nas imagens podem ser classificadas em dois tipos: especulares e difusoras. Podemos usar o critério geral de Rayleigh (h) para determinar se uma superfície é especular ou difusora, o que é dependente do comprimento de onda e do ângulo de incidência (θ) da radiação, segundo a seguinte equação:

$$h \leq \lambda / (8 \cos \theta) \text{ ou } h \geq \lambda / (8 \cos \theta)$$

eq.1.2

onde, h = altura média da superfície

θ = ângulo de incidência

λ = comprimento de onda

Quando $h \leq \lambda / (8 \cos \theta)$ a imagem do objeto é classificada como uma superfície especular de textura lisa, e quando $h \geq \lambda / (8 \cos \theta)$ a superfície do objeto é classificada como uma superfície difusora de textura rugosa, como mostra a Figura 1.2.

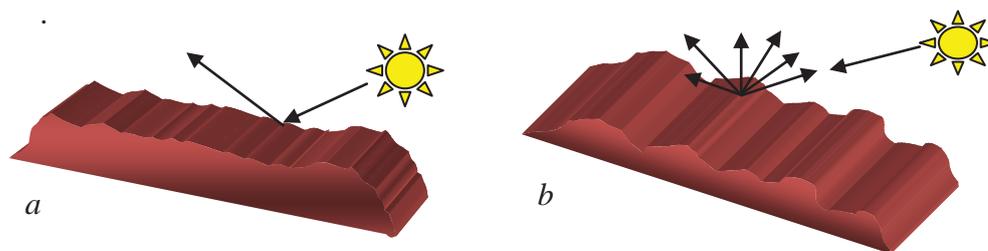


Fig. 1.2 Comportamento da reflectância condicionada à rugosidade da superfície do alvo. (a) reflectância especular de uma superfície lisa com o raio incidente refletido no sentido oposto com o mesmo ângulo. (b) reflectância difusora de uma superfície rugosa com os raios refletidos espalhados em todas as direções.

Em alguns casos pode-se ter uma mistura de reflectância especular e difusora. Para todos os efeitos, costuma-se classificar uma superfície como sendo difusora quando 25% ou mais da radiação é refletida difusamente. Na natureza, a maioria dos objetos tem comportamento difuso em relação aos comprimentos de onda.

Do que foi discutido podemos concluir que a condição para uma superfície ser classificada como especular ou difusa, depende do comprimento de onda incidente. Por exemplo, um solo gradeado, cuja textura medida pelas mínimas variações da altura da sua superfície seja de poucos centímetros, será considerado rugoso na faixa de comprimento de onda do visível ($0,40 \mu\text{m}$ a $0,76 \mu\text{m}$), pois o tamanho da onda é milhões de vezes menor que o tamanho das variações de altura h da superfície do solo. No entanto, o mesmo solo poderá ser considerado liso, ou seja, especular, na faixa das micro-ondas, visto que as micro-ondas têm comprimentos de onda até 100 cm. Dessa forma, as áreas de solos arados vistas nas imagens desses dois comprimentos de onda, visível e micro-ondas, serão diferentes. O usuário de sensoriamento remoto que não souber das implicações desse processo de interação macroscópica julgará, analisando as duas imagens, que são solos com texturas diferentes, imaginando, talvez, que as imagens tenham sido tomadas em datas diferentes.

Para o sensoriamento remoto, o modelo ondulatório se aplica melhor para os grandes comprimentos de onda das micro-ondas das imagens de radar, que são obtidas com λ maiores que 3,0 cm. Observe na Figura 1.3 de uma imagem de radar, que os alvos escuros representam superfícies especulares (água e solo gradeado) nas quais a onda eletromagnética foi refletida em direção oposta à direção de visada do sensor, e assim nenhuma radiação voltou ao sensor para ser registrada. Os demais níveis de cinza representam alvos com reflectância difusa que retornaram ao sensor.



Fig. 1.3 Imagem de radar de comprimento de onda de 23 cm mostrando alvos de textura lisa com reflectância especular (tons de cinza escuros) e alvos de textura rugosa com reflectância difusora (tons de cinza variados).

1.3.2 Modelo Corpuscular

As formulações de Maxwell sobre o comportamento da radiação eletromagnética como um movimento de ondas suaves dos campos elétrico e magnético falham em explicar certos importantes fenômenos quando a radiação eletromagnética interage com a matéria. Esse comportamento é mais evidente para as ondas de pequenos comprimentos.

Desde os primeiros experimentos de geração de ondas eletromagnéticas observou-se que a radiação é emitida em forma de pulsos que carregam certa quantidade de energia. Em 1901 Planck observou que a REM transferia energia de um corpo para outro em quantidades fixas e discretas, à qual denominou de fótons. O fóton é a forma física de um quantum, a partícula básica estudada em mecânica quântica (ramo da física que se dedica com o muito pequeno, nos níveis atômicos ou subatômicos), e que pode ser descrita como a partícula mensageira da energia da onda eletromagnética. Os fótons são como corpúsculos de energia sem matéria. Assim, uma onda eletromagnética exibe propriedades de partículas, como as partículas (elétrons) exibem propriedades de onda.

O conceito de energia discreta é muito importante e revolucionou a física do século XX, que até então considerava que qualquer forma de energia era contínua. O termo discreto significa que a intensidade de energia transportada pela radiação eletromagnética num dado comprimento de onda é sempre a mesma, independente do momento que é medida. Para cada comprimento de onda há uma específica quantidade de energia.

Segundo o modelo corpuscular pode-se definir que a radiação eletromagnética é uma forma dinâmica de energia que se manifesta somente por suas interações com a matéria. A quantidade de energia E de um quantum é diretamente proporcional à frequência ν da radiação:

$$E = h\nu \quad \text{eq.1.3}$$

onde, E = energia
 h = constante de Planck ($6,624 \times 10^{-34}$ Joules.seg)
 ν = frequência

Substituindo-se ν por λ a partir da equação 1.1 do modelo ondulatório, tem-se que:

$$E = hc/\lambda \quad \text{eq.1.4}$$

Da equação 1.4 verifica-se que um fóton de energia E é inversamente proporcional ao comprimento de onda da REM. Os comprimentos de ondas menores transportam, conseqüentemente, maiores quantidades de energia. Um fóton de luz visível com comprimento de onda de $0,6 \mu\text{m}$ tem uma energia de $3,3 \times 10^{-19}$ J, e um fóton de uma onda de rádio, com comprimento de dois metros, tem uma energia muito menor, de $9,9 \times 10^{-26}$ J. A unidade usada em física atômica e óptica quântica é o elétron-volt, que é igual a $1,59 \times 10^{-19}$ joules.

De acordo com o modelo corpuscular, a energia da onda, ao atingir a superfície dos materiais, interage com ela por meio de trocas de energia entre a energia discreta que carrega e as energias, também discretas, contidas nos átomos e moléculas da matéria. As energias contidas nos átomos e moléculas estão distribuídas por níveis de energia, que são determinados pelos orbitais dos elétrons em torno do núcleo e pelas forças de vibrações das ligações moleculares. Para haver uma troca ou interação da energia da radiação da onda com

a energia da matéria, é preciso que a REM incidente seja em parte absorvida pelos elétrons ou moléculas, o que promove uma mudança do elétron de um orbital para outro de maior energia, ou em um aumento da intensidade da vibração molecular (Figura 1.4). A parte da energia da radiação eletromagnética que não é absorvida é refletida para o sensor. Nesse processo, as imagens medem a radiação refletida, mas, indiretamente, podemos avaliar o que foi absorvido pelos materiais. Isso é importante, porque são essas quantidades de energia eletromagnética absorvidas pelos materiais que definem algumas informações sobre a composição dos alvos terrestres, nas imagens de sensoriamento remoto.



Fig. 1.4 A absorção da radiação eletromagnética pelos materiais desloca o elétron para um orbital de maior energia (a) ou aumenta a frequência dos movimentos vibracionais da molécula (b).

1.3.2.1

Interação microscópica da radiação eletromagnética com os objetos

Como as energias da radiação eletromagnética e as energias dos átomos e moléculas são discretas, as trocas de energia somente ocorrerão se a quantidade de energia contida na REM for exatamente igual àquela necessária para promover uma mudança nos níveis de energia dos átomos ou moléculas. Nesse caso, é dito que a interação é do tipo microscópico, pois ocorre nos níveis microscópicos dos átomos e moléculas e é, portanto, totalmente dependente da constituição química (atômica/molecular) do material. Materiais de diferentes composições, ou seja, com diferentes constituições de elementos químicos de átomos e moléculas, têm absorções e reflectâncias diferentes, resultando nas imagens em diferentes tons de cinza. Para o sensoriamento remoto, o modelo corpuscular é mais adequado para os comprimentos de ondas menores, porque esses possuem maiores energias, como previsto pela equação 1.4. A Figura 1.5 é um esquema bastante simplificado para exemplificar a interação microscópica por trocas de energia segundo o modelo corpuscular da REM, para dois diferentes tipos de rocha. Os hipotéticos diagramas dos níveis de energia dos átomos de Fe e da molécula CO₃ necessitam de intensidade de energias eletromagnéticas para promoverem o salto quântico para níveis de energia superiores, para isso absorvendo intensidades de radiações eletromagnéticas de comprimentos de ondas diferentes.

Nos comprimentos de ondas grandes e, portanto, com muito baixa energia, como nas micro-ondas, não ocorre interação ao nível microscópico. A quantidade de energia dessas ondas é insuficiente para provocar uma mudança nos níveis energéticos dos átomos ou moléculas e, conseqüentemente, pouquíssima quantidade de energia incidente é absorvida pela matéria. Por isso, como mencionado anteriormente, a região das micro-ondas se ajusta mais ao modelo ondulatório ou macroscópico.

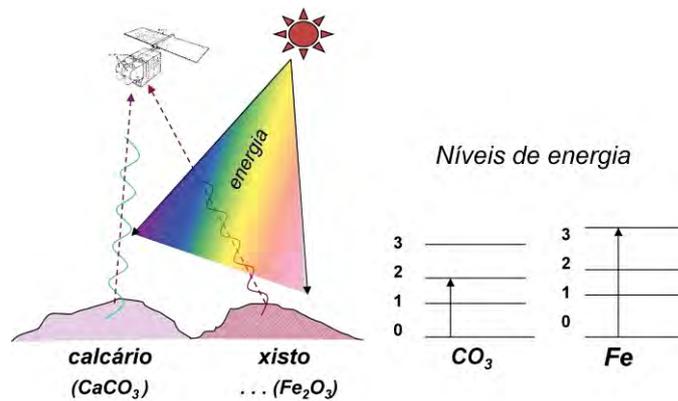


Fig. 1.5 Rochas calcárias e xistos absorvem com intensidades diferentes radiações eletromagnéticas de diferentes comprimentos de onda devido aos diferentes valores dos níveis de energia que apresentam as moléculas de CO_3 e os átomos de Fe.

Em resumo, pode-se dizer que devido à dualidade da natureza da radiação eletromagnética, o modelo ondulatório se relaciona com as propriedades texturais dos objetos, enquanto que o modelo corpuscular às propriedades composicionais. Sendo assim, para se discriminar ou diferenciar nas imagens de sensoriamento remoto um objeto do outro, como uma ardósia de um granito, deve-se ter imagens nos comprimentos de onda de alta energia, que possam interagir com os minerais constituintes. E para que possamos ver as diferenças das duas rochas, em função tão somente de suas texturas (formas de relevo), é aconselhável ter imagens nos grandes comprimentos de onda, onde a textura da superfície das rochas é que comanda as intensidades de reflectância.

1.3.3

Manifestação Conjunta das Interações Macroscópica e Microscópica

Devido à indissociabilidade de onda e energia, somos obrigados a afirmar que as imagens dos objetos sempre são, em maior ou menor proporção, as respostas em função do tamanho da onda e da intensidade de sua energia. Como antes apresentado, é prático considerar que para os menores comprimentos de onda a imagem dos objetos é o retrato da interação ao nível microscópico com as suas composições e para os maiores comprimentos de onda a imagem dos objetos é o retrato da interação ao nível macroscópico com a rugosidade de suas superfícies.

Há, particularmente, uma situação que serve de maneira didática para demonstrar a atuação conjunta das duas formas de interação. Podemos ver isso na Figura 1.6 a partir de imagens tomadas de uma área de densa cobertura vegetal, da região amazônica. As duas imagens são do sensor TM do Landsat-5, uma da região do infravermelho próximo de $0,76 \mu\text{m}$ a $0,90 \mu\text{m}$ (banda 4) e a outra da região do visível de $0,63 \mu\text{m}$ a $0,69 \mu\text{m}$ (banda 3). A primeira impressão é de que na imagem do infravermelho próximo se consegue ver o relevo abaixo das árvores. Na realidade, ambas as imagens são a reflectância apenas das folhas das árvores, haja vista que nesses comprimentos de onda a radiação eletromagnética não consegue penetrar a vegetação. Na figura à direita vemos que a topografia dos dosséis é uma reprodução bem aproximada da topografia do relevo subjacente e, por isso, a radiação solar incidente ilumina as faces frontais do relevo e sombreia as faces opostas. Combinando as

condições de iluminação do relevo com as informações do padrão de comportamento da reflectância da vegetação (lado direito da figura), podemos ver que na imagem do visível as faces opostas sombreadas exibem níveis de cinzas escuros e as faces frontais que refletem a radiação eletromagnética também exibem níveis de cinzas escuros devido à alta absorptância da vegetação no visível. A falta de contraste dos níveis de cinza não favorece, ao olho humano, uma visão tridimensional do relevo. Na imagem do infravermelho próximo as faces sombreadas continuam a exibir níveis de cinzas escuros, mas devido à alta reflectância da vegetação neste comprimento de onda, as faces frontais exibem níveis de cinza-claro, criando uma condição de alto contraste entre as faces, o que favorece a percepção visual humana em 3D. Nesta banda do infravermelho próximo as interações macroscópicas e a microscópica se combinam, favoravelmente, para se ter a imagem do relevo.

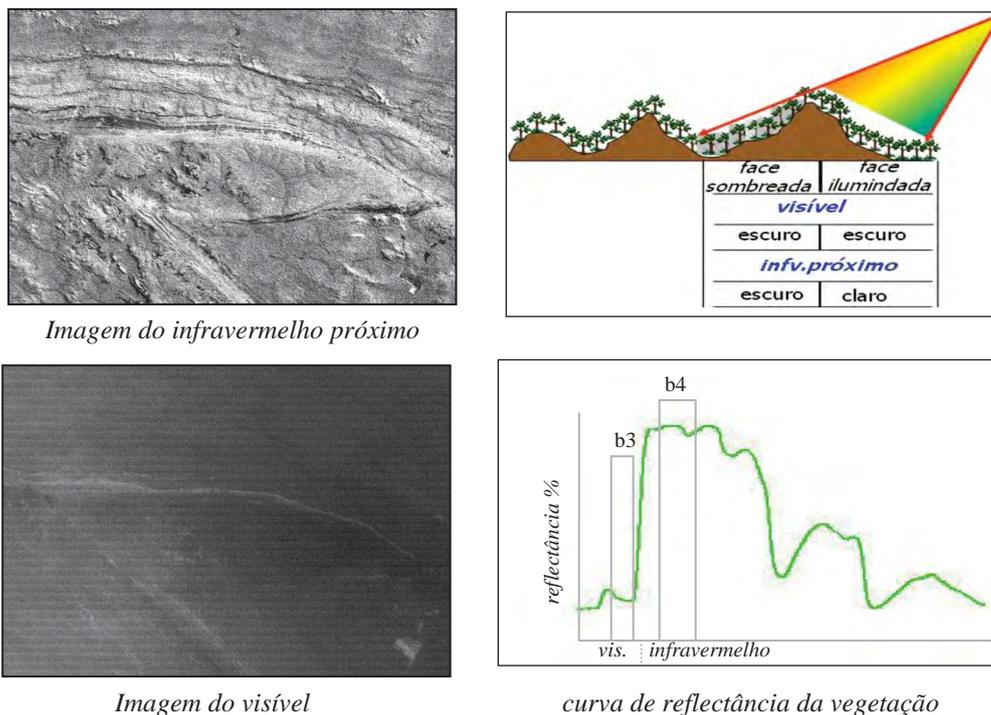


Fig. 1.6 Nas imagens com densa cobertura vegetal (floresta amazônica) a associação da interação macroscópica e microscópica da radiação eletromagnética com a superfície das copas das árvores, em um relevo montanhoso, possibilita a observação aparente do relevo somente na imagem do infravermelho próximo.

1.4 Fontes de Radiação Eletromagnética

Todos os objetos do mundo real que estejam a uma temperatura acima de zero absoluto ($-273,15^{\circ}\text{C}$ ou zero Kelvin) apresentam uma movimentação aleatória das partículas dos átomos e das moléculas. Quando essas partículas se colidem elas mudam o seu estado de energia e emitem radiação eletromagnética. E quanto maior é a temperatura da fonte, maior é a sua potência irradiante de energia.

As imagens de sensoriamento remoto não dependem apenas das qualidades técnicas dos sensores, mas, também, da qualidade e intensidade irradiante das fontes de REM. No nosso sistema planetário o Sol é a mais potente fonte de radiação eletromagnética devido a

sua alta temperatura de superfície, próxima a 6000°C. A Terra também é uma fonte de REM, embora bem menos potente que o Sol, pois a sua temperatura média é de apenas 27°C. Essas duas fontes naturais de radiação eletromagnética são as mais usadas em sensoriamento remoto, mas como veremos adiante, elas não conseguem emitir radiação de todos os comprimentos de onda. Por isso, o homem construiu fontes artificiais capazes de emitirem altas intensidades em comprimentos de onda, além da capacidade do Sol ou da Terra, como na região das micro-ondas.

O cálculo da intensidade da energia que uma fonte de REM emite foi modelado por Planck, que idealizou uma fonte padrão de radiação eletromagnética, chamada de corpo negro. Um corpo negro é um modelo físico teórico de um perfeito absorvedor e emissor de energia eletromagnética. Planck utilizou esse modelo de corpo negro para calcular a quantidade máxima de intensidade radiante que uma fonte emite em um dado comprimento de onda, em função de sua temperatura de superfície. A partir desse modelo, em 1901 Planck formulou a seguinte lei, conhecida com Lei de Planck, que é derivada da mecânica quântica.

$$E_{\lambda} = \frac{2\pi hc^2}{\lambda^5 \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]}$$

eq.1.5

onde, E_{λ} = energia radiante espectral medida em $W m^{-2} \mu m^{-1}$;
 h = constante de Planck = $6,6256 \times 10^{-34} W.s^2$;
 c = velocidade da luz = $2,997925 \times 10^8 m.s^{-1}$
 k = constante de Boltzman = $1,38054 \times 10^{-23} W s ^{\circ}K^{-1}$
 T = temperatura absoluta (em °K) da fonte.

Substituindo as constantes pelos seus valores, a forma mais usual da equação 1.5 é apresentada como:

$$M_{\lambda} = \frac{3,7415 \times 10^5}{\lambda \left[\exp\left(\frac{1,43879 \times 10^4}{\lambda T}\right) \right] - 1}$$

eq. 1.6

Resolvendo matematicamente a equação 1.5 de Planck, chega-se às curvas de distribuição de energia emitida por uma fonte a uma dada temperatura de superfície (Figura 1.7). Para cada temperatura há um pico máximo de emissão dentro do intervalo de comprimento de onda que a fonte emite. Por lei, qualquer material real não pode emitir termalmente a uma taxa que exceda à do corpo negro.

Entre as várias curvas de emitância radiante espectral da Figura 1.7, a que mostra a distribuição da energia a 6000 K é a que mais se aproxima da curva de emitância espectral do Sol. Observe nesta figura que o pico máximo de emitância situa-se no comprimento de onda de 0,49 μm , ou seja, na região espectral da luz visível. Já para a curva de emitância radiante da fonte a 300 K, que é comparável à temperatura média da superfície da Terra, o seu pico máximo de energia emitida está situado no comprimento de onda de 9,6 μm . O Sol e a Terra, que são fontes reais naturais, mostram curvas de emitância radiante próximas aos padrões das fontes de corpo negro de Planck. A Terra, por ter uma temperatura interna muito mais baixa que o núcleo solar, transmite calor para a superfície por radioatividade, apenas o suficiente para colocar a temperatura superficial numa média de 27°C. É, portanto, uma fonte de radiação eletromagnética muito menos intensa que o Sol e de qualidade espectral bastante limitada. Emite radiação eletromagnética somente na faixa espectral do termal. É por causa da sua baixa temperatura de superfície, que não é uma fonte de luz visível.

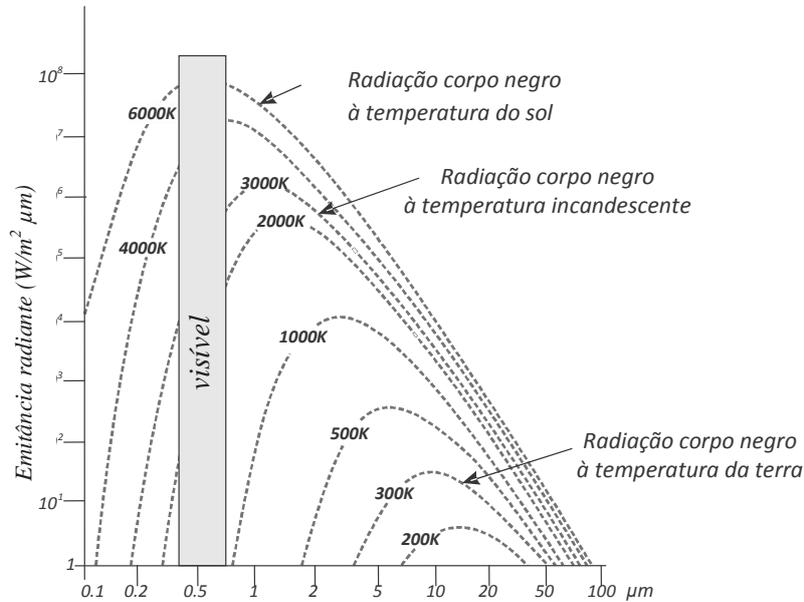


Fig. 1.7 As curvas mostram os valores das intensidades da energia radiante emitida por comprimento de onda, por fontes de radiação com diferentes temperaturas, segundo o modelo de corpo negro de Planck.

Semelhante ao que se vê na Figura 1.7 para as fontes de corpo negro, na Figura 1.8 é mostrado, comparativamente, a configuração do fluxo de energia radiante eletromagnética do Sol e da Terra. Nesta figura a intensidade da energia radiante da fonte solar decresce abruptamente abaixo dos comprimentos de ondas do ultravioleta e atinge valores mínimos além dos comprimentos de onda de 3,0 μm . Devido a isso, somente o intervalo espectral da REM de 0,45 μm a 2,5 μm é útil ao sensoriamento remoto, e nesse intervalo, o pico máximo de intensidade de radiação encontra-se na faixa de 0,45 μm a 0,76 μm , conhecida como a região do visível. A Terra tem uma intensidade de fluxo de energia bem abaixo do fluxo solar, tendo o seu máximo de emitância radiante em torno de 9,6 μm e um intervalo espectral útil ao sensoriamento remoto entre 8,0 μm a 14,0 μm .

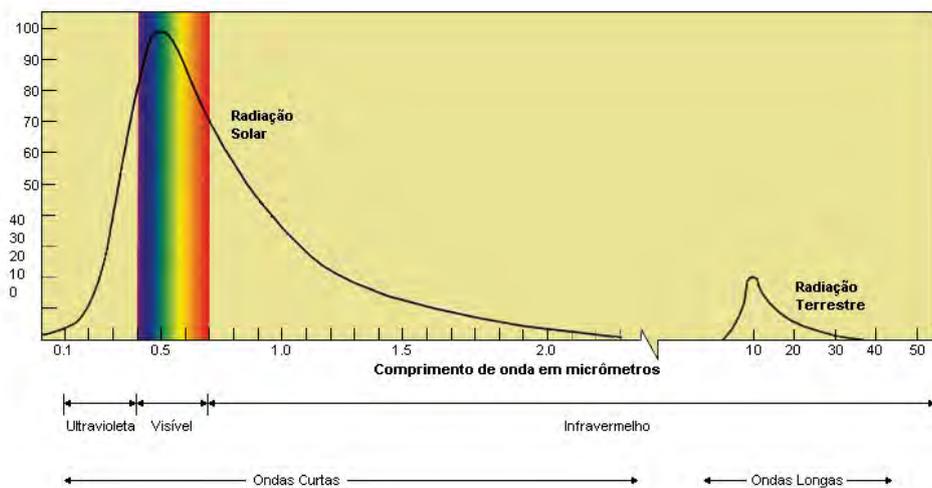


Fig. 1.8 Distribuição da intensidade da energia emitida pelas fontes naturais de radiação eletromagnética, medidas no topo da atmosfera. Barras indicam a região de comprimento de onda de máxima emitância.

total ou parcialmente a radiação eletromagnética solar. Essas absorções são o motivo dos sensores mostrarem descontinuidades nos comprimentos de onda entre bandas contíguas.

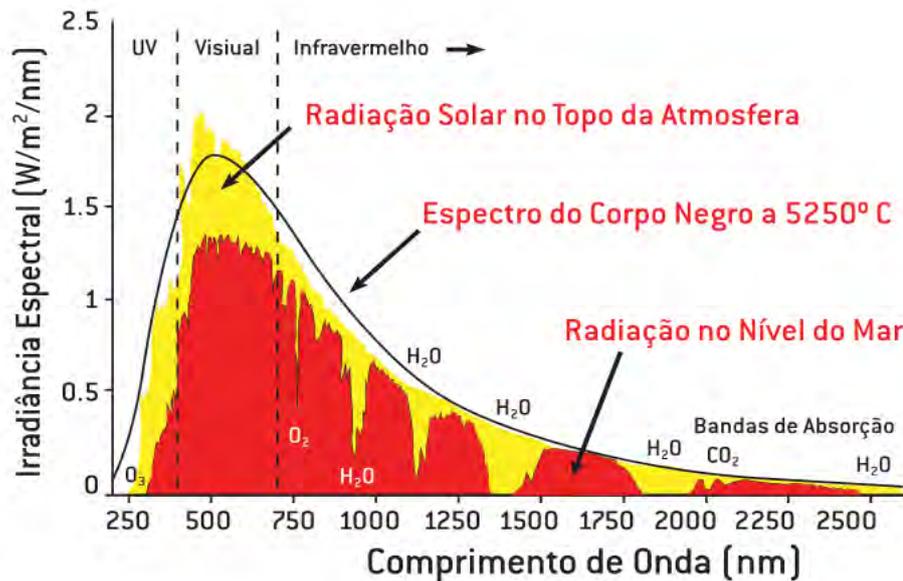


Fig. 1.10 Em vermelho a curva da irradiância solar no topo da atmosfera e em azul quando a irradiância atinge a superfície terrestre, mostrando as absorções pelos diferentes gases atmosféricos.

O espalhamento (difusão ou dispersão) corresponde à mudança aleatória da direção de propagação da radiação solar incidente devido a sua interação elástica com os componentes atmosféricos. A suposição comum é que a radiação espalhada não é atenuada, mas sim redirecionada. O espalhamento contribui para diminuir a eficiência do sensoriamento remoto na identificação dos objetos terrestres. Conforme mostra a Figura 1.11 os gases e particulados (aerossóis) da atmosfera podem espalhar a radiação incidente do Sol ou mesmo parte da radiação refletida pelas superfícies dos materiais. Nesse caso, o sensor receberá a energia refletida não somente do alvo (L_p), mas adicionada da radiação que a atmosfera espalhou (L_{am}), antes que ela atingisse a superfície do solo. Isso é conhecido como o efeito aditivo da atmosfera.

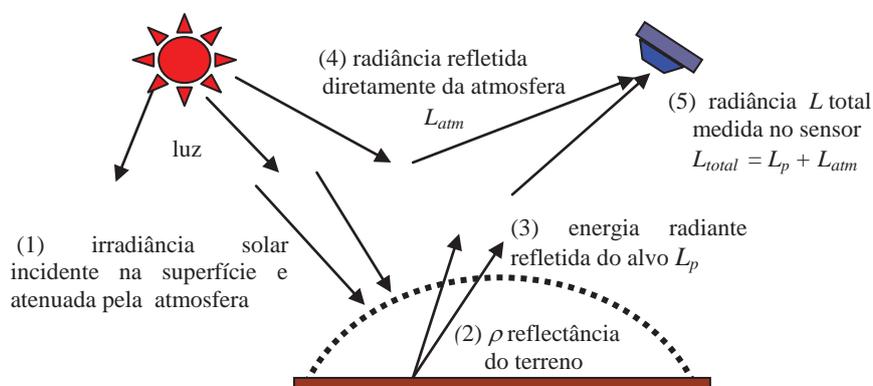


Fig. 1.11 O espalhamento atmosférico adiciona radiação na quantidade de energia refletida do alvo que chega ao sensor.

Teoricamente o espalhamento pode ser dividido em três diferentes categorias, dependendo das relações entre o comprimento de onda da radiação e o tamanho das partículas atmosféricas que causam o espalhamento. Estes três tipos são: espalhamento Rayleigh; espalhamento Mie; e espalhamento Não-Seletoivo.

O espalhamento Rayleigh é o mais comum. Ele ocorre quando o diâmetro das partículas é menor do que o comprimento da onda. Relaciona-se com as moléculas de gases presentes na atmosfera, e por isso o espalhamento Rayleigh é também denominado de espalhamento molecular. O cálculo do coeficiente de espalhamento Rayleigh depende do número de partículas por centímetro cúbico, do comprimento da radiação e dos índices refrativo das partículas e do meio, mas de forma mais simplificada, pode-se dizer que ele é proporcional ao inverso da quarta potência do comprimento de onda.

$$R = \frac{1}{\lambda^4}$$

eq.1.7

De acordo com a lei de Rayleigh, a influência mais prejudicial do espalhamento atmosférico ocorre nas imagens obtidas nos menores comprimentos de onda do visível. Desde que o coeficiente de espalhamento é proporcional ao inverso da quarta potência do comprimento de onda, os menores comprimentos de onda da luz azul são espalhados mais fortemente que a luz vermelha. A luz visível azul é espalhada cerca de seis vezes mais que a luz visível vermelha ($\lambda = 0,617 \mu\text{m}$), enquanto que o efeito do espalhamento nas imagens do infravermelho ($\lambda > 0,76 \mu\text{m}$) é bem menor, sendo quase imperceptível. O fato de a luz azul espalhar-se mais que os comprimentos de onda mais longos do visível, é por ela ser absorvida pelas moléculas e reemitida em todas as direções, modificando, portanto, a direção da radiação. O espalhamento Rayleigh é a causa de o céu aparecer azul. O vermelho do pôr do sol é também causado pelo espalhamento Rayleigh. Tão logo o sol se aproxima do horizonte, seus raios seguem uma trajetória maior através da atmosfera, espalhando os menores comprimentos de onda e deixando apenas as radiações de maiores comprimentos, laranja e vermelho, alcançarem nossos olhos. Por causa desse forte espalhamento dos comprimentos de onda azul, o uso de imagens multiespectrais na porção do espectro eletromagnético do visível requer correções atmosféricas. Por essa mesma razão, é que nas câmeras fotográficas aéreas, filtros especiais amarelos são usados para cortar a radiação azul.

O espalhamento Mie ocorre quando a onda eletromagnética é de tamanho comparável ao tamanho das partículas atmosféricas. Nesse caso, o coeficiente de espalhamento é um coeficiente de área definido como a razão da frente de onda afetada pela partícula e a seção de área transversal da própria partícula. Em analogia ao espalhamento de Rayleigh, o espalhamento de Mie tem a seguinte relação com o comprimento de onda:

$$M = \frac{1}{\lambda^{0,7-2,0}}$$

eq.1.8

Como no espalhamento Mie o tamanho das partículas atmosféricas é consideravelmente maior que o considerado no espalhamento Rayleigh, esse tipo de espalhamento ocorrerá apenas com os maiores comprimento de onda do visível. Em sensoriamento remoto o espalhamento Mie se manifesta também por uma perda de contraste entre os alvos da imagem, mas que acontece apenas sob atmosfera com partículas esféricas de vapor de água e poeiras, isto é, quando a atmosfera está mais densa. Nas imagens de sensoriamento remoto o principal efeito do espalhamento Rayleigh e Mie é o de aumentar a

reflectância real dos objetos, o que ocasiona uma diminuição do contraste entre os diferentes objetos presentes nas imagens. O exemplo dessa diminuição do contraste é mostrado na Figura 1.12. Nesta figura, a cena original possui dois objetos, um com brilho 5 para o alvo mais claro e outro com brilho 2 para o mais escuro, considerando-se uma situação com ausência total de espalhamento atmosférico. O contraste entre esses dois alvos pode ser medido como uma razão do brilho dos dois alvos: $5/2$ que é igual a 2,5. Quando esta mesma cena é colocada sob influência de uma atmosfera, onde são adicionadas cinco unidades de brilho devido ao espalhamento, o alvo com brilho 5 aumenta para brilho 10 e o alvo com brilho 2 aumenta para 7. A razão de contraste dos alvos que era de 2,5 diminui para 1,4, reduzindo assim, a possibilidade de se diferenciar os dois alvos nas imagens.

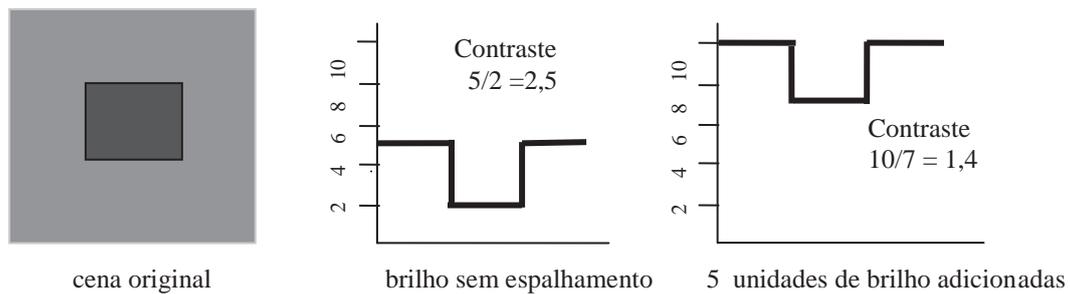


Fig. 1.12 Diminuição do contraste da reflectância entre dois alvos, medido por uma razão, devido ao espalhamento atmosférico.

O mecanismo final de espalhamento é o não-seletivo. Ele ocorre quando o tamanho das partículas é muito maior que o comprimento de onda da faixa espectral que vai do visível ao termal ($0,4 \mu\text{m}$ a $14 \mu\text{m}$). Daí, a razão de ser denominado de não-seletivo em relação ao tamanho da onda. Ele tem a soma da contribuição dos três processos envolvidos na interação da radiação com as partículas. O espalhamento não-seletivo ocorre em atmosferas muito densas, com neblinas e nuvens, e resulta em severas atenuações da radiação refletida pelos alvos ao sensor. É o responsável pela cor branca das nuvens, que espalham a radiação para cima com alta intensidade. A Tabela 1.1 resume as características dos três tipos de espalhamento.

Tabela 1.1 Tipos de espalhamento atmosférico

Tipo de espalhamento	Dependência com o comprimento de onda	Tamanho das partículas	Tipo de partículas	Efeitos na redução do contraste
Rayleigh	$\lambda^{-4.0}$	$\ll 1\lambda$	Moléculas de gás	Visível de pequeno comprimento de onda
Mie	$\lambda^{0.7}$ a $\lambda^{-2.0}$	0,1 a 10λ	Gotas de água, aerossóis	Visível de longo comprimento de onda
Não-seletivo	λ^0	$>10 \lambda$	Nuvens, neblinas, névoas	Afeta igualmente todos os comprimentos de ondas

1.6 Espectro Eletromagnético

Denomina-se espectro eletromagnético as regiões espectrais da REM conhecidas pelo homem. O espectro eletromagnético conhecido se estende dos comprimentos de onda dos raios cósmicos aos comprimentos de corrente alternada emitidos pelas redes de alta tensão. A faixa de comprimento de onda da REM é praticamente ilimitada. Há estrelas que emitem radiações eletromagnéticas com máximo de irradiância em comprimentos de onda do raio-X e outras, como o Sol, que emitem seu máximo de radiação eletromagnética no visível. O homem já construiu fontes artificiais de REM que geram ondas com comprimentos de 10^{-15} a 10^8 metros.

A REM deve ser vista como um espectro contínuo. Porém, o espectro eletromagnético foi arbitrariamente dividido pelo homem em intervalos de comprimentos de onda com base nos mecanismos físicos geradores da energia eletromagnética e nos mecanismos físicos de sua detecção. A nomenclatura de cada um dos intervalos foi feita em função do uso que o homem encontrou para as suas aplicações. Para os usuários do sensoriamento remoto é essencial saber os valores dos comprimentos de onda desses intervalos, as denominações que recebem, e quais comprimentos de ondas são possíveis de ser detectados por cada tipo de sensor. Isso porque, quando se estiver com uma imagem de sensoriamento remoto em mãos, a primeira pergunta que se faz é: *qual o comprimento de onda dessa imagem?* Usando uma terminologia mais correta, perguntar-se-ia: *qual é a banda espectral dessa imagem?*

Um dos intervalos ou faixas de comprimentos de onda que é mais familiar é a faixa de luz visível da radiação solar, por ser aquela que o olho humano é capaz de detectar. O intervalo espectral da luz visível foi decomposto pela primeira vez em 1766 por Isaac Newton, atravessando a luz branca por um prisma de vidro (dispersão) e emergindo do lado oposto do prisma em raios de luz coloridos (Figura 1.13). Cada raio colorido tem o seu específico comprimento de onda. A inclinação de cada raio, ao emergir da outra face do prisma, é devido à relação entre o comprimento da onda e o índice de refração do prisma (vidro). Essa experiência se repete toda vez que no céu vemos a formação de um arco-íris, provocado pela dispersão da luz pelas gotas de água, num dia chuvoso.

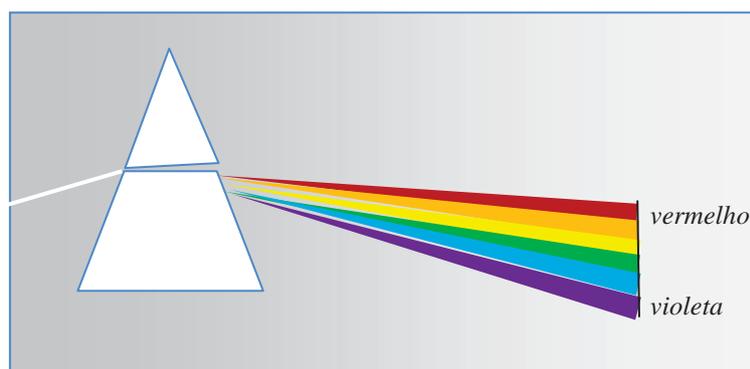


Fig. 1.13 Dispersão da luz branca em seis cores espectrais ao atravessar o prisma de vidro.

Foi a partir dessa experiência que o homem propôs a divisão do espectro eletromagnético. A Tabela 1.2 apresenta a divisão que é a mais aceita no sensoriamento remoto. Não são limites rigorosamente precisos, sendo comum encontrarmos na literatura

pequenas diferenças de limites dos intervalos espectrais. As faixa espectrais em negrito são as mais usadas em sensoriamento remoto. A Tabela 1.3 é um detalhamento dos limites de comprimentos de onda do espectro de cores do visível.

Tabela 1.2 Divisão do espectro eletromagnético.

Intervalo Espectral	Comprimento de Onda
Raios cósmicos	0,01 A°
Raios gama	0,01 – 0,1 A°
Raios X	0,1 – 10 A°
Ultravioleta	100nm – 0,38µm
Visível	0,38 – 0,76 µm
Infravermelho próximo	0,76 – 1,2 µm
Infravermelho de ondas curtas	1,2 – 3,0 µm
Infravermelho médio	3,0 – 5,0 µm
Infravermelho termal	5,0 µm – 1 mm
Micro-ondas	1 mm – 100 cm
Rádio	1 m – 10 km
Áudio	10 – 100 km
Corrente alternada	> 100 km

Obs: A° = 10⁻¹⁰ m; nm = 10⁻⁹ m; µm = 10⁻⁶ m

Tabela. 1.3 Divisões dos comprimentos de ondas das cores da região do visível

Comprimento de onda (µm)	Cor da luz refletida
0,380 – 0,455	Violeta
0,455 – 0,482	Azul
0,482 – 0,487	azul – esverdeado
0,487 – 0,493	azul – verde
0,493 – 0,498	verde – azulado
0,498 – 0,530	Verde
0,530 – 0,559	verde-amarelado
0,559 – 0,571	amarelo-verde
0,571 – 0,576	amarelo-esverdeado
0,576 – 0,580	Amarelo
0,580 – 0,587	laranja-amarelado
0,587 – 0,597	Laranja
0,597 – 0,617	laranja-avermelhado
0,617 – 0,760	Vermelho

Sabendo que a radiação eletromagnética de cada comprimento de onda interage de formas distintas e com intensidades diferentes com os objetos terrestres, um dos parâmetros mais importantes para definir as características de um sensor são os comprimentos de onda das imagens que o sensor irá adquirir. As imagens não são definidas num específico comprimento de onda, mas abrangendo pequenos intervalos, chamados de bandas espectrais.

Em função das absorções da radiação eletromagnética pela atmosfera, os intervalos discriminados na Tabela 1.4 são aqueles em que, realmente, se podem obter imagens a partir de sensores instalados em aeronaves ou satélites.

Tabela 1.4 - Intervalos espectrais possíveis de serem usados pelos sensores remotos.

0,45 – 0,76 μm <i>visível</i>	0,76 – 1,2 μm <i>infravermelho próximo</i>	1,2 – 3,0 μm <i>infravermelho de ondas curtas</i>	3,0 – 5,0 μm <i>infravermelho médio</i>	5,0 μm – 1 mm <i>infravermelho termal</i>	1mm– 100 cm <i>micro-ondas</i>
toda faixa	0,76 – 0,91 1,00 – 1,12	1,19 – 1,34 1,55 – 1,75 2,05 – 2,40	3,5 – 4,2 4,5 – 5,0	8,0 – 9,2 10,2 – 12,5	3,0 – 100

Segue uma síntese das características mais importantes desses intervalos espectrais.

Visível (0,45-0,76 μm) - É a região do espectro solar com a mais alta intensidade de fluxo radiante e onde há a melhor janela atmosférica, bastante transparente, deixando passar uma grande quantidade de radiação. Por isso, é muito usada em sensoriamento remoto. É a região responsável pela interação com os minerais e que dá origem às suas cores e com os pigmentos da vegetação. O problema dessa faixa espectral é o alto espalhamento da radiação solar incidente pelos gases atmosféricos, que pode reduzir o contraste da reflectância dos alvos terrestres. É chamada de visível, porque o olho humano é sensível a essa região espectral.

Infravermelho próximo (0,76 - 1,2 μm) - Região do espectro solar onde a atmosfera também é bastante transparente, mas ocorrem algumas bandas de absorções, impedindo que todo o intervalo possa ser continuamente utilizado por sensoriamento remoto. É o intervalo onde ocorrem importantes interações da REM com os níveis de energia eletrônica dos átomos, gerando feições espectrais que são diagnósticas para identificar a natureza de vários tipos de rochas, principalmente as de composição mineral com metais de transição (Fe, Ni, Cr, Mn...)

Infravermelho de ondas curtas (1,2 – 3,0 μm) - É a região espectral geológica, porque é nesta faixa espectral que os vários minerais de alteração hidrotermal têm as suas diagnósticas feições de absorção. Também é a região onde os comprimentos de onda em 1,4 μm e em 1,9 μm são totalmente absorvidos pelas moléculas de vapor d'água da atmosfera, proibindo o uso do sensoriamento remoto e, por consequência, de se determinar nos materiais terrestres a presença de água molecular nas suas estruturas.

Infravermelho médio (3,0 - 5,0 μm) - Região onde o Sol e a Terra não emitem quantidades suficientes de energia que possam ser detectadas pelos sensores. Somente alvos com elevadas temperaturas, como vulcões e incêndios, podem ser detectados, pois agem como fontes próprias de emissão de radiação. É uma região espectral pouco usada no sensoriamento remoto, à exceção de sensores meteorológicos ou atmosféricos.

Infravermelho termal (5,0 – 1,0 mm) - É conhecido como a região termal, devido à radiação emitida pelos objetos terrestres em função das suas temperaturas de superfícies. A melhor janela atmosférica nessa região espectral para imageamento orbital é o intervalo de 8,0 μm a 14,0 μm , porque acima de 30 km, a camada de ozônio absorve toda a radiação além de 14 μm emitida pela Terra. Ótima faixa espectral para detecção de quartzo de veios nas rochas.

Micro-ondas (3,0 - 100 cm) – Região de uso de sensores ativos (radar), que utilizam fontes artificiais para a geração da REM. Por causa do tamanho do comprimento de onda, o radar

tem a habilidade de operar em condições atmosféricas adversas, com coberturas de nuvens ou chuvas, e pode operar tanto de dia como à noite. Importante para a geologia estrutural e mapeamento geológico, porque a interação das micro-ondas com as rochas é controlada pelas texturas de relevo. Atualmente, o intervalo útil ao sensoriamento remoto estende-se de 3,0 cm a 100 cm.

1.7 Conceitos de Radiância e Reflectância

A forma como um sensor mede a radiação eletromagnética é praticamente a mesma, independente do comprimento de onda. Mas, o importante é saber o que é de fato o componente da radiação eletromagnética que deixa o alvo e vai até o sensor para ser medido e transformado em imagem. Normalmente, nos referimos erroneamente a esse componente, como reflectância. Veremos que há uma conceituação radiométrica específica que define a radiação que deixa o alvo, e que é dependente do intervalo espectral. Trataremos aqui dos conceitos radiométricos da radiação óptica da luz solar. A radiação termal e das micro-ondas veremos nos capítulos seguintes.

Quando o sensor detecta e mede a radiação que deixa a superfície dos objetos, o sensor está fazendo uma medição radiométrica. É por isso que os sensores imageadores podem também ser denominados de radiômetros imageadores. A radiometria inclui uma série de termos e leis que em sensoriamento remoto são fundamentais para explicar o significado físico dos valores da REM medidos pelo sensor. As definições que serão vistas são somente as mais importantes para se entender o significado dos componentes de um modelo básico de sensoriamento remoto, como ilustrado na Figura 1.14. Os números que identificam na figura cada um dos componentes desse modelo representam os termos radiométricos que são definidos a seguir, em uma ordem sequencial segundo a trajetória da REM da fonte (1) até o sensor. O subscrito λ indica que o valor calculado para a grandeza radiométrica que o contém é dependente do comprimento de onda.

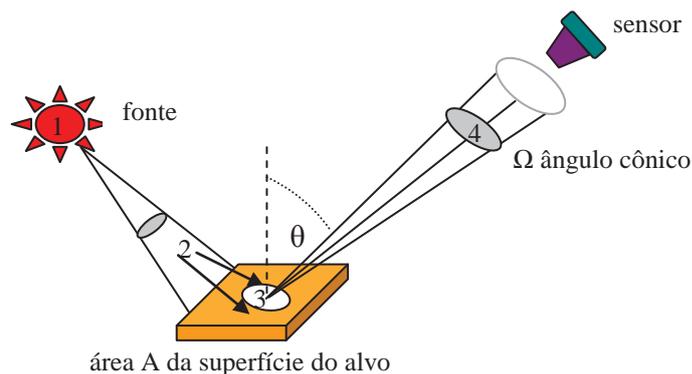


Fig. 1.14 Componentes radiométricos da trajetória da radiação eletromagnética, da fonte ao sensor.

1. *Energia radiante* Q é a energia que se propaga da fonte na forma de ondas eletromagnéticas, medida em Joule (J).

2. *Fluxo radiante* $\Phi = \partial Q / \partial t$ é a taxa na qual a energia radiante é transferida de um ponto ou superfície para outra superfície, medida em watts (W). O fluxo é medido por um

período de tempo. Também é a taxa de tempo que o fluxo ilumina a superfície do terreno, que será imageada pelo sensor.

3. *Irradiância* $E_\lambda = \Phi/\Delta A$ é o fluxo radiante solar incidente na superfície do terreno por área de superfície, medido em watts por metro quadrado (W/m^2). Mas, se efetivamente se quiser medir a quantidade de irradiância incidente por área, deve-se integrar as variáveis da atmosfera pela qual a radiação passa. Segundo Jensen (2009), essa integração é uma função da irradiância solar espectral no topo da atmosfera ($E_{o\lambda}$), multiplicada pela transmitância atmosférica ($T_{\theta 0}$) num certo ângulo zenital solar (θ_0), mais a contribuição solar difusa ($E_{d\lambda}$). Em termos de unidade a irradiância é medida em $W/m^2\mu m$.

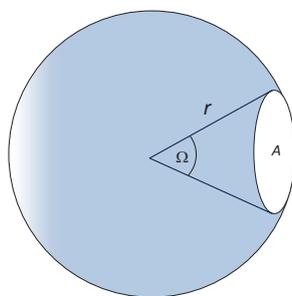
$$E_{g\lambda} = \int_{\lambda_1}^{\lambda_2} (E_{o\lambda} T_{\theta 0} \cos \theta_0 + E_{d\lambda}) d\lambda \quad eq.1.9$$

4. *Radiância* $L_\lambda = \Phi/\Delta\Omega \Delta A \cos\theta$ é a medida feita pelo sensor da densidade de fluxo radiante que deixa um elemento de área da superfície do terreno, e que se propaga em uma direção definida por um cone elementar de um ângulo sólido contendo aquela direção. Em termos de unidade a radiância é medida em $W/m^2\text{str}\mu m$. Assumindo-se que a superfície da Terra seja um refletor difuso perfeito, a quantidade total de radiância que deixa a superfície de um alvo em direção ao sensor, é de acordo com Jansen (2009):

$$L_T = \frac{1}{\pi} \int_{\lambda_1}^{\lambda_2} \rho_\lambda T_{\theta v} (E_{o\lambda} \cos \theta_0 + E_{d\lambda}) d\lambda \quad eq.1.10$$

onde, ρ = reflectância média da superfície do alvo e o fator π considera o espaço hemisférico.

O conceito de ângulo sólido é importante em sensoriamento remoto. Ele descreve a convergência ou divergência angular, em três dimensões, do fluxo de ou para uma superfície. Ele é convenientemente definido em termos da geometria de uma esfera, como mostra a Figura 1.15. O ângulo sólido subtendido no centro de uma esfera é definido como a razão da superfície de área da esfera pelo quadrado do raio da esfera. Como em sensoriamento remoto o ângulo sólido é de valor muito pequeno, de alguns poucos miliradianos, por conveniência, usa-se a área plana da base do cone, de diâmetro D.



$$\Omega = A/r^2$$

onde: Ω = ângulo sólido em esferoradiano
 A = área da esfera subtendida pelo cone Ω
 r = raio da esfera

Fig. 1.15 Conceito de ângulo sólido.

Voltando à Figura 1.14 vemos que o sensor focaliza uma área no terreno cujo tamanho é definido pelo ângulo sólido de visada do sensor. Esse ângulo sólido de visada é definido pela abertura do sistema óptico do sensor, no caso um telescópio portátil, à semelhança da abertura definida pela objetiva de uma máquina fotográfica. Dessa maneira, o sensor mede a intensidade radiante que deixa a superfície de área do terreno limitada por um ângulo sólido Ω . Esterradiano (str), ou esferorradiano, é a unidade de medida de ângulo sólido, 1 esterradiano equivalendo a 57 graus plano. No sensor o ângulo é da ordem de miliradianos. Além do ângulo sólido, a medida da radiação que deixa a área do terreno depende também da posição que o sensor está no espaço. Na Figura 1.14 a posição do sensor é medida pelo co-seno do ângulo em relação à normal superfície do terreno. Tudo isso, que é considerado na medida da radiação pelo sensor, é o que foi definido de *radiância*. Sendo assim, a imagem formada no sensor é uma imagem da radiância. Como será abordado adiante, os valores de radiância são convertidos em valores digitais, gerando a imagem digital.

Mas, há algo mais, muito importante, que deve ser considerado no modelo básico de configuração de sensoriamento remoto da Figura 1.14. Sabe-se que a densidade de fluxo incidente na superfície do terreno, a *Irradiância* E , varia no tempo (hora, dia, mês), pois a distância e a posição do Sol em relação à Terra mudam, continuamente, e mesmo porque o Sol não é uma fonte totalmente uniforme. Além disso, a atmosfera é muito dinâmica, ou seja, a cada momento deixa passar quantidades diferentes de fluxo radiante devido às absorções dos gases. O que isso acarreta? A radiância que será medida no sensor para construir a imagem dos objetos poderá apresentar-se diferente de um dia para outro, mesmo que os alvos nada tenham mudado. Essa influência da variação da irradiância poderia ser eliminada, se no exato momento em que o sensor medisse a radiância L_λ que deixa o alvo, medisse, também, a quantidade de fluxo radiante incidente no alvo, ou seja, a irradiância E_λ . A relação de medida da irradiância com a radiância estabelece um conceito muito importante em sensoriamento remoto, que é a reflectância.

Reflectância é a razão entre a quantidade de energia radiante que deixa uma unidade de área no terreno (*Radiância*) pela quantidade de energia incidente naquela área (*Irradiância*), medida no mesmo instante de tempo. Como irradiância e radiância são densidades de fluxo, o valor dessa razão torna-se adimensional, sendo, portanto, expresso em porcentagem. Qualquer alvo no terreno poderá refletir uma porcentagem $> 0\%$ e $< 100\%$ da radiação nele incidente. Usa-se a letra grega ρ para se referenciar à reflectância.

$$\rho_\lambda(\%) = \frac{L_\lambda}{E_\lambda}$$

eq.1.11

Os sensores imageadores não medem a irradiância solar, e por isso a imagem é uma representação digital dos valores da radiância, e não uma imagem de reflectância. Para chegar a uma imagem de reflectância, devem-se converter os valores digitais para radiância e em seguida calcular a reflectância, segundo os princípios da equação 1.10. Para isso há a necessidade de se saber os valores da irradiância no momento em que a imagem foi tomada. Há complexas formulações matemáticas que possibilitam fazer essa conversão de valores. Elas estão embutidas nos algoritmos de processamento de imagens para correção atmosférica.

Para a maioria das aplicações de sensoriamento remoto e das técnicas de processamento de imagens se usa imagens no formato digital, aceitando-se que os valores digitais são representações bem próximas da reflectância. Razoáveis análises da reflectância espectral dos alvos podem ser feitas com imagens multiespectrais no formato digital.

Contudo, com imagens de sensores hiperespectrais, que exigem em suas análises

algoritmos de classificação espectral, a imagem digital precisará, obrigatoriamente, ser convertida para imagem de reflectância. Sobre isso veremos no capítulo 14.

1.8 Resoluções das Imagens

Atualmente, o sensoriamento é constituído por uma razoável constelação de satélites que oferecem imagens para atender as necessidades de uma ampla demanda de usuários. Para aqueles usuários que necessitam de uma observação detalhada do tamanho e das formas dos objetos, há os sensores que detectam áreas unitárias inferiores a 1 metro, e com meios para visualização estereoscópica 3D, muito úteis para levantamentos cadastrais multifinalitários, urbanos e cartografia digital. Os interessados em monitoração para o acompanhamento da evolução e de mudanças da paisagem podem recorrer aos sensores com alta taxa de revisita à área. Já os que se interessam em determinar a composição ou constituição dos minerais ou rochas, a procura é pelos sensores com um grande número de bandas espectrais. Por isso, uma forma de se abordar as potencialidades de um sensor é pelo dimensionamento de suas resoluções.

Nas aplicações de sensoriamento remoto em estudos geotemáticos duas questões estão sempre presentes:

- i) qual é a melhor resolução da imagem para se identificar ou resolver os objetos de interesse e;*
- ii) qual é a melhor escala para representar os objetos ou fenômenos geográficos.*

Nem sempre há respostas simples para essas indagações. O que mais prontamente pode-se responder é que, devido à limitação que o sensor orbital tem para transmitir grandes volumes de dados para as estações terrestres de rastreamento de satélites, as imagens que recobrem grandes áreas, de dezenas de milhares de quilômetros quadrados, como as do satélite Landsat e CBERS, são associadas com resoluções espaciais pequenas (30, 20 metros), e as imagens que recobrem pequenas áreas, como as imagens Ikonos e Orbview, são associadas com resoluções espaciais grandes (1 metro). Consequentemente, as imagens de pequena resolução espacial, por não mostrarem os detalhes dos alvos, servirão para estudos em escalas mais regionais, enquanto as imagens com grande resolução espacial se prestarão para estudos locais de detalhe.

Na prática, a detecção ou identificação de um objeto nas imagens de sensoriamento remoto não é determinada somente pela resolução espacial, mas por quatro diferentes formas de medições:

- 1) pela área do campo de visada do sensor;
- 2) pelo comprimento de onda das bandas;
- 3) pelos valores numéricos da medida da radiância do alvo;
- 4) e pela data em que a imagem foi tomada.

São essas quatro formas de medidas que são descritas em termos de resoluções, respectivamente denominadas de resolução espacial, espectral, radiométrica e temporal. Elas atuam em conjunto, num processo interativo, nem sempre facilmente percebido pelo analista, o que é, também, o motivo de frequentes dúvidas ao se tentar explicar por que pequenos objetos são surpreendentemente identificados nas imagens.

Os conceitos e explicações tratadas a seguir, sobre resoluções, são válidas para todos os tipos de sensores imageadores, independente da faixa espectral em que operam, à exceção do radar.

1.8.1 Resolução Espacial

O tamanho individual do elemento de área imageada no terreno representa em qualquer tipo de sensor uma propriedade importante da imagem: a resolução espacial. A resolução espacial é um importante parâmetro do sensor porque ela determina o tamanho do menor objeto que pode ser identificado em uma imagem. Por definição, um objeto somente pode ser resolvido (detectado), quando o tamanho deste é, no mínimo, igual ou maior do que o tamanho do elemento de resolução no terreno, ou seja, da resolução espacial. Por exemplo, se uma casa tem 20 m x 20 m de tamanho, a resolução espacial da imagem deveria ser, no mínimo, de 20 metros para que essa casa possa ser identificada na imagem. Entretanto, a experiência mostra que, de fato, para um objeto ser resolvido na imagem, a resolução espacial nominal deveria ser, pelo menos, a metade do tamanho do objeto medido na sua menor dimensão. Mesmo assim, o objeto ainda tem que apresentar um bom contraste de reflectância com os alvos que lhe são vizinhos, vistos na dimensão do pixel. A Figura 1.16 exemplifica estas relações.

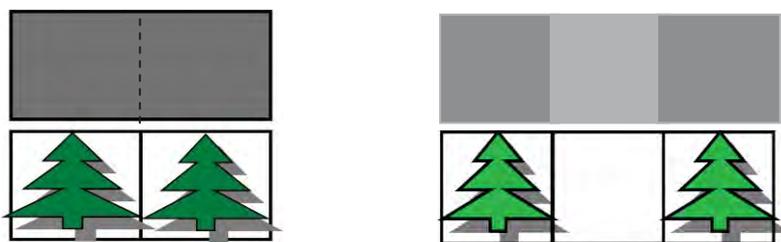


Fig. 1.16 Resolver os objetos pelo valor da resolução espacial depende também do contraste de reflectância dos pixels vizinhos. Em (a) as duas árvores não são resolvidas, fundindo-se em um único objeto. Em (b) elas são resolvidas por estarem separadas pela área de um pixel com reflectância diferente.

Determinar qual deve ser a resolução espacial de um sensor, envolve para a maioria das aplicações de sensoriamento remoto, uma análise da relação do grau de autocorrelação da organização espacial dos objetos no terreno. Em terrenos naturais os alvos apresentam uma alta correlação espacial, mostrando pouca variabilidade ao longo de uma área, não exigindo, para a sua identificação, altas resoluções espaciais. Já, para uma área com alta variabilidade de tipos de objetos, como numa área urbana, a exigência seria para um sensor com resolução espacial de poucos metros, para que as casas, ruas, estacionamentos, possam ser resolvidos.

Para se calcular a resolução espacial pode-se usar a projeção geométrica no terreno subtendido pelo campo de visada instantâneo (IFOV) do sensor, que é medido pelo ângulo β . A compreensão desse conceito é mostrada na Figura 1.17, simplificada para um único elemento de resolução espacial no terreno. O tamanho do ângulo β do IFOV é determinado pela abertura do sistema óptico em conjunção com o tamanho do detector, pois é o detector que mede a intensidade da radiância do terreno. Como nos sensores orbitais a óptica é a de um telescópio portátil com distância focal de 2 a 3 metros, o valor do ângulo β do IFOV é de centésimos de miliradianos.

O tamanho do elemento de resolução no terreno pode ser calculado pela equação:

$$D = H\beta$$

eq.1.12

onde, H = altura do sensor em metros
 β = ângulo IFOV em miliradianos

Usando a equação 1.12, para um sensor orbital colocado à altura de 700 km e com um IFOV igual a 0,043 miliradianos, o tamanho do elemento de resolução no terreno será:

$$D = 700.000 \times 0,043 \cdot 10^{-3}$$

$$D = 30,1 \text{ metros}$$

Um pequeno IFOV é desejável quando há a necessidade de se registrar altos detalhes espaciais. Dessa forma, quanto menor o tamanho do IFOV maior será a capacidade de se detectar nas imagens os menores elementos que integram a cena. A resolução espacial deve ser entendida como uma medida geométrica, e, portanto, não deve ser considerada como sinônimo de pixel. Pixel representa uma taxa de amostragem no terreno, que mede no espaço geométrico do elemento de resolução no terreno, o valor da radiância do alvo.

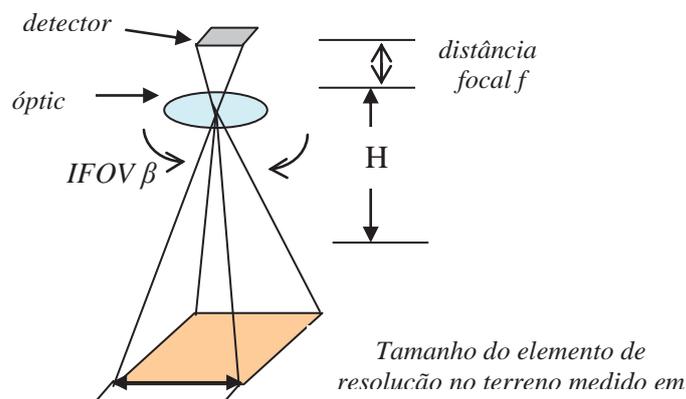


Fig. 1.17 Medida geométrica da resolução espacial a partir do valor do ângulo IFOV e da altura H do sensor.

A Figura 1.18 mostra imagens de três sensores ópticos com diferentes resoluções espaciais. Fica evidente que se pode estabelecer uma relação de comparação entre a resolução espacial e a escala de visualização da imagem. Na Tabela 1.5 são sugeridas as escalas para as correspondentes resoluções espaciais de alguns conhecidos sensores. São escalas aproximadas, porque na prática, dependendo do contraste da cena e das bandas, quase sempre se consegue uma escala maior do que a sugerida pela resolução espacial.



Fig. 1.18 Da esquerda para a direita, imagens dos satélites, Landsat com resolução espacial de 30m, Spot com 10 m e Ikonos com 1 m, de uma porção do lago Paranoá de Brasília.

Tabela 1.5 Escalas aproximadas de visualização de imagens multiespectrais em função da resolução espacial.

Escala	Resolução espacial (m)	Sensor
1: <10.000	1	Ikonos pancromático
1: 10.000	2,5	Spot pancromático
1: 20.000	5	Ikonos XS
1: 40.000	10	Spot HRG
1: 75.000	20	CBERS
1: 100.000	30	Landsat (faixa óptica)
1: 200.000	60	Landsat TIR (termal)
1: 350.000	90	Aster TIR (termal)

Obs. Escalas determinadas experimentalmente com imagens em composições coloridas realçadas.

1.8.2 Resolução Espectral

Para o sensoriamento remoto, a obtenção simultânea de imagens em múltiplas bandas espectrais é, sem dúvida, a propriedade mais importante dos sensores imageadores. O termo resolução espectral envolve pelo menos três parâmetros de medida:

- i) o número de bandas que o sensor possui;
- ii) a largura em comprimento de onda das bandas;
- iii) as posições que as bandas estão situadas no espectro eletromagnético.

Comparativamente, um sensor tem melhor resolução espectral se ele possui maior número de bandas situadas em diferentes regiões espectrais e com larguras estreitas de comprimentos de onda. Essa necessidade é devido às diferenças relativas de reflectância entre os materiais da superfície da terra, que permitem distinguir um material do outro, em determinados comprimentos de onda. Por exemplo, as gemas são mais facilmente diferenciadas nos comprimentos de onda do visível, devido às diferenças de cores que na maioria é controlada por pequenas impurezas nas suas estruturas cristalinas. Por outro lado, as rochas evidenciam suas diferenças espectrais mais nos comprimentos de onda do infravermelho próximo e de ondas curtas. Quanto à largura da banda, ela deve ser dimensionada em concordância com as larguras das feições de absorção exibidas pelos espectros de reflectância de cada material. As feições de absorções são identificadores de composições dos tipos de rochas, solos, vegetação e água, e normalmente, são da ordem de 10 nm a 20 nm. Sensores com bandas muito largas, além de 20 nm tendem a não ser capazes de diferenciar um objeto do outro em função de sua composição. Assim, o objeto é apenas detectado em razão da resolução espacial. A Figura 1.19 ilustra esses critérios de resolução espectral, tendo como exemplo as nove bandas do sensor ASTER, cuja resolução espectral foi definida para discriminar minerais de alteração hidrotermal.

Um simples exemplo que serve para ilustrar o efeito da resolução espectral na detecção ou identificação de um objeto é mostrado na Figura 1.20 de uma área da floresta amazônica. Ambas as imagens estão na mesma resolução espacial de 30 metros. Na imagem (a) da Figura 1.18, de uma banda do visível de 0,63 μm a 0,69 μm , mesmo os grandes rios com dezenas de metros de largura não são facilmente identificados, porque a baixa reflectância da água e da vegetação são, praticamente, iguais nesse comprimento de onda, não havendo contraste entre os dois tipos de alvos. Para a região amazônica seria um erro seleccionar esta banda espectral para se elaborar mapas de drenagem. A imagem (b) da Figura

1.20 é de uma banda do infravermelho próximo. Nessa banda os rios são facilmente identificados, porque a água possui uma baixa reflectância, enquanto a vegetação da floresta tem uma alta reflectância, estabelecendo uma razão de alto contraste entre os dois alvos.

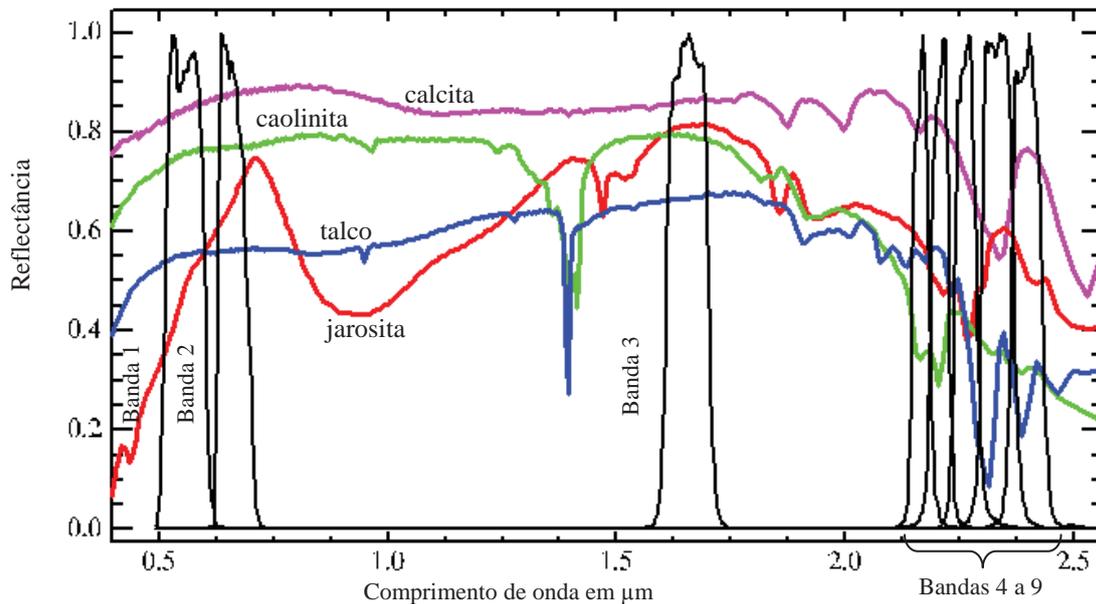


Fig. 1.19 Espectros de reflectância de alguns minerais sobrepostos às bandas do sensor ASTER. A largura da banda do sensor deve ser equivalente à largura da banda de absorção do mineral para que este possa ser identificado na imagem.

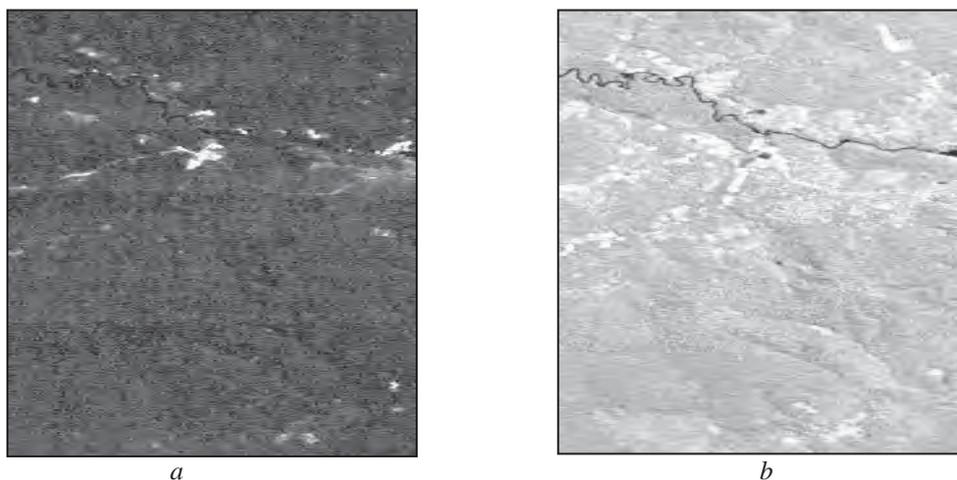


Fig. 1.20 Imagens da região amazônica nas bandas do visível (a) e do infravermelho próximo (b) exemplificando o efeito da resolução espectral no contraste do rio com a vegetação.

Valendo-se do poder da resolução espectral é que os sensores multiespectrais aparentam ter a sua resolução espacial melhorada. É bem conhecido que é possível detectar

objetos que são consideravelmente menores do que a resolução espacial, se seu contraste com os objetos vizinhos é suficientemente alto. O exemplo mais marcante é a identificação de estradas em imagens de satélites. Na Figura 1.21 o exemplo é novamente de uma imagem com resolução de 30 metros, onde há estradas de terra, cujas larguras são inferiores a 10 m. Devido ao tamanho dos pixels ser de 30 por 30 metros, eles integram as áreas da estrada e da vegetação marginal, constituindo um pixel mistura que define um valor qualquer de reflectância. Tal valor não será nem o valor puro da reflectância da estrada e nem o da vegetação. Mas como na banda do visível a estrada tem uma alta reflectância, muito superior à reflectância da vegetação, o valor médio da reflectância do pixel mistura se aproximará mais do valor da reflectância da estrada do que da vegetação. Nesse caso, os pixels misturas que contém a estrada e a vegetação terão um nível de cinza mais claro que os pixels puros, apenas com vegetação. Tal efeito de contraste apresenta-se como uma aparente melhoria na resolução espacial da imagem. Para confirmar esse efeito da resolução espectral, na resolução espacial, observe que quando a banda espectral selecionada for de comprimento de onda do infravermelho próximo (figura da esquerda), a estrada é dificilmente identificada, porque neste caso, as reflectâncias da estrada e da vegetação são muito próximas, portanto, sem um contraste espectral.

Infelizmente, não é possível aumentar, indefinidamente, qualquer um dos três parâmetros que medem a resolução espectral do sensor: largura das bandas, posição das bandas ao longo do espectro eletromagnético e número de bandas. Um sensor com centenas de bandas espectrais, com o fim de se ter uma amostragem detalhada do comportamento espectral da reflectância dos objetos aumenta, significativamente, a taxa de transmissão de dados do satélite para a Terra, exigindo-se em se colocar no satélite equipamentos mais potentes para transmissão (*transponder*), o que implica em maior consumo de energia elétrica. Larguras de bandas muito estreitas diminuem a quantidade de energia radiante do pixel, o que ocasiona baixa razão sinal/ruído.

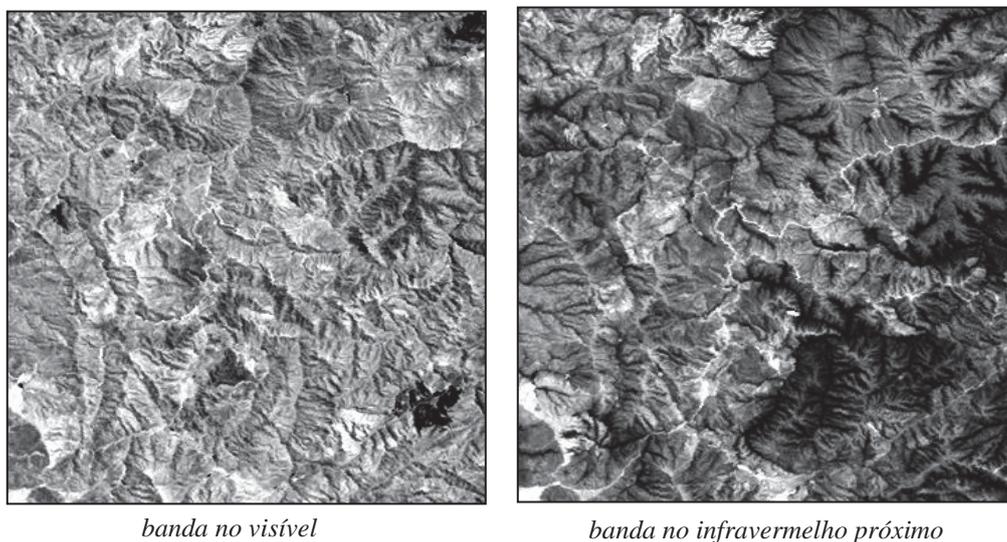


Fig. 1.21 Efeito da resolução espectral na identificação de alvos (estradas de terra) em áreas de relativa densa vegetação, cujas dimensões são inferiores à resolução espacial de 30 m da imagem.

De certa forma, é por essas restrições que se vê atualmente, nos exemplos dos sensores orbitais em operação, certo comprometimento entre a resolução espectral e a resolução espacial. Normalmente, os sensores de alta resolução espacial para compensarem o grande volume de dados que tem de ser transmitido para a Terra, possuem poucas bandas,

limitadas às faixas espectrais do visível e do infravermelho próximo. São assim considerados sensores de alta resolução espacial e baixa resolução espectral. Ao contrário, um sensor de baixa resolução espacial, como o ASTER, é compensado pelo maior número de bandas (14 bandas).

1.8.3 Resolução Radiométrica

A medida pelos detectores da intensidade de radiação da área de cada pixel unitário é denominada de resolução radiométrica. Maior será a resolução radiométrica, quanto maior for a capacidade do detector para medir as diferenças de intensidades dos níveis de radiação. Quanto maior for essa capacidade, maior será a resolução radiométrica. Ela define o número de níveis de radiação que o detector pode discriminar.

Em função da intensidade da radiação de entrada no sensor, a resposta de saída dos detectores é convertida eletronicamente em um número digital discreto. Também se dá o nome de quantização à medida da resolução radiométrica. Em termos práticos, a quantização do sinal é medida pelo intervalo de número de valores digitais usados para expressar os valores de radiação medidos pelo detector. A quantização é normalmente expressa em termos de números de dígitos binários (*bits*). Quanto maior é a quantização, maior será a qualidade visual da imagem, como mostra a Figura 1.22. Nesta figura, observa-se que a imagem de 8 bits ($2^8=256$) tem detalhes visuais melhores que as imagens de menores resoluções radiométricas de 6, 4 e 2 bits. A imagem de 2 bits possui apenas 4 níveis de cinza.

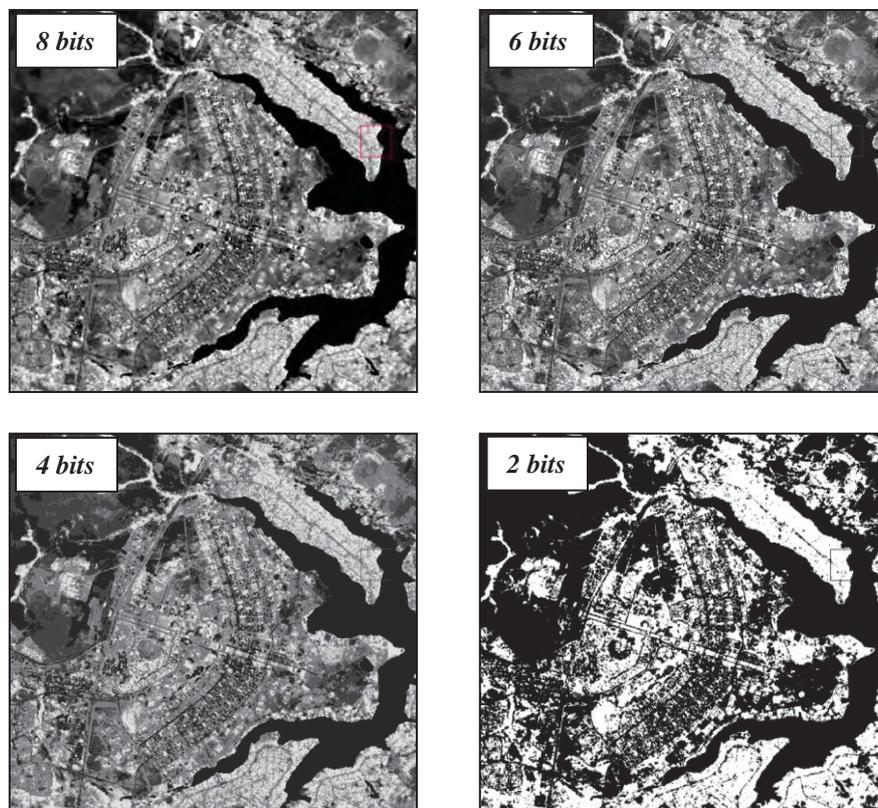


Fig. 1.22 Exemplos de imagens com diferentes níveis de quantização ou de resolução radiométrica.

A maioria dos sensores multiespectrais com resolução espacial de 10 a 30 metros trabalha com resoluções radiométricas de 8 bits, isso é, possui capacidade de discriminar até 256 valores de radiância por banda espectral. Já os sensores com alta resolução espacial, com tamanho de pixel de 1 metro, possuem resoluções radiométricas de 10 ou 11 bits (1024 ou 2048 valores digitais). Para ilustrar essa questão, imaginemos uma área de floresta com árvores que exibem pequenas variações na intensidade da cor verde de suas folhas, que é o componente da vegetação que irá interagir com a luz solar incidente. Com uma imagem com pixel de 30 metros várias árvores estarão dentro da área do pixel. Nesse caso, a radiância medida pelo sensor será uma média da reflectância de várias árvores, e não de árvores individuais. A floresta será, portanto, identificada nas imagens por uma textura tonal que será bem distinta de uma área vizinha com menor densidade de vegetação, como um cerrado *sensu strictu*. Isso nos diz que as imagens somente possibilitam diferenciar classes de alvo (mata e cerrado). Sendo assim, para reconhecer classes de alvos, não há necessidade de uma refinada medida da radiância, bastando uma imagem com resolução de 8 bits. Já, para uma imagem com 1 m de resolução espacial, as árvores podem ser individualmente detectadas. Havendo sutis variações de reflectância entre as árvores, a imagem deverá ter uma resolução radiométrica de 10 ou 11 bits, para que se possa diferenciar possíveis variações espectrais entre as espécies de árvores. A Figura 1.23 exemplifica essa discussão, apresentando a comparação de uma composição colorida de imagens Ikonos com resoluções radiométricas de 11 bits e espacial de 1 metro, com uma composição de imagens ETM+ com resoluções radiométricas de 8 bits e espacial de 30 metros.

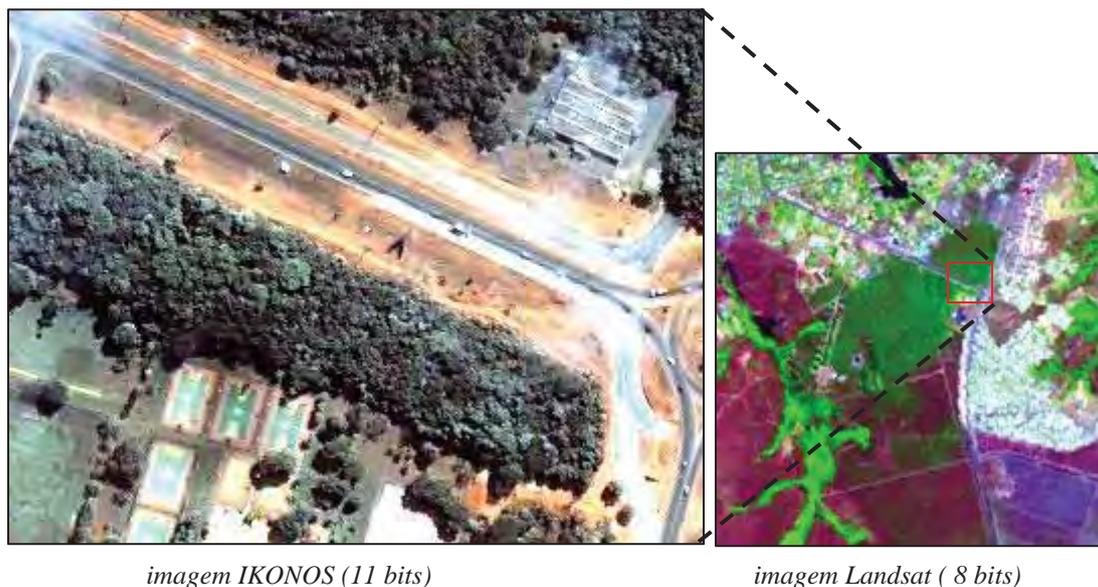


Fig. 1.23 A identificação dos objetos como elementos individuais da paisagem (árvores) ou como classe (mata) respectivamente, nas imagens IKONOS e Landsat, é determinada pela relação entre os valores das resoluções espacial e radiométrica.

1.8.4 Resolução Temporal

Refere-se à frequência que o sensor revisita uma área e obtém imagens periódicas ao longo de sua vida útil. Isso só é possível porque os satélites de sensoriamento remoto

executam uma órbita heliosíncrona, que é um caso particular de uma órbita semipolar. O plano de órbita é sempre fixo e ortogonal ao sentido de rotação da Terra. Assim, o satélite passa sobre o mesmo ponto da superfície da Terra na mesma hora. Orbitam com uma inclinação em relação ao equador de 97° a 98° a uma altitude nominal próxima de 550 a 900 km e o tempo de viagem para completar uma órbita é de aproximadamente 90 minutos. Num tempo de 24 horas, aproximadamente 14 órbitas se completam. Considerando-se que os sensores a bordo dos satélites conseguem imagear somente uma faixa da Terra com algumas dezenas ou centenas de quilômetros de largura, as 14 órbitas imageadas em um dia ficam distanciadas entre si de milhares de quilômetros devido às velocidades relativas de órbita do satélite, e da rotação da Terra no sentido de oeste para leste. A cada novo dia, a posição da órbita progride na direção oeste. Esse processo de cobertura pode ser exemplificado considerando-se as características de imageamento do satélite Landsat (Figura 1.24). Cada órbita do Landsat cobre uma faixa no terreno de 185 km de largura. As órbitas tomadas no mesmo dia se distanciam entre si de 2.875 km, sendo necessários 16 dias para concluir o recobrimento total do globo. O princípio é o mesmo para qualquer outro satélite. O que irá variar é a resolução temporal do imageamento, pois cada sensor imageia faixas no terreno de larguras diferentes.

A resolução temporal é fundamental para acompanhar ou detectar a evolução ou mudanças que ocorrem na Terra, principalmente para alvos mais dinâmicos, como o ciclo fenológico de culturas, desmatamentos, desastres ambientais, tendo forte impacto na monitoração ambiental. A Figura 1.25 é um exemplo de uma área agrícola com vários pivôs de irrigação, e que no intervalo de nove anos mostra as alterações no parcelamento dos cultivares e aumento do número de pivôs. Atualmente, pela facilidade com que se pode reposicionar a visada de um sensor, de nadir para *off nadir* (fora da vertical), muitos satélites oferecem a possibilidade de revistas à área em espaços de tempo de dois a três dias.

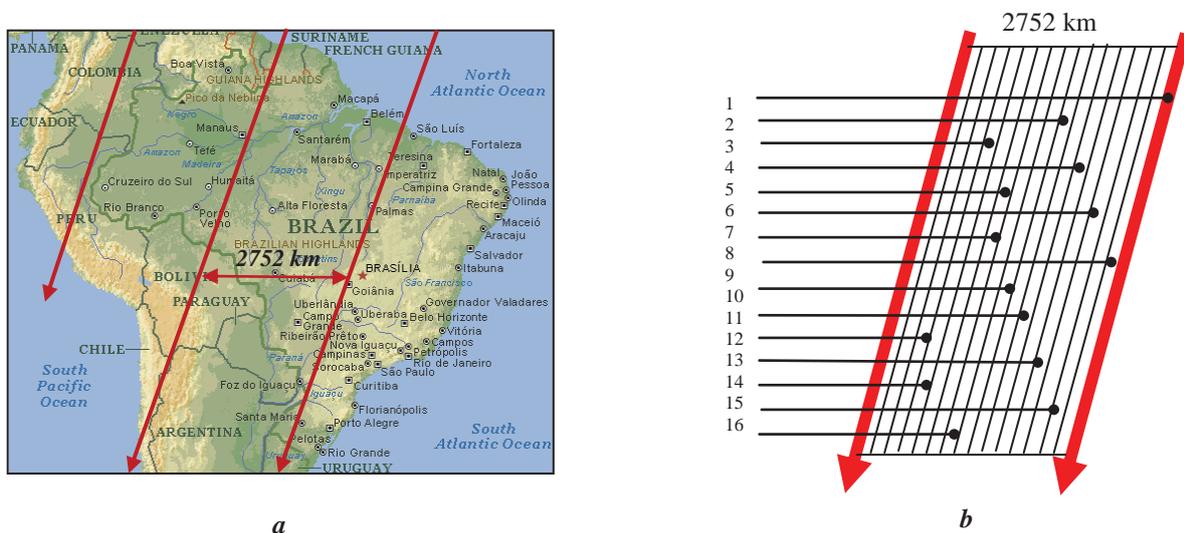


Fig. 1.24 Padrão de recobrimento de órbitas completadas em um único dia pelo satélite Landsat (a) e no período da resolução temporal de 16 dias (b). (Fonte: Novo, 1996).

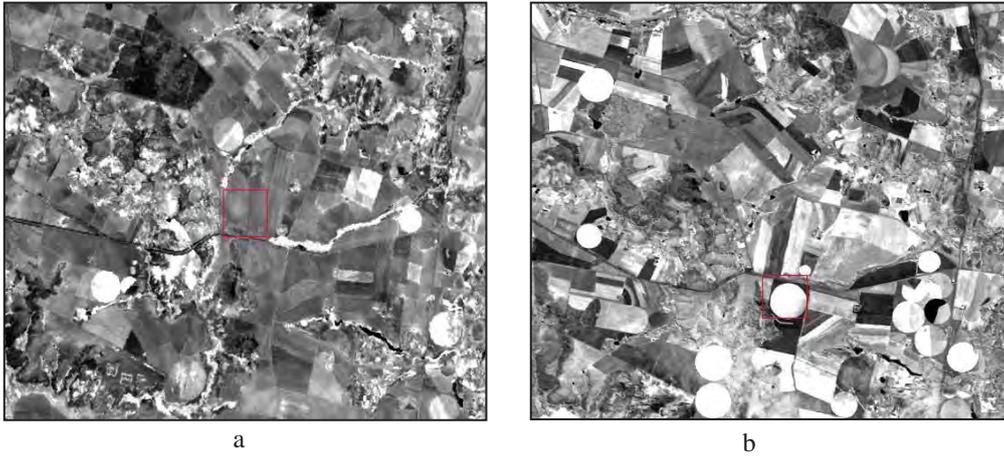
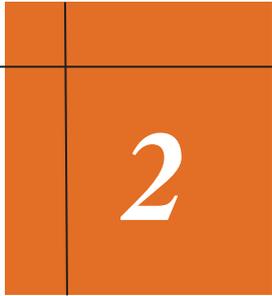


Fig. 1.25 Imagens Landsat de área agrícola obtidas nos anos de 2000 (a) e 2009 (b). Notar o crescimento de pivôs centrais e a modificação do parcelamento dos cultivares.

SENSORES IMAGEADORES MULTIESPECTRAIS NA FAIXA ÓPTICA (0,45 – 2,5 μm)



2

Paulo Roberto Meneses

2.1 Das Fotos Aéreas às Imagens Multiespectrais

O sensoriamento remoto tem suas bases nos princípios que levaram ao desenvolvimento das câmeras fotográficas aéreas para se obter, a partir de avião, fotografias da superfície terrestre. O princípio básico é o registro dos alvos por meio da detecção do fluxo de radiação eletromagnética refletida pelas superfícies dos objetos terrestres. Apesar do enorme benefício que as fotografias aéreas proporcionaram para a humanidade, foi-se percebendo, com o tempo, que o uso de aeronaves restringia a cobertura de grandes áreas e, sobretudo, a tomada de dados de forma sistemática para fins de monitoração do ambiente. Com o desenvolvimento tecnológico de novas plataformas aéreas, como os satélites, essa limitação estaria resolvida porque um satélite é capaz de orbitar continuamente à Terra, por muitos anos. Mas como colocar em órbita um sensor fotográfico munido de filmes que precisam ser constantemente substituídos? E também, como obter fotos além dos comprimentos de onda do início do infravermelho próximo (0,90 μm), que é o limite de sensibilidade espectral dos microscópicos detectores de cristais de haletos ou brometos de prata que revestem as emulsões fotográficas?

Essas indagações foram feitas porque já havia conhecimentos nos anos de 1950 que importantes informações dos objetos terrestres poderiam ser adquiridas muito além do poder de resolução espectral dos filmes, como no infravermelho de ondas curtas, no termal e nas micro-ondas. Detectores eletrônicos de radiação eletromagnética, compostos de cristais de silício, estavam em desenvolvimento para substituírem os filmes fotográficos.

Estimulados pelo desenvolvimento e construção de satélites artificiais, novos instrumentos sensores começaram a ser projetados, visando obter dados da Terra, a partir do espaço. Esses novos sensores, dito não fotográficos, foram denominados de sensores imageadores multiespectrais. Define-se sensores imageadores multiespectrais os instrumentos eletro-óptico capazes de obter múltiplas imagens simultâneas da superfície terrestre, desde o comprimento de onda da luz visível azul, até a região termal. Os sensores ópticos e termais operam, praticamente, da mesma forma. O mais comum é ter os dois sensores operando simultaneamente na mesma plataforma, apenas em módulos instrumentais distintos. Trataremos em capítulo à parte, o sensoriamento termal.

Pode-se justificar a grande eficiência dos sensores imageadores multiespectrais pelos seguintes motivos: (i) os dados são em formato digital; (ii) podem ser operados de plataformas espaciais por meio de satélites, permitindo a tomada de imagens de forma repetitiva ao longo de vários anos; e (iii) as imagens podem ser obtidas num amplo intervalo de comprimento de onda, com dezenas a centenas de bandas espectrais. Combinadas, essas características projetaram esse modelo de sensoriamento remoto como uma das melhores e mais bem sucedidas inovações para a tomada de dados da superfície terrestre. As imagens quando obtidas por imageadores a bordo de satélites possibilitam um imageamento global da Terra, em curto período de tempo, incomparáveis para uma monitoração precisa dos eventos e mudanças ambientais. Por sua vez, a versatilidade dos imageadores de obter imagens em

diferentes comprimentos de onda, ampliou sua utilização muito além das aplicações temáticas das ciências da Terra. E o formato digital trouxe o computador como um meio rápido para visualizar as imagens e processá-las para uma análise qualitativa e quantitativa, pelos fotointérpretes

Dos filmes fotográficos usados nas câmeras aéreas, aos detectores eletrônicos dos sensores imageadores, migrou-se de fotos analógicas para imagens digitais, dando-se o surgimento a uma nova tecnologia para análise de dados, que é o Processamento Digital de Imagens.

Deixando de lado o entendimento da complexa engenharia dos diferentes componentes instrumentais que integram um sensor imageador, pode-se dizer que o coração de um sensor imageador é composto pelos detectores da radiação eletromagnética e pela eletrônica de sinal, que converte a radiação eletromagnética em um número digital. É devido à maior efetividade e versatilidade que os detectores eletrônicos têm para registrar a radiação eletromagnética em diferentes intervalos de comprimento de onda, que é conferido aos sensores imageadores a capacidade de gerar, simultaneamente, um grande número de imagens em diferentes comprimentos de onda.

Um imageador é um instrumento que a cada instante capta a energia eletromagnética da radiação de pequenas amostras de área da superfície terrestre (pixel), convertendo-a, através dos detectores, em um sinal elétrico cuja intensidade é correspondente à intensidade da radiação de cada pixel. O sinal elétrico, amplificado e filtrado, é amostrado e quantizado em valores digitais dentro de um valor escalar dimensionado em bits. A conversão ou relação entre o nível do sinal analógico/digital (conversor A/D) é feito usualmente com um quantizador linear que converte o sinal para o valor digital inteiro mais próximo. Com o uso de *software* de processamento de imagens, os valores digitais de uma imagem são convertidos em valores de brilho (tons de cinza) quando a imagem é exposta em um monitor de vídeo, tal que o valor digital zero converte-se em um nível de brilho escuro e o valor digital máximo em um nível de brilho claro, entre eles, estabelecendo-se uma escala linear de brilhos de tons cinza.

As regiões espectrais do visível e do infravermelho da luz solar representam apenas uma parte do sensoriamento remoto, conhecida como a faixa dos sensores ópticos. Como se sabe, imagens termais podem ser obtidas da radiação eletromagnética emitida pela própria Terra, enquanto imagens de radar das micro-ondas podem ser adquiridas com o uso de fontes de radiação construídas pelo homem. Por isso, podemos dividir os sensores imageadores orbitais em três classes: sensores ópticos que utilizam fonte solar de radiação eletromagnética; sensores termais que usam Terra como a fonte de radiação; e sensores de radar que usam fontes artificiais construídas pelo homem.

Os sensores ópticos (e os termais) são constituídos basicamente de três sistemas: um sistema óptico, um sistema de detecção e um sistema eletrônico de registro de dados, que são agrupados em uma única unidade aeroespacial.

Sistema óptico: Constituído de espelhos e lentes, possui a função de focar uma área na superfície terrestre e coletar a REM por ela radiada. Os imageadores utilizam um telescópio portátil do tipo *Ritchey Chretch*, que permite a observação de pequenas áreas da superfície terrestre a uma altitude de centenas ou milhares de quilômetros. Os telescópios possuem essa capacidade, pois operam com distâncias focais de alguns metros e aberturas ópticas de miliradianos.

Sistema de dispersão e de detecção: Grades dicróicas e prismas são utilizados como filtros para dividir a REM em vários intervalos de comprimento de onda ou bandas espectrais, que são direcionados para incidirem sobre um conjunto de detectores, que geram sinais elétricos proporcionais às intensidades das radiações neles incidentes.

Sistema eletrônico: Constitui-se de componentes eletrônicos que ampliam os sinais elétricos de saída dos detectores e os transformam em valores digitais; os sinais digitais podem ser transmitidos em tempo real para estações terrestres de rastreamento de satélites, onde são gravados e, posteriormente, processados em laboratórios de produção de imagens.

2.2 Mecanismos de Imageamento Multiespectral

As formas dos sensores capturem as imagens multiespectrais do terreno podem variar um pouco, havendo dois principais mecanismos de imageamento por varredura, mas que não são significativamente diferentes entre si (Figura 2.1). Há os sensores do tipo de varredura mecânica (*whiskbroom*) e os do tipo de varredura eletrônica (*pushbroom*). As diferenças entre eles têm algumas implicações no poder de resoluções das imagens e em algumas das técnicas de processamento de imagem.

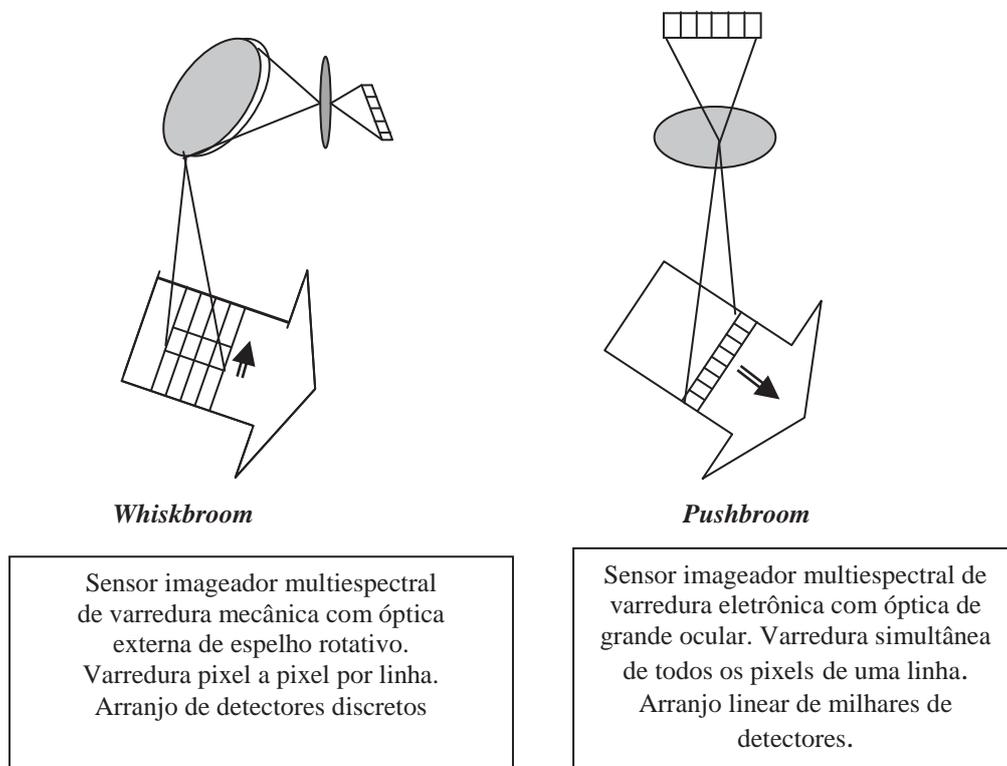


Fig. 2.1 Os dois modelos básicos de sistemas de varredura dos sensores multiespectrais.

2.2.1 Sensores de Varredura Mecânica (*whiskbroom*)

São sensores que usam um espelho externo para varredura do terreno e um conjunto de detectores discreto por bandas. A Figura 2.2 apresenta com mais detalhe o esquema de varredura mecânica. A principal característica deste tipo de sensor é o fato de o imageamento do terreno ser feito pixel a pixel ao longo de uma linha de várias dezenas ou centenas de quilômetros de extensão, no sentido transversal ao deslocamento do satélite. Daí serem também denominados de sensores *cross-track*. O sistema óptico de visada do pixel é feito por

um telescópio, e a sua designação como varredura mecânica é devido à existência no alinhamento de abertura do telescópio de um espelho plano de berílio inclinado de 45° , ligado a um eixo rotor que imprime uma altíssima rotação ou oscilação no sentido transversal ao deslocamento da plataforma. É esse movimento rotativo ou oscilante do espelho que varre o terreno em linhas perpendiculares à direção de voo. A radiação que chega ao espelho é refletida em direção ao telescópio, que a foca no sistema de dispersão e depois aos detectores. O movimento oscilatório do espelho permite que o *scanner* meça a radiação refletida de um lado a outro da faixa do terreno, ao longo da órbita da plataforma. O ângulo de oscilação σ do espelho plano, de cerca de 5° a 10° , determina a largura da faixa imageada no terreno. Esse ângulo de oscilação é denominado de FOV (*Field of View* – campo de visada). Conforme a plataforma avança, linhas sucessivas são varridas, até compor uma imagem. Esse processo é similar às imagens produzidas pelo processo de varredura de linhas utilizado pelos escaneadores de mesa.

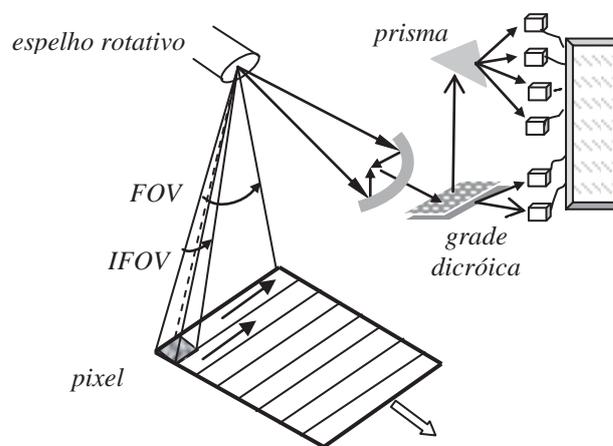


Fig. 2.2 Configuração esquemática do mecanismo de imageamento pixel a pixel de um sensor multiespectral de varredura mecânica.

Para que os sensores multiespectrais possam construir uma imagem pixel a pixel da superfície do terreno, ao longo de cada linha imageada o espelho rotativo montado a 45° se detém por frações muito pequenas de tempo (milésimos de segundo) e “enxerga”, pela óptica do telescópio, a radiância que deixa o pixel na direção definida por um ângulo cônico de visada β , chamado de IFOV (*Instantaneous Field of View*). Como β é um ângulo pequeno (poucos milliradianos), milhares de pixels individuais são observados sucessivamente a cada incremento de rotação do espelho, ao longo de uma linha de imageamento. Na realidade, esse processo constitui-se numa taxa de amostragem por área de radiância, que comumente denominamos de pixel, e que são as células de resolução espacial no terreno. Em resumo, com os imageadores mecânicos a taxa de amostragem é feita pixel a pixel ao longo de uma linha.

Esse mecanismo de varredura tem como limitação a reduzida taxa de permanência para a medição da radiância dos alvos contidos no pixel, o que impossibilita uma alta razão sinal/ruído. Para compensar a limitação, os sensores imageadores mecânicos operam em bandas espectrais de ampla largura, o que aumenta a quantidade de energia radiante do alvo, ajudando a melhorar o sinal em relação ao ruído. O ruído é também um sinal, mas gerado pelo próprio sensor em virtude do funcionamento elétrico de seus componentes. Os sensores

TM e ETM do satélite Landsat são os exemplos mais conhecidos de sensores de varredura mecânica.

Observando-se o lado direito da Figura 2.2 nota-se que a radiação de entrada proveniente de cada elemento de área de resolução no terreno é, primeiramente, direcionada para o sistema de dispersão. Como a radiação eletromagnética proveniente do alvo é composta pela REM refletida da luz solar, no intervalo de 0,45 μm a 2,5 μm , para se obter imagens multiespectrais é necessário, antes que ela atinja os detectores, separá-las em intervalos espectrais de comprimentos de onda, definindo-se assim, as bandas espectrais do sensor. Essa função é realizada pela grade de difração e prisma. Para medir a intensidade ($\text{w}/\text{m}^2\text{sr}$) de cada intervalo espectral, ou banda, comumente um arranjo discreto de um número pequeno de detectores eletrônicos de silício (Si) e de antimônio de índio (SbIn) é colocado em posição geométrica apropriada, atrás da grade de difração ou do prisma. A energia da radiação eletromagnética incidente nos detectores provoca-lhes uma excitação, proporcional à intensidade da energia incidente, gerando um sinal elétrico de saída que é registrado pelo sistema eletrônico do sensor. Esse sistema eletrônico é um conversor analógico/digital que transforma os sinais elétricos de saída dos detectores em correspondentes valores digitais. Os valores digitais compõem uma grade de pixel equivalente a cada pixel imageado no terreno, formando desta maneira uma imagem no formato digital. Cada detector é projetado para ter o seu pico de sensibilidade espectral em um comprimento de onda específico.

2.2.2

Sensores de Varredura Eletrônica (*pushbroom*)

Os sensores de varredura eletrônica possuem arranjos lineares de milhares de detectores que usam diodos ou dispositivos de cargas acopladas (CCD – *Charge-Coupled-Devices*), que nada mais é do que um *chip* de metal semicondutor montado em matrizes lineares ou bidimensionais. A óptica é de grande objetiva, que dispensa o uso de espelho rotativo. De um modo semelhante ao mecanismo dos sensores de varredura mecânica, os sensores de varredura eletrônica registram a imagem ao longo de uma faixa no terreno, através de varreduras de linhas sucessivas orientadas ortogonalmente à direção de trajetória da plataforma. A diferença entre esses dois tipos de varredura está na maneira como cada linha é varrida. Por meio da óptica de grande angular cada linha é imageada no terreno em toda a sua extensão, num único instante, utilizando-se do arranjo de milhares de detectores acoplados a um circuito eletrônico - CCD. A configuração de um sensor de varredura eletrônica é apresentada na Figura 2.3. Cada detector é responsável para registrar a energia de um único elemento de área do terreno (pixel) ao longo de uma linha de varredura. Portanto, a amostragem do terreno não é feita pixel a pixel, mas todos os pixels de uma linha são imageados simultaneamente. À medida que a plataforma se desloca ao longo de sua trajetória de voo ou órbita, linhas sucessivas são imageadas no terreno pelo arranjo dos detectores. São assim denominados de sensores *along-track*.

Como os detectores CCDs têm tamanhos minúsculos, um único arranjo pode conter dezenas de milhares de detectores individuais. É exemplo de varredura eletrônica o sensor HRV do satélite SPOT. Com uma largura de faixa de imageamento de 60 km de extensão e tamanho de pixel de 10 metros, em cada banda SPOT o arranjo linear de CCDs é composto de 6000 elementos. Normalmente, os arranjos são localizados no plano focal do sensor, tal que todas as linhas varridas são vistas simultaneamente por todos os arranjos CCDs das várias bandas. Nesse sistema de varredura linha a linha, tem-se a vantagem de maior tempo de permanência para a medida da radiância que deixa cada pixel, gerando uma imagem com

melhor qualidade sinal/ruído. Uma das desvantagens desses sistemas é que os detectores CCDs comercialmente disponíveis não são sensíveis para comprimentos de onda maiores do que o infravermelho próximo, o que limita a faixa espectral das imagens por eles obtida.

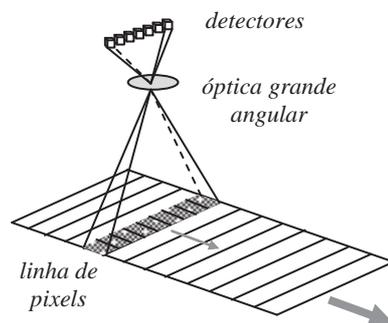


Fig. 2.3 Configuração esquemática do mecanismo de imageamento de um sensor de varredura eletrônica, com todos os pixels de uma linha imageados simultaneamente.

Por ser uma tecnologia mais avançada do que os sensores mecânicos, exatamente porque dispensa o movimento de varredura oscilatório de um espelho, que é um sério problema, a tecnologia de sensores *pushbroom* de arranjo linear é a melhor opção para sensores de alta resolução espacial, como as imagens dos satélites Ikonos e QuickBird. A resolução espacial das imagens desses sensores é da ordem de 1 metro ou maior para o modo pancromático. A intenção é oferecer à comunidade um produto que se aproxime da resolução espacial das fotos aéreas, com a vantagem de poderem ser requeridas pelo usuário, quando necessário. Ambos os satélites possuem, também, um módulo multiespectral com três bandas no visível e uma no infravermelho próximo, com resolução de poucos metros, as quais podem ser fundidas com a imagem pancromática, produzindo-se uma imagem colorida com resolução de 1 metro ou maior. A órbita desses satélites possui altitude um pouco mais baixa que a dos outros sensores multiespectrais, e o tempo de revisita é de apenas alguns dias.

2.3

As Informações Contidas nas Imagens Multiespectrais da Faixa Óptica

O conhecimento sobre a identificação das imagens dos objetos da superfície terrestre iniciou-se a partir de fotos aéreas obtidas por sensores fotográficos a bordo de aeronaves. No decorrer do tempo a partir dos anos de 1930 começaram surgir os primeiros métodos de fotointerpretação, a maioria dirigido a aplicações para mapeamentos urbanos, geológicos, geomorfológicos, de solos e de vegetação. Invariavelmente, todos esses métodos de interpretação tiveram seus conceitos fundamentados na análise das formas ou texturas dos objetos, e não de suas reflectâncias, em razão de pelo menos três parâmetros inerentes aos sensores fotográficos.

O primeiro desses parâmetros diz respeito ao tipo de detector da radiação eletromagnética, os filmes, e na forma como eles registram a imagem dos objetos. Nos filmes, a reflectância de cada objeto é uma medida integrada de uma larga faixa do espectro, que abrange quase toda a região da luz visível, do azul ao vermelho ($0,45 \mu\text{m}$ a $0,76 \mu\text{m}$). Isso diminui muito o nível de contraste de reflectância entre os alvos, e por isso as fotos aéreas apresentam pouca variação de níveis de cinza. O segundo parâmetro consiste no alto poder de resolução espacial das fotos, que permite a identificação de objetos no terreno de

tamanhos até menores que 1 metro. O terceiro parâmetro deve-se ao tipo de geometria do recobrimento aéreo do terreno que é feito de uma maneira que possibilita uma visão tridimensional do relevo, a partir de um par de fotos sobrepostas, usando como recurso um simples instrumento óptico, o estereoscópio. Como consequência da conjunção desses três fatores, os atributos da forma dos objetos são destacados, enquanto que a capacidade de análise dos níveis de cinza de uma foto preto e branco torna-se secundária, por não trazer informações suficientes para uma análise do comportamento espectral da reflectância dos objetos.

Essa deficiência espectral das fotos é devida à ampla largura da faixa espectral dos filmes do visível, os mais utilizados em levantamentos aéreos, o que faz com que os sensores fotográficos sejam classificados como de baixa resolução espectral. Para compensar essa baixa resolução espectral é necessário que eles tenham uma alta resolução espacial. Na foto aérea o filme registra, no intervalo de comprimentos de onda do visível, a média das intensidades de reflectância dos objetos, que como mostra o gráfico da Figura 2.4 pode resultar para muitos tipos de objetos, em médias de reflectância muito próximas. Nesta figura vemos que isso contraria o que mostram os padrões das curvas de reflectância da água e da vegetação, tomados como exemplo. Enquanto na foto aérea do visível a água e a vegetação seriam vistas com tons de cinza muito próximos, o contrário se consegue com uma imagem do infravermelho próximo obtida por um sensor multiespectral. A vantagem dos sensores multiespectrais de obter imagens simultâneas em vários comprimentos de onda, é a forma de se ter a resolução espectral como um atributo de análise superior à resolução espacial. Normalmente, os sensores imageadores possuem várias bandas espectrais no visível e no infravermelho, com o nítido propósito de facilitar a discriminação de diferentes tipos de materiais por meio de suas reflectâncias.

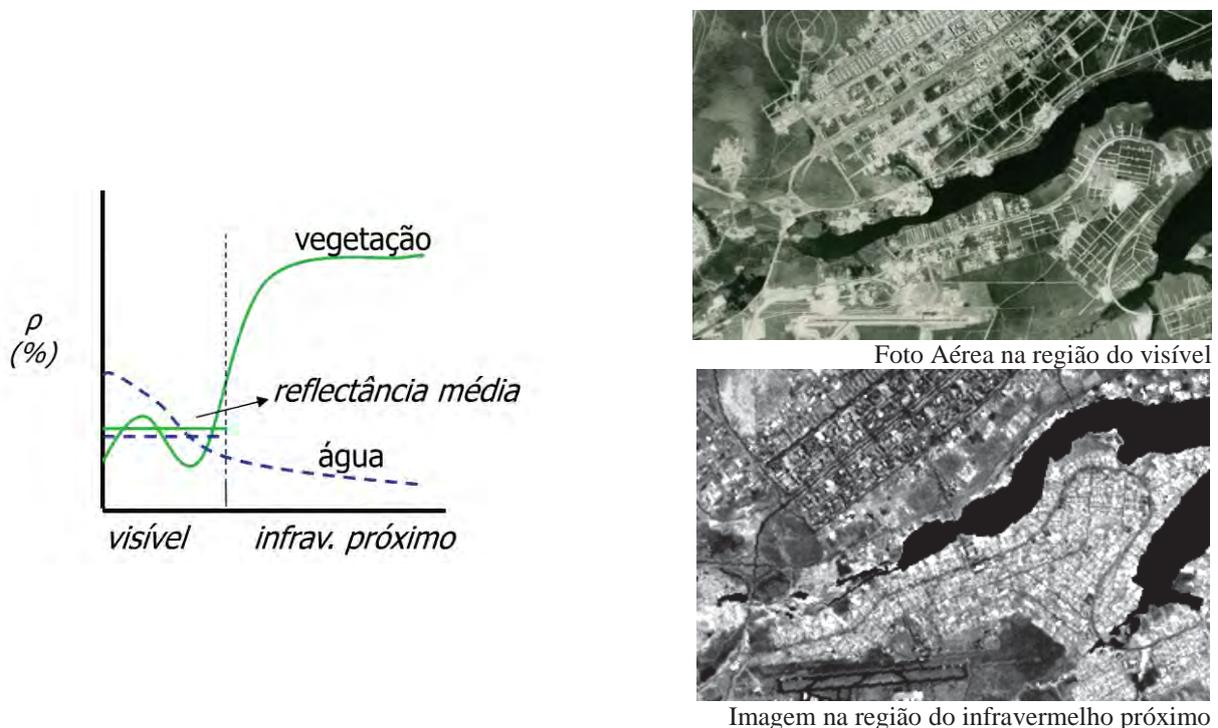


Fig. 2.4 As reflectâncias médias da água e da vegetação são muito próximas na região do visível dificultando as suas discriminação nas fotos aéreas do visível, enquanto facilmente são discriminadas na imagem do infravermelho próximo de um sensor multiespectral (imagem da região amazônica).

2.3.1

Interação da Luz Solar com os Materiais

Por princípio, os sensores imageadores podem medir a radiação eletromagnética em um amplo intervalo de comprimentos de ondas, do visível às micro-ondas. Como discutido no capítulo 1, devido a considerações tecnológicas e opacidade e espalhamento da atmosfera, uma grande parte do espectro eletromagnético é excluída. Isso faz com que os intervalos de comprimentos de onda úteis ao sensoriamento remoto se limitam a três grandes regiões espectrais: 1) região espectral óptica da luz solar, no intervalo de 0,45 μm a 2,5 μm ; 2) região espectral do termal da radiação eletromagnética emitida pela superfície da Terra, no intervalo de 8,0 μm a 14,0 μm ; 3) região espectral das micro-ondas (radar) da radiação eletromagnética emitida por uma fonte artificial no intervalo de comprimento de onda de 3,0 cm a 100 cm.

Ao longo da história do sensoriamento remoto a concepção de sensores multiespectrais tem valorizado mais os sensores que operam na faixa óptica de reflectância da luz solar. No intervalo espectral da luz solar a quantidade de energia do fluxo radiante é muito intensa, suficiente para interagir ao nível microscópico com os átomos e moléculas dos constituintes da matéria, possibilitando obter informações de suas composições físico/químicas. Um exemplo é mostrado na Figura 2.5, onde as duas imagens em diferentes comprimentos de onda mostram que para se identificar a presença de pivôs centrais de irrigação, em uma área agricultada, basta identificar os objetos com formas circulares, independente, de qual seja a banda espectral da imagem. Porém, para identificar se na área do pivô central existe uma cultura presente ou se a área do pivô está com solo descoberto, é preciso analisar e comparar as refletâncias do solo e da vegetação, em diferentes comprimentos de onda, ou seja, nas várias imagens que o sensor multiespectral capta. Por haver no mínimo um comprimento de onda no qual o solo e a vegetação exibem notável diferença de reflectância, facilmente a solução será encontrada. Nesse exemplo, a imagem do infravermelho próximo bastaria para resolver esta questão. Por isso, ao contrário das fotos aéreas, a análise baseada simplesmente nas propriedades da forma dos objetos é secundária no sensoriamento remoto multiespectral.

É exatamente essa condição de os diferentes tipos de materiais poderem se distinguidos por suas diferenças de reflectância, uma das principais motivações do sensoriamento remoto moderno. Para os geólogos, que são acostumados a identificar nas fotos aéreas as unidades litológicas pela análise dos elementos texturais do relevo, com as imagens multiespectrais, têm-se a oportunidade de acrescentar a essa forma de análise, informações referentes à composição das litologias. Podemos então resumir, que enquanto as fotos aéreas dão as informações sobre as propriedades da forma dos objetos, as imagens multiespectrais oferecem informações sobre a composição dos objetos. Devido ao fraco poder de penetração da radiação no corpo do material, apenas os primeiros 10 a 50 micros de espessura podem ser investigados.

Dentro desse contexto, para que uma imagem multiespectral possa ser interpretada, é fundamental conhecer os mecanismos de interação da radiação eletromagnética com a superfície dos materiais terrestres. É através do entendimento de como se processam esses mecanismos de interação que se pode determinar como e com qual intensidade cada objeto ou material reflete a onda eletromagnética. Sendo assim, o interprete deverá estar habilitado em saber identificar em qual banda ou bandas espectrais contém a informação que deseja. Os sensores multiespectrais normalmente possuem configurações de bandas espectrais selecionadas para interesses em múltiplas aplicações.

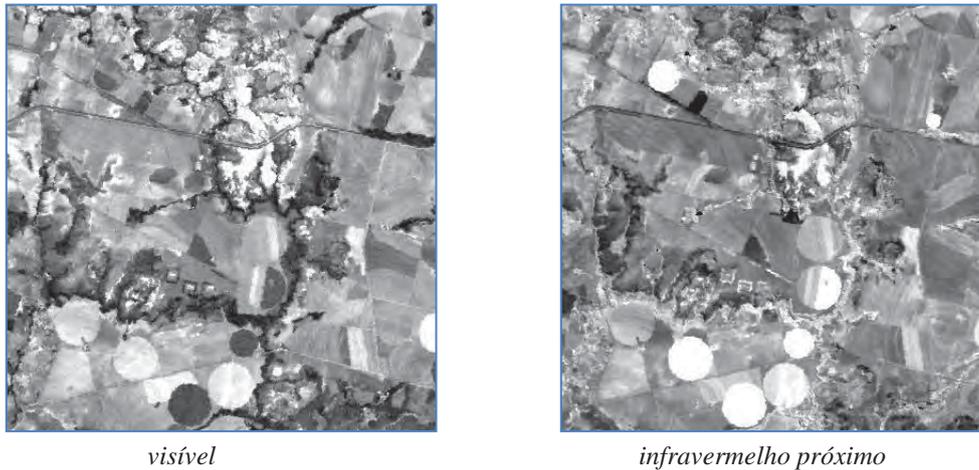


Fig. 2.5 As diferenças dos comprimentos de onda das duas bandas mostram que os pivôs com cobertura vegetal aparecem em tons de cinza escuro no visível e em tons claros no infravermelho, e os pivôs com solo nu aparecem claros em ambas as imagens.

Como mostra a Figura 2.6, a luz solar, que é a que mais revela as propriedades das naturezas dos materiais, ao incidir sobre a superfície do objeto sofre três possíveis processos de interações: *absortância* (α_λ); *transmitância*; (τ_λ); *reflectância* (ρ_λ). Como pela lei de conservação de energia, nenhuma quantidade de energia é perdida, $\alpha_\lambda + \tau_\lambda + \rho_\lambda = 1$

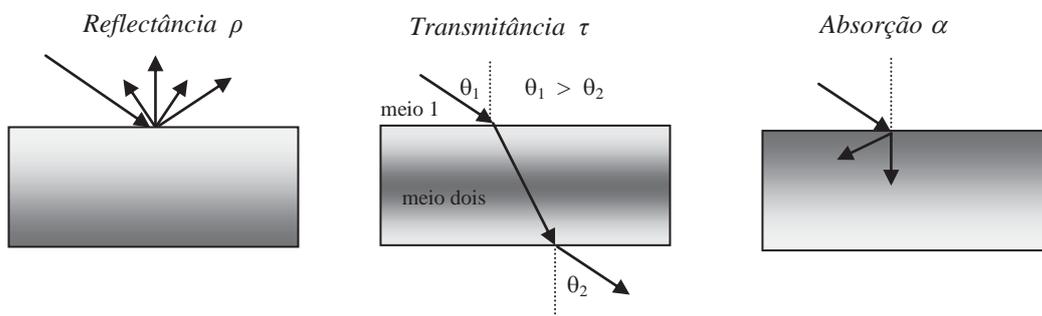


Fig. 2.6 Processos de interação da radiação eletromagnética com os materiais.

As quantidades de reflectância, absortância e transmitância dependem dos valores dos coeficientes ópticos do material, geralmente propriedades difíceis de serem medidas, dado à heterogeneidade dos materiais. Uma rocha é constituída de uma assembléia de minerais, cada um tendo um diferente coeficiente óptico. Para as rochas e solos, em sensoriamento remoto costuma-se simplificar essas propriedades, descrevendo-as em função apenas da opacidade e transparência dos materiais. Assim, esses materiais em relação à radiação eletromagnética são definidos como:

- ✓ *Opacos*: quando contém em sua constituição, proporções mesmo que ínfimas, de minerais opacos como magnetita, ou compostos como a matéria orgânica, que absorvem bastante a radiação eletromagnética, em quase todos os comprimentos de onda.

- ✓ *Transopacos*: quando numa dada região espectral exibem uma baixa reflectância e em outra região espectral exibem alta reflectância; a maioria das rochas e solos exhibe esse tipo de comportamento.

Além das propriedades ópticas que controlam as quantidades de energia radiante absorvida e refletida pelos objetos, há fatores externos que influenciam as relações de reflectância e absorvância, e por isso são complexas a análise e a interpretação das imagens. Um pixel de tamanho grande será muitas vezes um pixel mistura, com um padrão de reflectância que não é fácil de ser decodificado. E os gases presentes na atmosfera espalham a radiação eletromagnética, adicionando reflectância à reflectância do pixel, alterando dessa forma a reflectância dos materiais. E como vimos no capítulo 1, o efeito atmosférico tende a diminuir o contraste espectral entre os alvos.

Por esses motivos, o conteúdo que trata das considerações sobre a interação da REM com os materiais e de suas implicações na análise e interpretação de imagens, é assunto especializado em sensoriamento remoto. Recomenda-se aos leitores procurarem por essas publicações, sugerindo para leitura, o livro de Meneses e Madeira Netto (2001), “*Sensoriamento Remoto: reflectância dos alvos naturais*”. No presente contexto cabe abordar esse assunto apenas em um nível introdutório, mas o suficiente para se entender por que o sensoriamento remoto oferece uma gama variada de imagens em diferentes comprimentos de onda.

Os sensores que operam na faixa óptica do espectro, ou seja, do visível ao infravermelho de ondas curtas (0,4 μm a 2,5 μm), medem apenas a intensidade do componente de radiação refletida dos objetos. Cada material da superfície da Terra tem um comportamento particular nas quantidades da radiação refletida, absorvida e transmitida. A própria experiência do dia a dia demonstra isso. Uma folha de uma árvore é verde, porque é neste comprimento de onda que os pigmentos clorofílicos refletem com maior intensidade a luz solar verde, e para isso acontecer devem absorver a luz azul e vermelha. Um quartzito puro tem a cor clara porque os grãos de quartzo refletem com intensidades muito próximas e elevadas, a luz azul, a verde e a vermelha. Ele não absorve a luz visível.

A explicação para isso está na capacidade da radiação eletromagnética de fazer trocas da energia contida nas ondas eletromagnéticas com a energia contida nas pequenas partículas que constituem a matéria: átomos e moléculas. Recordando que pela dualidade da natureza da radiação eletromagnética, ela é uma onda com energia expressa por $E = h \times c / \lambda$, os pequenos comprimentos de onda do visível ao infravermelho de ondas curtas são os que carregam as maiores quantidades de energia, suficientes para interagirem ao nível microscópico da matéria. Portanto, esses menores comprimentos de onda de alta energia mais diretamente se relacionam com a composição ou constituição dos materiais. Pode-se assim dizer que as imagens dos sensores da faixa óptica do espectro nos permitem, por meio de uma análise das intensidades da radiação refletida, descobrir sobre interessantes propriedades da composição dos materiais. Como exemplos, é possível identificar se um folhelho tem matéria orgânica em sua composição, se uma rocha tem ferro férrico ou ferro ferroso na estrutura cristalina de seus minerais, ou se uma rocha carbonática é calcítica ou dolomítica.

O modelo quântico é a chave para explicar as interações de trocas energéticas da REM com os materiais, pois assim se comportam com muita semelhança as energias contidas na REM e nos átomos e moléculas dos materiais. Isto é, cada comprimento de onda carrega uma específica e única quantidade de energia e cada átomo ou molécula tem seus específicos níveis ou estados de energia. Pela teoria quântica um átomo ou molécula pode existir somente em certos estados ou níveis de energia permitidos, de modo que o átomo ou molécula somente absorverá uma quantidade específica da energia eletromagnética (número de fótons), se essa quantidade for suficiente para mudar num átomo ou molécula o seu estado de energia

fundamental para outro excitado. Diz-se que ocorreu uma transição entre os estados de energia.

Os materiais se diferenciam entre si por constituírem sistemas com diferentes estados de energia, e a radiação refletida seria uma resposta indireta das mudanças, ditas transições, ocorridas nesses níveis de energia: níveis eletrônicos e moleculares. No nível eletrônico as transições são mudanças dos níveis ou estados de energia dos elétrons acoplados aos íons. Nos íons, cada elétron ocupa um orbital que descreve uma carga elétrica em movimento em torno do núcleo. A distribuição dos elétrons nos orbitais depende do número atômico de cada elemento. Pode acontecer que o último ou penúltimo orbital não é totalmente preenchido, ficando assim, com elétrons desemparelhados. São esses elétrons desemparelhados que podem absorver a energia da radiação eletromagnética e mover-se de um orbital para outro de mais alta energia, caracterizando uma energia de transição.

A Figura 2.7 é um exemplo ilustrativo do processo. Em um mineral, um íon centrado de um metal de transição e envolvido por um campo octaedral de cargas negativas (ânions) apresenta, por efeito de campos eletrostático, uma separação de níveis de energia dos elétrons contidos nos seus orbitais $3d$ em dois níveis: um de mais alta energia (e_g), e outro de mais baixa energia (t_{2g}). Quando uma radiação eletromagnética de um determinado comprimento de onda incide sobre esse mineral, uma quantidade de fótons da radiação será absorvida para promover a transição de um ou mais elétrons que se situam no nível de energia mais baixo, para o nível de energia mais alto. Isso significa que nesse comprimento de onda o mineral absorveu uma grande quantidade de energia dessa onda e, conseqüentemente, mostrará uma reflectância mais baixa. Estando o mineral presente em uma rocha, nas imagens de sensoriamento remoto a rocha terá uma reflectância mais baixa quando comparada com outros tipos litológicos que não possuem este mineral. Um processo bem semelhante ocorre com os níveis de energia das ligações vibracionais das moléculas que um mineral de rocha contém. O mesmo se explica para qualquer outro tipo de matéria.

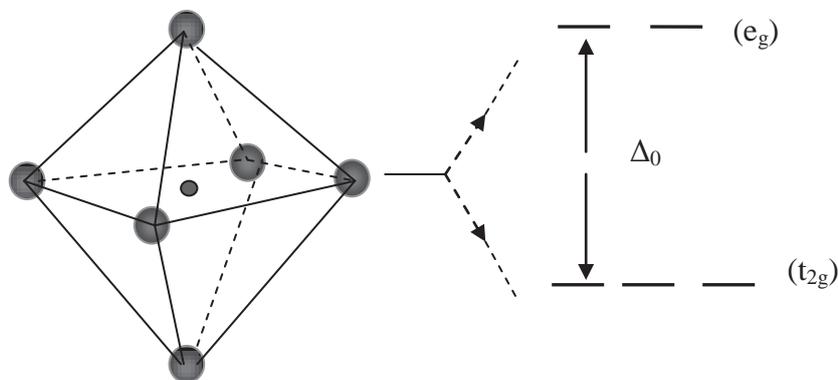


Fig. 2.7 Níveis de energia contidos no metal de transição centrado na estrutura de um mineral octaedral.

Em outras palavras, devido a essa natureza quântica da energia da matéria, as transições de energias eletrônicas e moleculares ocorrem somente quando um específico comprimento de onda, incidente no material, excita um processo interno no átomo ou na molécula. A quantidade de energia que é absorvida num específico comprimento de onda caracterizará uma feição espectral de absorção que se mostrará como uma assinatura espectral da composição daquele material. Sendo assim, são nos comprimentos de onda em que os

materiais mais fortemente absorvem a radiação eletromagnética, que um sensor deverá possuir as suas bandas espectrais.

A maneira prática que se tem para identificar em quais comprimentos de onda ocorrem as feições de absorção, é por meio de medições dos espectros de reflectância, feitas em laboratórios ou no campo. Para se obter essas medidas usam-se os espectrorradiômetros, que são instrumentos que plotam na forma de gráficos, a intensidade da energia refletida por unidade de comprimento de onda. Os espectrorradiômetros têm uma função equivalente aos sensores imageadores. Os sensores imageadores medem a radiância refletida por comprimento de onda (bandas de um sensor) e configuram a imagem dos objetos em níveis de cinza, onde os valores de cinza claros representam alvos com alta reflectância e os valores de cinza escuros representam alvos com baixa reflectância. Os espectrorradiômetros fazem a mesma coisa, apenas não geram uma imagem de saída.

A medida de reflectância obtida pelos espectrorradiômetros é mostrada em gráficos que relacionam a porcentagem da reflectância com o comprimento de onda, como as que estão na Figura 2.8, dos materiais rocha, solo e vegetação. As estreitas depressões indicadas pelas setas identificam os comprimentos de onda onde as absorções da radiação eletromagnética pelos átomos e moléculas, possibilitam identificar alguns dos constituintes do material. Observe a notável variação do padrão de reflectância desses materiais. Ao especialista em sensoriamento remoto cabe-lhe determinar quais elementos e moléculas presentes em cada um dos materiais são os responsáveis pelos padrões da reflectância/absortância. A largura da feição de absorção, a sua forma, profundidade e posição no espectro, ajudam nessa análise. Por exemplo, quando ocorrem duas absorções centradas em 1,4 μm e 1,9 μm há água presente na estrutura molecular do material, qualquer que seja ele, solo, vegetação ou mineral. Uma absorção centrada em 2,27 μm determina a presença do íon CO_3 do mineral calcita. Na vegetação a absorção em 0,65 μm é devida ao pigmento clorofítico e a absorção em 0,95 μm no solo é devida à presença de óxido de ferro. Sendo assim, um sensor será ideal para diagnosticar e identificar esses três tipos de materiais, quando as bandas estiverem posicionadas, coincidentemente, com essas feições de absorção desses materiais.

Os espectros de reflectância são fundamentais para guiar o intérprete na seleção das bandas do sensor para a interpretação das imagens. Um jeito prático de se fazer isso é mostrado na Figura 2.9. Com base em alguns conhecimentos prévios da área, o interprete plota os espectros de reflectância dos alvos existentes na área, e as posições das bandas espectrais das imagens do sensor que estiver usando. Com isso, ele poderá determinar quais as bandas do sensor têm a capacidade de discriminar os alvos, que é na prática, o que interessa em sensoriamento remoto. No exemplo, pode-se ver que as bandas 1 e 2 do visível mostram pouca diferença de reflectância entre a vegetação, o xisto e o solo orgânico, e, portanto, não é considerada uma boa banda para interpretação. Apenas a rocha carbonática poderia ser diferenciada dos outros três materiais. A banda 3 no comprimento de onda da luz vermelha, a banda 4 no infravermelho próximo, e a banda 5 no infravermelho de ondas curtas, mostram ser as melhores bandas. A banda 5 leva vantagem em relação às bandas 3 e 4 porque os níveis de reflectância são maiores, o que resulta na imagem em tons de cinzas mais claros que são melhores percebidos pelo olho humano. Com essas três bandas o interprete constrói uma composição colorida, reunindo em uma única imagem toda a informação.

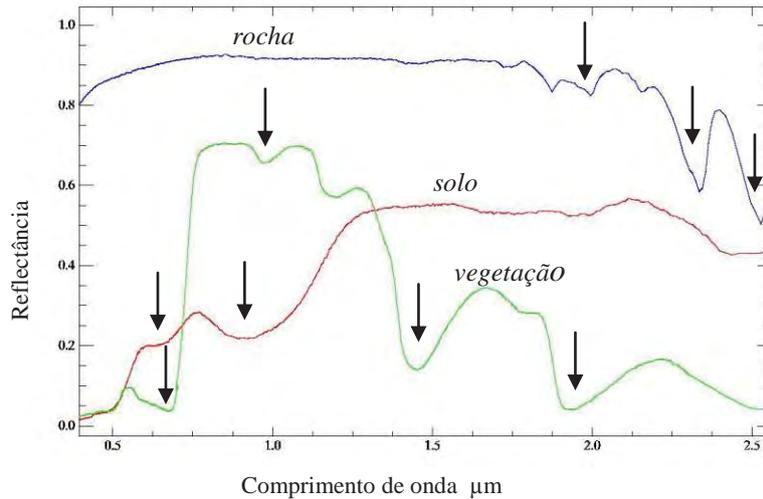


Fig. 2.8 Exemplos de espectros de reflectância de vegetação, rocha carbonática e solo com óxido de ferro, com indicação das bandas de absorção dos seus principais constituintes.

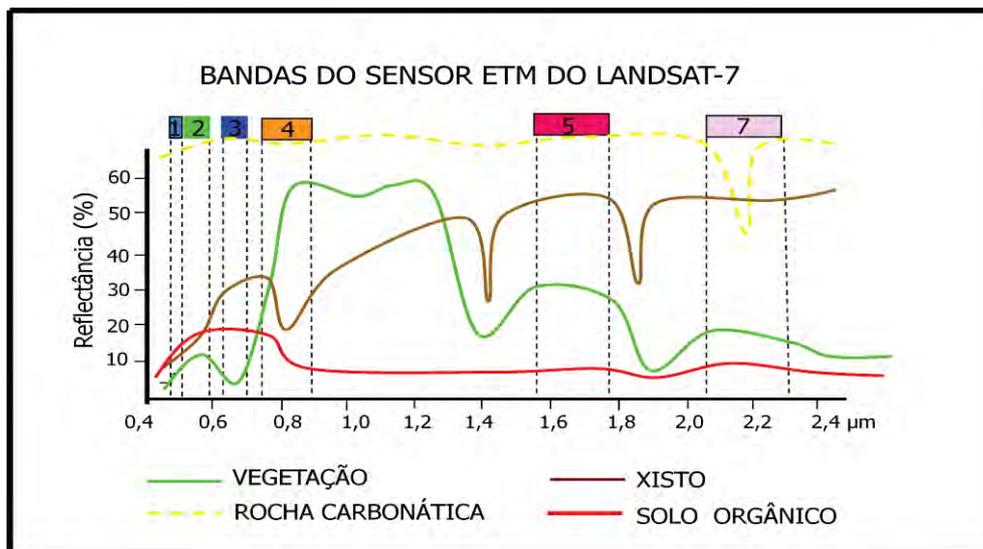


Fig. 2.9 Espectros de reflectância e as posições das bandas do sensor EMT-Landsat 7 como forma para avaliar as bandas que melhor diferenciam espectralmente os quatro tipos de materiais.

O exemplo apresentado mostra que dois parâmetros de análise são essenciais na maneira como se devem analisar as imagens para *identificar e distinguir* os diferentes tipos de materiais terrestres. Em sensoriamento remoto, identificar é reconhecer a natureza do objeto, e distinguir é diferenciar um objeto do outro. Os dois parâmetros de análise são:

1- As feições de absorções da radiação eletromagnética são assinaturas espectrais que *identificam* um tipo de material, pois elas ocorrem com formas e intensidades próprias, num específico comprimento de onda, e dependem unicamente da composição do material.

2- As diferenças dos níveis de reflectâncias entre os materiais num determinado comprimento de onda, e que se traduz na imagem por contrastes de níveis de cinza, é que possibilitam distinguir um objeto do outro. As diferenças sempre são maiores onde os materiais exibem as feições de absorção da radiação eletromagnética.

SENSORES IMAGEADORES NA FAIXA DO TERMAL (8 - 14 μm)

3

Gustavo Macedo de Mello Baptista

3.1 Temperatura e Calor

Todos os corpos que apresentam temperatura acima do chamado zero absoluto ou zero Kelvin ($-273,15^{\circ}\text{C}$) emitem radiação eletromagnética, incluindo a do infravermelho termal. Isso ocorre, porque acima dessa temperatura as moléculas se encontram em um estado vibracional, e quando colidem elas mudam seu estado de energia e emitem radiação eletromagnética. São, portanto, fontes de radiação eletromagnética. Isso se verifica para qualquer objeto terrestre, natural ou artificial, e da mesma forma que se pode medir com um sensor a radiação solar refletida dos objetos, pode-se também medir a radiação termal emitida e ter a imagem desses objetos. A radiação termal estende-se de $5,0\ \mu\text{m}$ a $1,0\ \text{mm}$, mas devido às absorções da atmosfera, apenas a faixa espectral de $8,0$ a $14\ \mu\text{m}$ é usada nas aplicações de sensoriamento remoto terrestre.

A percepção mais direta ou a primeira que temos com a radiação termal está relacionada com a emissão de raios solares. Como vimos no capítulo inicial, a radiação eletromagnética pode ser entendida como uma onda que carrega diversas partículas de energia. Essas partículas ou fótons ao serem absorvidos pelo material aumentam o estado energético, levando o material a um estado que chamamos de excitado. Porém, o material não pode permanecer continuamente excitado e precisa retornar ao seu nível energético original. Para tal, é necessário que ele se “livre” dos fótons absorvidos, que são emitidos sob a forma de ondas longas, perceptíveis na faixa do infravermelho termal.

Os seres humanos não têm sensores ópticos sensíveis à percepção da radiação eletromagnética do termal, pois nossa percepção visual está restrita à faixa da luz visível. Mas, por meio do tato podemos perceber a radiação calorífica ou termal, emitida pelos objetos. Um exemplo disso, é que se colocarmos dois indivíduos expostos ao Sol, sendo um com uma camisa branca e outro com uma camisa preta, nós não temos como avaliar a diferença de emissão de fótons dos dois tecidos, mas ao aproximarmos nossas mãos, sem a necessidade de tocá-los, podemos sentir que a camisa preta emite mais calor. Isso porque, ao absorver mais radiação que o tecido branco, o tecido de cor preta teve seu estado energético aumentado e para retornar à normalidade houve a necessidade de liberar os fótons absorvidos.

Para compreendermos melhor as informações contidas nas imagens do espectro termal de emissão, é necessário expor alguns conceitos. O primeiro conceito a ser apresentado é o de energia, que é definida como a capacidade de realizar qualquer tipo de trabalho, e uma dessas formas de energia é a energia cinética, que pode ser entendida como a quantidade de energia de movimento. Esse conceito é fundamental para diferenciarmos temperatura, de calor.

Temperatura é a medição do grau de movimento ou de agitação dos átomos e das moléculas de um corpo, conhecida também como temperatura cinética ou temperatura verdadeira. O calor é entendido como o fluxo de energia entre dois corpos de temperaturas diferentes. Portanto, temperatura é diferente de calor. A distribuição espacial da temperatura

no corpo determina o fluxo de calor. O calor sempre se desloca do mais quente para o mais frio e o calor contido em um objeto não só depende de sua temperatura, mas também de sua massa.

A transferência do calor é feita, comumente, por três processos: condução; convecção; e radiação. A condução é um processo no qual o calor passa de partícula a partícula, desde a extremidade mais quente até a mais fria. Percebemos isso ao segurar uma barra metálica próxima a uma fonte de calor. Com o tempo o calor irá chegar à nossa mão e provavelmente irá nos queimar. A convecção ocorre, normalmente, nos fluidos, quando o calor proveniente de uma fonte é transferido pela circulação de água ou de ar. Isso ocorre, por exemplo, ao se colocar uma panela ao fogo com um conteúdo de água. À medida que a água mais próxima da chama se aquece e tende a reduzir sua densidade por maior agitação das moléculas, ela ascende, enquanto que a porção mais fria descende e aí a água ferve. A radiação é a transferência de calor que ocorre pelo espaço sob a forma de radiação termal. Não há a necessidade de encostar a mão no fogão para perceber pelo tato a radiação que sai da chama em direção a sua mão. Essa radiação é a radiação eletromagnética termal e é o mesmo caso das camisas de cores branca e preta. A Figura 3.1 apresenta esses três processos mais comuns de transferência de calor.



Fig.3.1 Processos de transferência de calor (fonte <http://física.ufpr.br>. acesso 2/10).

Outros dois conceitos fundamentais para nossa compreensão dos sensores termais são os de calor sensível e de calor latente. Quando o corpo cede ou recebe calor, variando apenas a sua temperatura, sem mudar o seu estado físico, dizemos que ele recebeu ou cedeu calor sensível. Já quando a quantidade de calor causa mudança de estado físico, mas não de temperatura, dizemos que houve variação de calor latente.

A compreensão do calor sensível é bem tranquila, pois percebemos isso o tempo todo. Quando nos deparamos com os termômetros de rua podemos verificar que à medida que a manhã avança em direção ao meio dia, a temperatura do ar vai aumentando e à medida que o dia vai se estendendo para a noite, ela diminui. Para entendermos o conceito de calor latente vamos utilizar a água e suas mudanças de estado físico, conforme mostra Figura 3.2.



Fig. 3.2 Mudanças de estado físico da água pelo calor.

Para que ocorra a fusão, ou seja, a mudança do estado sólido para o líquido, o gelo precisa absorver 80 calorias. Porém, se medirmos a temperatura do gelo antes da fusão e do líquido no instante exato da fusão, os dois apresentam 0°C. Se formos avaliar a evaporação é necessário que o líquido absorva 600 calorias para se transformar em vapor d'água, porém nos dois momentos, antes e depois da evaporação, a água apresentará 100°C no nível do mar.

O calor latente para os dois processos é representado pelo número de calorias que foi absorvido para as mudanças de estado, sem a mudança na temperatura. Para ocorrer os processos inversos, os de solidificação e o de condensação, são necessários liberar as mesmas quantidades de calor latente.

3.2 Leis Físicas da Radiação Termal

Quando pensamos em sensoriamento remoto termal temos de pensar no comportamento térmico dos alvos. Para tal, é necessária a compreensão das leis físicas que regem esse comportamento.

O primeiro aspecto que devemos pensar é no conceito de fonte corpo negro, tal como vimos no capítulo 1. A idéia de corpo negro foi desenvolvida por Kirchoff e designa o corpo que transforma em calor toda a radiação que sobre ele incide. Mais tarde, Planck, aluno de Kirchoff, desenvolveu a lei para explicar como funciona a radiação emitida por um corpo negro em todos os comprimentos de onda (eq. 1.5, cap.1).

Como não se possui na natureza um corpo 100% absorvedor, a solução encontrada para simulá-lo foi utilizar uma esfera oca com o interior metálico refletor e com um pequeno orifício que permite a entrada da REM. Ao entrar pelo orifício, a radiação tem uma baixa probabilidade de sair e como fica sendo espalhada pelo interior, tende a atingir o equilíbrio térmico. Cria-se assim a simulação do corpo negro (Figura 3.3).

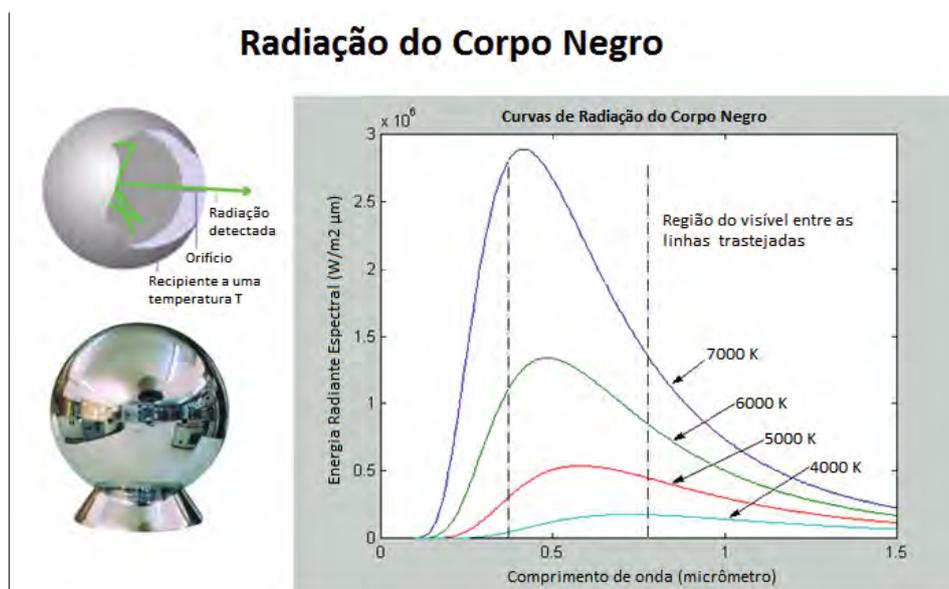


Fig. 3.3 Radiação do corpo negro para fontes de diferentes temperaturas, definida pela lei de Planck. Destaque para a esfera que simula o corpo negro.

Podemos perceber pelo gráfico da Figura 3.3 que realmente há uma relação inversa entre a temperatura e o comprimento de onda no qual se tem o pico máximo de energia radiante espectral. Se tomarmos a temperatura média do planeta Terra como de 300 K, um corpo negro a essa temperatura emitirá seu máximo de energia radiante em torno de 9,6 μm e sua faixa como fonte de REM será de 8 a 35 μm (Figura 3.4). Por isso, podemos dizer que se na faixa do espectro óptico refletido, de 0,4 a 2,5 μm , o Sol é a fonte de radiação eletromagnética, no espectro emitido, de 8 a 14 μm , a Terra é a fonte de radiação (além de 14 μm a radiação termal é absorvida pela atmosfera). Simplificando, o Sol é a fonte de REM de ondas curtas e a Terra, de ondas longas. Portanto, se quisermos fazer sensoriamento remoto termal dos objetos terrestres como solo, vegetação, água e rochas, as imagens deverão ser obtidas no intervalo de 8 a 14 μm . Em todo esse intervalo é possível de se fazer ao nível de aeronaves, mas ao nível orbital, por causa da maior espessura da atmosfera, há uma forte banda de absorção em torno 9,5 μm .

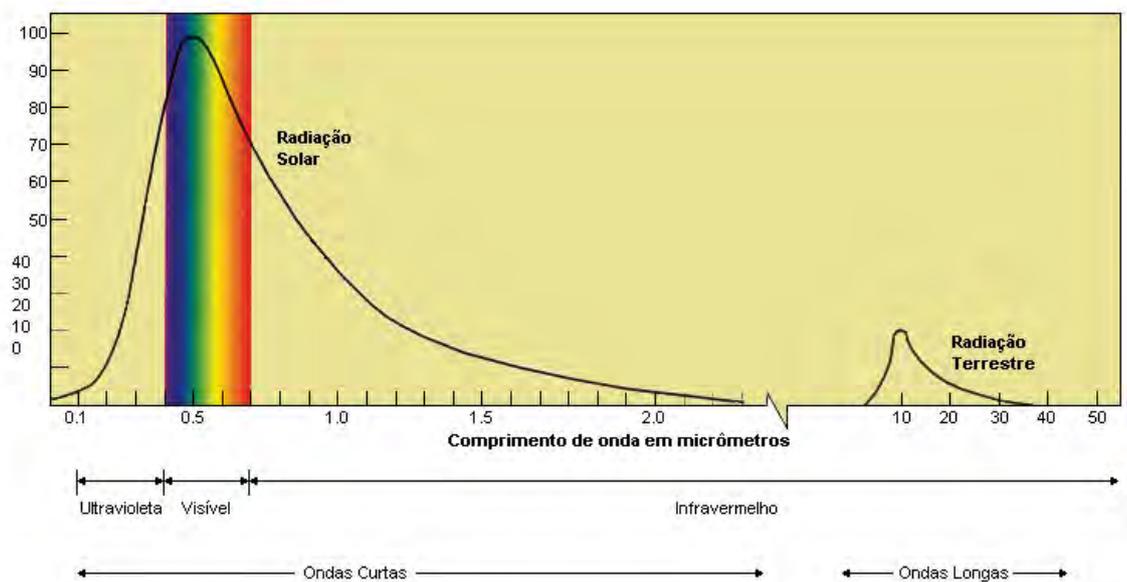


Fig. 3.4 Intensidade da radiação eletromagnética da fonte terrestre a 300 K.

A quantidade de energia que qualquer corpo emite é, dentre outras coisas, função da temperatura do corpo. Essa propriedade pode ser expressa pela Lei de Stephan-Boltzman.

$$M = \sigma T^4$$

eq. 3.1

onde, M = emitância radiante da superfície do material (W m^{-2})
 σ = constante de Stephan-Boltzman ($5,6697 \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$)
 T = temperatura absoluta medida em Kelvin

Por essa equação notamos que há uma relação direta entre a emitância radiante e a temperatura, e a relação não é linear, ou seja, um pequeno aumento da temperatura representa um grande aumento na emissão de radiação. Da mesma maneira que a energia total emitida por um corpo varia com a temperatura, a distribuição espectral da energia emitida também varia. O comprimento de onda no qual a emissão de energia é máxima pode ser determinado pela Lei de Wien, também conhecida como Lei do Deslocamento, expressa pela equação 3.2 e visualizada na Figura 3.5.

$$\lambda_m = A/T$$

eq. 3.2

onde, λ_m = comprimento de onda de máxima emissão (μm);
 A = constante 2898 $\mu\text{m K}$;
 T = temperatura absoluta medida em Kelvin.

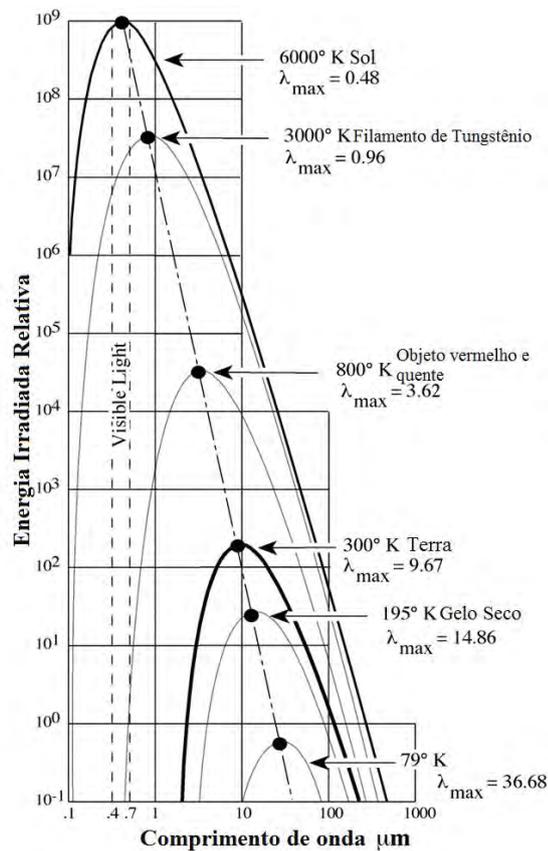


Fig. 3.5 Deslocamento do pico máximo de energia em direção aos menores comprimentos de onda à medida que a temperatura do corpo aumenta. (Adaptado de Jensen, 2009).

Na Figura 3.5 o corpo com temperatura de 800 K pode representar um intenso incêndio, que tem o seu pico de emissão termal em 3,62 μm . Esse comprimento de onda está fora do intervalo de emitância espectral da Terra, de 8 a 14 μm . Sendo assim, um incêndio ou um derrame de lavas são fontes de radiação termal anômalas na superfície da Terra, e as suas imagens devem ser obtidas próximas ao comprimento de onda de 3,6 μm .

3.3 Emissividade

O mundo não é composto por corpos negros radiadores, que é apenas um modelo físico para explicar o comportamento das fontes de radiação eletromagnética. Ao invés disso, encontramos corpos que radiam seletivamente e que emitem apenas uma parte da energia que

seria emitida por um corpo negro que estivesse à mesma temperatura. Emissividade – ε – representa a relação entre a radiância real emitida pelo corpo do mundo real (M_r) e pelo corpo negro à mesma temperatura (M_b) (equação 3.3).

$$\varepsilon = \frac{M_r}{M_b} \tag{eq. 3.3}$$

A emissividade de um objeto é função de uma série de fatores, tais como cor, composição química, rugosidade da superfície, umidade e tantos outros. Lembre-se de que a emissividade depende da absorção préterita de fótons e para tal é fundamental lembrarmos dos processos de absorção. Kirchoff observou que na porção do infravermelho do espectro a emissividade espectral de um objeto geralmente é igual a sua absorptância espectral, por isso podemos dizer que bons absorvedores são bons emissores. Se analisarmos as imagens dos objetos de coloração mais escura, ou seja, de baixa reflectância, deduzimos que eles são mais absorvedores e no termal notaremos que eles são mais emissores, ou seja, apresentam maior emissividade que alvos que apresentem coloração clara, com maior reflectância.

Vaughn *et al.* (2003) deduziu que se a emissividade geralmente é igual à sua absorptância, e sabendo que o objeto tem transmitância zero à radiação termal, então a intensidade radiante é:

$$I = \rho_\lambda + \varepsilon_\lambda \tag{eq. 3.4}$$

Isso demonstra que a energia que emana dos objetos tem uma relação entre a reflectância (ρ_λ) e a emissividade (ε_λ). Se a reflectância é alta a emissividade é baixa. Um bom exemplo para ilustrar essa propriedade é um corpo de água. Como a água absorve quase toda a energia do infravermelho e reflete muito pouco, a sua emissividade é próxima a 1. Um teto metálico de um galpão tem alta reflectância e sua emissividade deverá ser muito baixa quando comparada à do corpo de água, como se pode ver na Tabela 3.1. Quando pensamos em materiais geológicos, a composição química é uma das propriedades utilizadas para que possamos identificá-los nas imagens de sensoriamento remoto. Se tivermos um material com altas concentrações de minerais que apresentam ligações do tipo Al-OH, teremos fortes absorções na faixa de 2,2 μm . Por exemplo, ao analisarmos espectros na faixa óptica refletida entre os materiais que contém caulinita ($\text{Al}_2\text{SiO}_5(\text{OH})_4$) ou gibbsita ($\text{Al}_2\text{O}_3 \cdot 3\text{H}_2\text{O}$), notaremos que os gibbsíticos apresentam feições mais intensas de absorção e, assim, apresentam maior emissividade. A composição química é o fator mais importante para se verificar as variações de emissividades entre os materiais, e a imagem termal, tal como as imagens da faixa espectral óptica, revela as variações de composições dos materiais.

Tabela 3.1 Emissividades (ε) médias de alguns materiais terrestres entre 8 a 14 μm (fontes: Sabins, 1997; Lillesand e Kiefer, 2004).

Material	Emissividade (ε)
Água destilada	0,99
Água	0,92 – 0,98
Gelo seco	0,97 – 0,98
Vegetação verde	0,96 – 0,99
Vegetação seca	0,88 – 0,94
Gramma	0,97
Solo úmido	0,95 – 0,98
Solo seco	0,92 – 0,94

Neve	0,83 – 0,85
Areia	0,90
Asfalto	0,95
Basalto	0,95
Granito	0,86
Dunito	0,78
Metal polido	0,16 – 0,21
Alumínio polido	0,55
Ouro polido	0,02 – 0,03
Aço inoxidável	0,16

A umidade do material tende a reduzir o albedo (lembre-se que um solo molhado é mais escuro que um seco) e com isso, maior é a sua capacidade de absorver a energia e de reemissão posterior de energia. Observe na Tabela 3.1 que um solo seco tem uma emissividade de 0,92 e quando se torna úmido, a emissividade aumenta para 0,95. Partículas de solo úmido têm uma alta emissividade, semelhante à da água.

Superfícies com maior rugosidade tendem a apresentar menor albedo que superfícies mais lisas, pois maiores serão as áreas de sombra. E com uma maior área superficial do objeto, maior tende a ser seu potencial de absorção, tornando-se um bom emissor.

Outros fatores podem influenciar a emissividade dos alvos na superfície, como o grau de compactação, o tamanho do campo de visada do sensor termal e, principalmente, o comprimento de onda termal considerado. Lembre-se de que a maioria dos alvos terrestres com temperatura média da Terra de 300 K (26,85 °C; 80,3 °F), o comprimento de onda dominante é em 9,67 μm e, portanto, a faixa de 8 a 14 μm é a mais apropriada para a investigação dos materiais naturais.

Como se pode observar na Figura 3.6 a água destilada é o material terrestre que apresenta um comportamento termal mais similar ao do corpo negro à mesma temperatura, pois possui uma emissividade bastante próxima a 1, entre 0,98 a 0,99. Note que a curva de emissividade da água acompanha bem próxima a curva de emissividade do corpo negro.

A maioria dos outros materiais apresenta um comportamento seletivo. O quartzo, um mineral comum na mineralogia de muitas rochas ou na forma de veios, atua como um radiador seletivo, como é mostrado na Figura 3.6. Todos os materiais que se comportam como fortes radiadores seletivos, como a exemplo do quartzo, são os melhores para serem detectados e diferenciados nas imagens termais. Rochas que contém muitos veios de quartzo, e que às vezes são fontes de minérios metálicos, têm grandes possibilidades de serem discriminadas nas imagens termais, dos outros litotipos estéreis. Nas imagens da faixa óptica isso não seria possível, porque o quartzo não possui nessa faixa espectral nenhuma banda de absorção que se relacione a sua composição, a não ser quando contém algum mineral como impureza ou água confinada.

Tal como vimos com as curvas de reflectância dos materiais, as curvas de emitância servem para indicar as diferenças espectrais da emissividade dos diferentes materiais. Dessa forma, quando analisamos uma imagem termal, não necessariamente nos interessa extrair da imagem informações da temperatura dos materiais. A informação da emissividade dos materiais seria a forma de identificá-los. Para fazer isso, é preciso resolver o problema da separação temperatura/emissividade, de tal forma que os efeitos da temperatura são subtraídos e apenas a informação da emissividade dos alvos possa ser analisada. Vários trabalhos foram realizados nesse sentido, descrevendo como a radiação termal emanada das superfícies das rochas pode ser usada em conjunção com a informação da emissividade derivada, para mapear rochas ou seus minerais (Vaughn *et al.*, 2003; Jacob *et al.*, 2004). Essa questão é tratada a seguir.

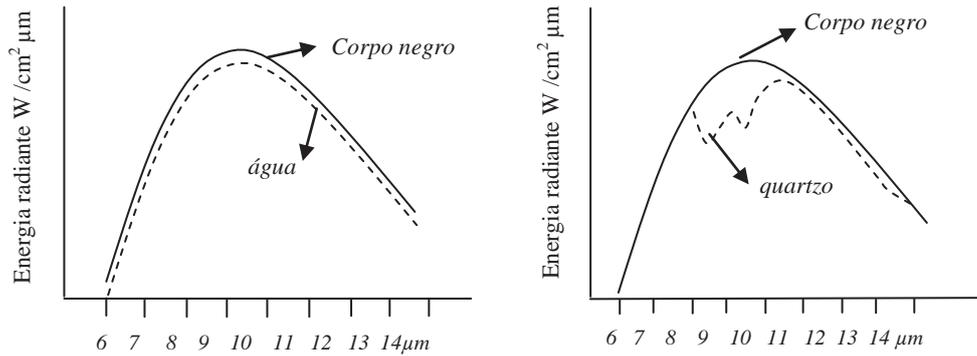


Fig. 3.6 Comparação da emitância radiante espectral da água e do quartzo com a do corpo negro à mesma temperatura de superfície. (Fonte: Lillesand e Kiefer, 1994).

3.4 Temperatura Cinética versus Temperatura Radiométrica

Devido à propriedade de emissividade dos corpos naturais, os sensores do infravermelho termal registram a intensidade da radiação equivalente à temperatura radiante aparente do terreno, e não a temperatura cinética verdadeira. A temperatura cinética verdadeira (T_{kin}), que é medida com um termômetro, como já vimos é a que mede o grau de movimento ou de agitação das moléculas. Como efeito desse fenômeno, os objetos emitem radiação eletromagnética. A radiação eletromagnética que sai de um objeto é chamada de fluxo radiante (Φ) e é medida em watts. A concentração dessa quantidade de fluxo radiante que sai do objeto é chamada de temperatura radiométrica (T_{rad}) ou temperatura aparente. Portanto, quando o sensor termal mede essa energia emitida, ele não está medindo a temperatura cinética do objeto, como se faz com o termômetro, mas a temperatura radiométrica.

Em algumas aplicações de uso de imagens termais, saber qual é a temperatura do objeto pode ser importante. Alguns exemplos são o mapeamento dos padrões de nuvens e movimentos de frentes, o monitoramento das temperaturas da superfície do mar, a detecção de ilhas urbanas de calor, focos de queimada ou mesmo derrames de lavas. Nesses casos, é necessário determinar a relação entre a temperatura cinética com a temperatura radiométrica. Para fazer isso utilizamos a lei de Stefan-Boltzmann, vista na equação 3.1, que é válida para objetos que são emissores perfeitos (corpos negros). Para compensar a diferença das fontes corpos negros com as fontes naturais, basta acrescentar a ela o valor de emissividade correspondente a cada material. Assim a equação 3.1, de Stefan-Boltzmann deve ser reescrita como,

$$M_r = \varepsilon \sigma T^4 \tag{eq. 3.5}$$

e combinando a equação 3.1 com a equação 3.5 temos que,

$$M_r = M_b \varepsilon \tag{eq. 3.6}$$

e assim,

$$\sigma T_{rad}^4 = \varepsilon \sigma T^4 \tag{eq. 3.7}$$

de onde se obtém que a relação entre a medida da temperatura radiante T_{rad} de um objeto com a sua temperatura cinética T_{kin} é

$$T_{rad} = \varepsilon^{1/4} T_{kin} \quad \text{eq. 3.8}$$

Como a emissividade ε varia entre 0 a <1, pode-se deduzir da equação 3.8 que a temperatura radiométrica medida no sensor sempre será inferior à temperatura cinética real do objeto. Os materiais com emissividades próximas a 1 exibem temperaturas radiométricas mais próximas a de suas temperaturas cinéticas. Revendo a Tabela 3.1, isso melhor se verifica nas rochas basálticas e menos para os granitos e dunitos. Para os materiais com emissividade muito baixa, como os metais polidos, a temperatura radiométrica será muito mais baixa que a sua temperatura cinética, dando a impressão de ser uma superfície mais fria. Isso pode ser um problema na identificação de alguns objetos urbanos, tais como os que apresentam coberturas metálicas.

3.5 As Imagens do Termal

Como vimos todos os objetos que compõem a superfície terrestre são fontes emissoras de radiação eletromagnética com intensidades de emitância proporcionais à sua temperatura de superfície. Como as condições ambientais e climáticas interferem a todo o momento nessa temperatura de superfície, modificando-a em curtos intervalos de tempo, os dados das imagens obtidas na faixa do termal podem variar temporalmente. Outro fator que pode trazer problemas para o uso prático das imagens termais é a influência do aquecimento solar sobre os materiais. Uma imagem termal tomada em um dia em que a insolação é fraca, as superfícies dos materiais terão temperaturas mais baixas e emitirão intensidades menores de energia radiante do que num dia de alta insolação. Conseqüentemente, as duas imagens apresentarão diferentes tons de cinza para os mesmos alvos, dando a impressão que ocorreu alguma variação ou mudança dos alvos entre as duas datas de tomadas das imagens

Para evitar esse efeito é mais aconselhável obter as imagens termais um pouco antes de amanhecer o dia, quando o calor armazenado pela insolação já tenha se dissipado. Nessas horas a temperatura dos materiais estará mais próxima de suas temperaturas naturais, as quais são diretamente relacionadas às suas propriedades intrínsecas de calor específico, condutividade e densidade. Por isso, qualquer uso ou aplicação das imagens termais depende do conhecimento das condições ambientais no momento da tomada da imagem, a fim de se corrigir a radiância da cena.

Os mecanismos de imageamento no termal são iguais ao do imageamento feito com os sensores ópticos e os mesmos conceitos sobre resoluções espacial, espectral e radiométrica discutidos anteriormente, também se aplicam aos sensores termais. Por isso, muitos dos sensores orbitais atualmente em operação adquirem simultaneamente imagens termais e imagens ópticas da mesma área, e assim a aquisição dos dados termais acaba sendo realizado em função do horário de obtenção das imagens ópticas.

Em casos como esse, em que as imagens termais são obtidas simultaneamente com as imagens ópticas, vemos que sempre a resolução espacial das imagens termais é menor. Isso porque existe um comprometimento entre a resolução espacial e a resolução radiométrica na obtenção de dados do infravermelho termal. Quanto maior o campo de visada instantâneo do sensor (IFOV, do inglês *Instantaneous Field Of View*), maior o tempo de permanência do

detector visando o terreno. Isso possibilita uma medida da radiação emitida com maior precisão, ou seja, com maior resolução radiométrica, pois o sinal de energia radiante medido tende a ser mais forte do que qualquer ruído gerado por componentes do sistema sensor. Quando isso ocorre, temos uma boa relação sinal-ruído.

Porém, quanto maior é o IFOV, pior é a capacidade de se captar detalhes espaciais mais finos, que requer normalmente um IFOV pequeno. Em sensores termais a opção por IFOV grandes, da ordem de 2,5 mrad, é uma forma de reduzir o ruído, o que faz com que se opte por melhores resoluções radiométricas que espaciais. Atualmente, um dos exemplos atuais mais notáveis é sensor orbital ASTER. Esse sensor possui três módulos de imageamento, sendo um módulo do visível ao infravermelho próximo (VNIR do inglês *Visible/Near InfraRed*), com três bandas de resolução de 15 m e com 8 bits de resolução radiométrica; um segundo módulo no infravermelho de ondas curtas (SWIR do inglês *ShortWave InfraRed*), com seis bandas de resolução de 30 m e com 8 bits; e um terceiro módulo no termal próximo (TIR ou do inglês *Thermal InfraRed*), com cinco bandas de resolução de 90 m e com 12 bits. Note que a melhor resolução radiométrica é a do termal, porém tem a menor resolução espacial.

Outra razão que limita a resolução espacial das imagens termais orbitais é o tipo de detector usado. Os detectores termais respondem à radiação neles incidentes por meio de um aumento de temperatura do material de que são construídos. Esses detectores são compostos de In:Sb (antimoneto de índio) com pico de sensibilidade em 5 μm ; Ge:Hg (germânio dopado com mercúrio) com pico de sensibilidade em 10 μm ; e Hg:Ce:Te (telureto de cádmio-mercúrio) sensível ao intervalo de 8 a 14 μm . O aumento de temperatura provoca mudanças na resistência ou voltagem dos detectores, produzindo um sinal correspondente a essa mudança. A desvantagem é que eles têm uma lenta resposta de medida, que resulta em uma demora no tempo de retorno para a sua temperatura fundamental. Por isso a taxa de amostragem no terreno é menor se comparada com a taxa de amostragem dos fótons detectores, e menor será a sua resolução espacial.

A Figura 3.7 ilustra uma imagem no termal, ao lado da imagem da faixa óptica, tomadas simultaneamente no horário diurno. Observe que dificilmente um especialista poderia prontamente reconhecer qual é a imagem termal. Isso porque, qualquer imagem de qualquer comprimento de onda é o registro, em tons de cinza, das diferentes intensidades de radiação eletromagnética que chegam ao sensor. Porém, a interpretação do significado dos tons de cinza de uma imagem do visível e de uma imagem do termal é baseada em parâmetros de análises diferentes. Enquanto as variações de níveis de cinza na imagem do visível correspondem às diferenças de reflectâncias entre os alvos, na imagem do termal as variações de cinza correspondem às relações de temperaturas/emissividades dos alvos.

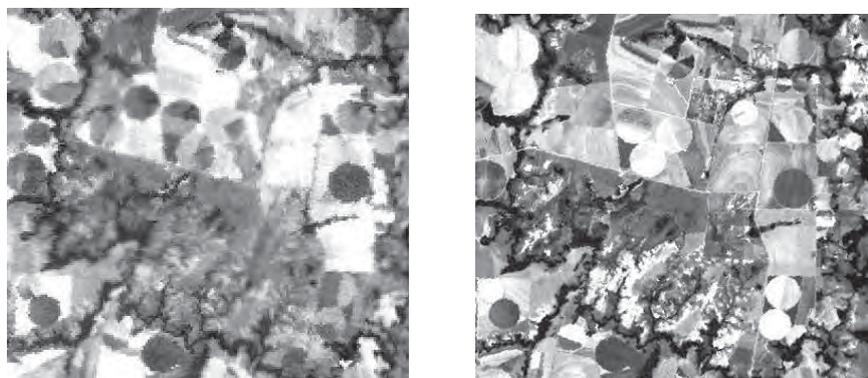


Fig. 3.7 Imagens no termal de 10,4 – 12,5 μm (esquerda) e da faixa visível do vermelho de 0,63 – 0,69 μm (direita), obtidas simultaneamente pelo sensor ETM do Landsat7.

SENSOR RADAR DE ABERTURA SINTÉTICA

4

Paulo Roberto Meneses
Edson Eyji Sano

4.1 Imageamento Lateral

A região das micro-ondas de 2,4 cm a 100 cm, cujos comprimentos de onda chegam a ser da ordem de 200.000 vezes maior que os comprimentos de onda da luz visível, é usada para obter imagens com os sensores de radar, um acrônimo de *Radio Detection and Ranging* (Detecção de Ondas de Rádio e Posição). O radar é um sensor que se utiliza de uma fonte de radiação eletromagnética artificial, construída pelo homem, porque o Sol e a Terra emitem baixíssima quantidade de radiação eletromagnética nessa região espectral. É por isso denominado de sensor ativo. Sua principal vantagem em relação aos sensores ópticos e termais é que o grande comprimento das micro-ondas não é barrado ou absorvido pelas micrométricas partículas ou gases da atmosfera. Essa condição permite obter imagens, mesmo quando a cobertura de nuvens é total. E pelo fato de a fonte ser ativa, o imageamento pode ser feito em qualquer hora do dia ou da noite. Essa é outra vantagem dos sistemas de radar, cujos dados independem das variações nas condições de iluminação solar (ângulos de elevação e azimute solar), como ocorrem, por exemplo, com os sensores da faixa óptica, como do CBERS ou Landsat.

Os comprimentos de onda das imagens de radar são identificados por letras, aparentemente sem nenhum significado, fruto de uma tentativa nos anos 1940 de manter segredo militar das faixas espectrais de operação dos primeiros sistemas de radar. As bandas mais utilizadas em radar são mostradas na Figura 4.1, com seus correspondentes valores de frequência em Hertz. Alguns preferem o uso da frequência ao invés do comprimento de onda, pois quando a radiação eletromagnética atravessa materiais de diferentes densidades, a frequência não se altera, enquanto o comprimento de onda e a velocidade se alteram.

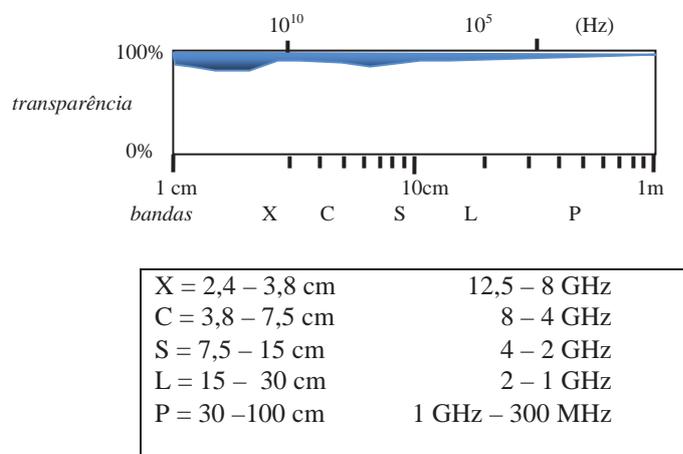


Fig. 4.1 O gráfico mostra a transparência quase total das várias bandas de radar e no quadro os respectivos intervalos de comprimento de onda e correspondentes frequências.

A escolha do comprimento de onda do radar deve ser compatível com o tamanho das feições do alvo que se deseja identificar. Por exemplo, a banda de comprimento de onda X é melhor para identificar as variações texturais de solos, enquanto que para o mapeamento geológico, cujas feições são de grandes dimensões, é mais apropriado usar a banda L. Mas, se quisermos obter uma maior penetração da onda na vegetação de uma mata, uma banda de grande comprimento, como a banda P, maior do que as folhas, é indicada.

Diferente da iluminação solar, que consiste no envio de radiações paralelas e contínuas de luz (fótons) sobre uma superfície, o radar envia por meio de uma antena, séries descontínuas de pulsos de fótons que se espalham sobre o terreno como um feixe angular na forma de um lóbulo. A transmissão é de um pulso eletromagnético de alta potência, de curto período e de feixe muito estreito. Durante a propagação pelo espaço o feixe se alarga em forma de cone, até atingir o alvo que está sendo iluminado, sendo então retroespalhado. A energia retroespalhada retorna para a mesma antena que, neste momento, torna-se receptora de sinais. O lóbulo no terreno, em relação à direção de propagação da plataforma que transporta o sistema de radar, é amplo na dimensão transversal (dezenas ou centenas de quilômetros) e estreito na dimensão longitudinal da linha de voo (Figura 4.2). O mecanismo se resume em enviar, num intervalo de tempo programado, sucessivos pulsos de onda eletromagnética na direção do objeto, à medida que a plataforma se desloca. Como a velocidade de propagação do pulso é conhecida (velocidade da luz, $3 \times 10^8 \text{ m.s}^{-1}$ ou 300.000 km/s), medindo-se o tempo de chegada do pulso de retorno refletido do alvo, calcula-se a distância do alvo à antena e é, então, registrada a sua posição no terreno. Para cada pulso registrado é medido a sua intensidade. Para emitir esses pulsos de radiação eletromagnética, os radares de sensoriamento remoto utilizam uma pequena antena retangular, que é fixada na lateral da aeronave ou do satélite e que é apontada lateralmente em relação à direção da trajetória. Por isso, são chamados de radares de visada lateral e a imagem é oblíqua. A largura do feixe da antena que determina a largura do lóbulo no terreno é controlada de duas maneiras: (i) pelo tamanho físico da antena, e nesse caso os radares são chamados de radar de abertura real (RAR), ou (ii) sintetizando o tamanho efetivo da antena em uma grande antena, que são os conhecidos radares de abertura sintética (SAR). O SAR é o radar utilizado em sensoriamento remoto, por ter a capacidade de melhorar a resolução espacial, como veremos adiante.

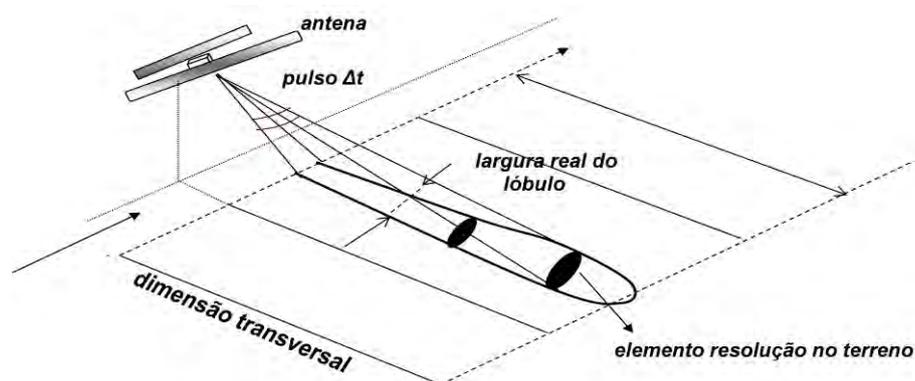


Fig. 4.2 Lóbulo de iluminação no terreno formado pelo pulso de radiação eletromagnética emitido por uma antena de radar de visada lateral.

A necessidade de uma visada lateral é explicada na Figura 4.3, que demonstra a incoerência da visada vertical para detectar os alvos em suas posições e distâncias, em

relação ao sensor. O alvo A_3 e os pares de alvos (A_1, A_5) e (A_2, A_4) estão em posições diferentes no terreno. Quando o pulso vertical de onda de radar chega ao terreno, primeiro ele encontra o alvo A_3 e faz o registro de sua posição na imagem, como se ele estivesse em uma posição do terreno mais próxima da aeronave. A seguir, o pulso de radar atinge simultaneamente os alvos A_2 e A_4 , registrando os pulsos refletidos com sobreposição de tempo e, portanto, de distância. O mesmo se repetirá em um terceiro momento de tempo para os alvos A_1 e A_5 . Esses pares de alvos são assim, registrados na imagem com posições distorcidas, tal como mostra o lado direito da Figura 4.3. Essa incoerência é conhecida como ambiguidade.

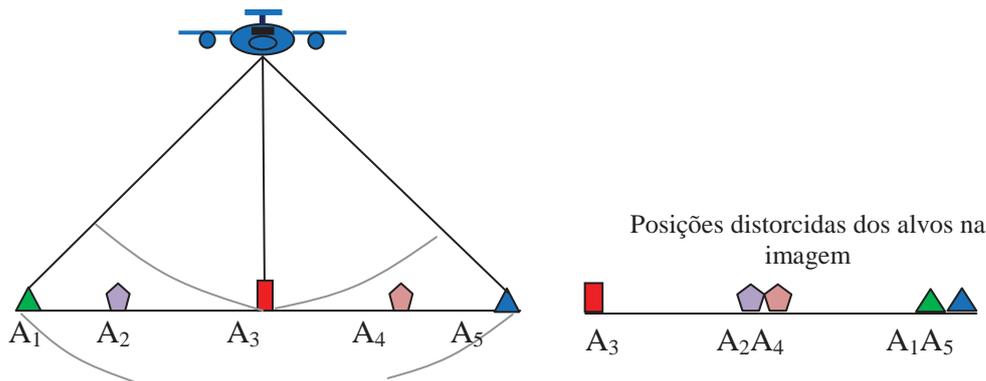


Fig. 4.3 Ilustração mostrando o motivo pelo qual não existem sensores de radar com visada vertical.

A configuração do envio de pulsos na direção de visada lateral, como é feito por todos os radares imageadores, é mostrada na Figura 4.4. A antena transmite os pulsos de micro-ondas em intervalos de microssegundos (cerca de 1.500 pulsos por segundo), que vão se propagar como frentes da onda em sucessivos incrementos de tempo (1 a 8). No tempo 6 o pulso transmitido (linha pontilhada azul) alcança a casa e a frente de onda de retorno (retroespalhada) tem início no tempo 7. No tempo 12 o sinal de retorno da casa alcança a antena e é registrado com esse tempo no gráfico de resposta da antena. No tempo 8 a frente de onda transmitida é refletida da árvore e o seu “eco” alcança a antena no tempo 16. Medindo-se eletronicamente o tempo de retorno do sinal, são determinadas as distâncias ou as posições (*range*) entre o transmissor e os dois objetos refletora. Como a casa retroespalha o pulso de onda de radar com intensidade maior do que a árvore, a intensidade da resposta do sinal registrado é mais forte.

Em todos os momentos são medidos os tempos de transmissão e de retorno dos pulsos, e por sabermos que a radiação eletromagnética, independente do seu comprimento de onda, se propaga à velocidade da luz, podemos calcular a distância de um objeto medida no plano inclinado (da antena ao alvo) usando a equação:

$$SR = \frac{ct}{2} \tag{eq. 4.1}$$

onde, SR = distância no alcance inclinado (*slant range*);
 c = velocidade da luz;
 t = tempo entre o pulso transmitido e recebido.

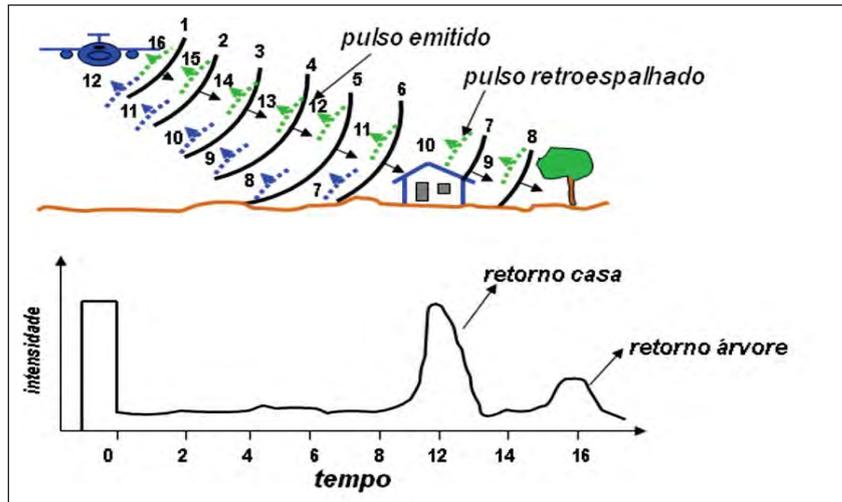


Fig. 4.4 Modelo de propagação de pulsos de onda por um radar de visada lateral e o retorno dos pulsos para a antena, após serem retroespalhados pelos alvos. (Adaptado de Lillesand *et al.*, 2008).

O tempo é medido pela fase de onda que tem a sua referência num ponto de partida relativo a um tempo arbitrário, no momento em que o pulso é transmitido. Como uma onda é um fenômeno cíclico, a fase é frequentemente medida em graus, onde 90° representa $\frac{1}{4}$ de um ciclo e 360° , um ciclo completo. Quando o pulso é transmitido registra-se o grau da fase no tempo $t = 0$, como mostra a Figura 4.5. A fase do sinal de retorno é comparada com a fase do sinal transmitido e o tempo de retorno do sinal é calculado, determinando-se assim, a posição do objeto no terreno.

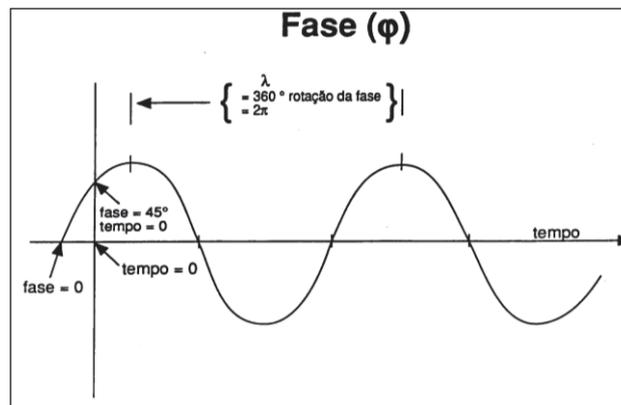


Fig. 4.5 Medida do tempo pela fase da onda no momento em que o pulso de radar é transmitido.

A antena funciona duplamente (*duplexer*), como uma fonte transmissora da radiação eletromagnética e como receptora da radiação de retorno. Uma chave liga a antena para emitir o pulso de alta potência, marca o tempo, e logo a seguir a desliga para registrar o sinal de retorno do pulso que foi enviado e o seu correspondente tempo de retorno. O sinal de retorno do terreno é bem mais fraco que o enviado e deve ser amplificado significativamente.

No sensor de radar a bordo do satélite SeaSat, o pulso transmitido tinha potência de 50 watts, enquanto a potência efetiva recebida pela antena de um objeto tendo uma seção de área transversal ao pulso de 10 m^2 era cerca de 10^{-17} Watts.

4.2 Polarização da Onda

As ondas corpusculares de fontes como o Sol são naturalmente despolarizadas. No radar, quando um pulso de energia é emitido pela antena, o vetor do seu campo elétrico é controlado por um cristal polarizador com eixo de transmissão situado na horizontal ou na vertical, para fazer vibrar a onda em uma direção horizontal (H) ou vertical (V). A onda é chamada de polarizada. A maioria dos pulsos é plano-polarizada, o que quer dizer que se o pulso foi emitido na direção H, o retorno do pulso também será registrado na direção H. Diz-se, então, que a polarização é HH. Da mesma maneira, tem-se a polarização plano-paralela VV. A polarização HH é mais aconselhada para as superfícies terrestres e a polarização VV para as superfícies (ondas) do mar. A Figura 4.6 mostra a configuração de polarização de um pulso horizontal e de um vertical.

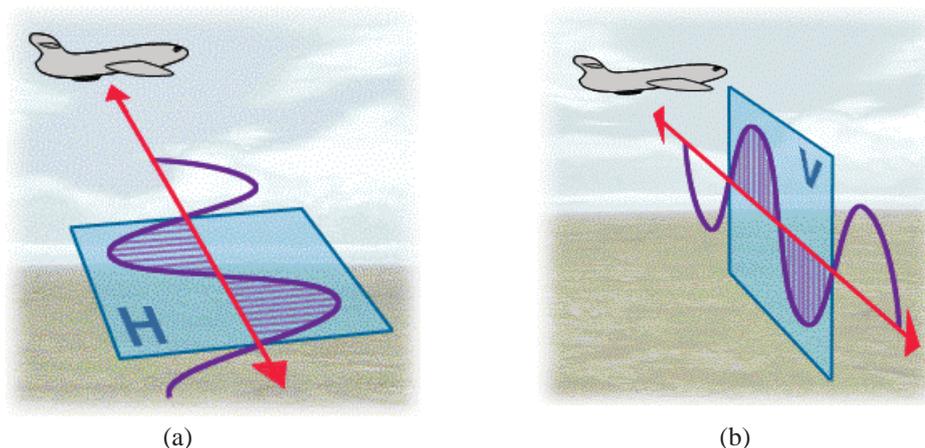


Fig. 4.6 Polarização do sinal de radar enviado pela antena nos planos horizontal (a) e vertical (b).

Quando o pulso atinge o alvo ocorre a despolarização, de modo que o sinal enviado pode retornar à antena com uma intensidade maior numa direção diferente da direção de polarização emitida. Por exemplo, um sensor que emite um pulso na direção H pode registrar o sinal de retorno na direção polarizada V. Nesse caso, tem-se o que se denomina de polarização cruzada HV. Se o sinal polarizado é emitido em V e o sinal de retorno é registrado pela antena em H, tem-se a polarização cruzada em VH. Atualmente, muitos sensores de radar como os sensores orbitais RADARSAT e PALSAR operam com as combinações de polarizações paralelas e cruzadas, possibilitando a aquisição de imagens de radar em quatro modos de polarização: HH, HV, VV e VH. Essa forma de imagens multipolarizadas aumenta as chances de discriminação dos materiais em função das variações de rugosidade da superfície. A vegetação, em particular, tende a mostrar diferentes respostas nas polarizações HH, HV (ou VH) e VV, por causa da despolarização da radiação

eletromagnética pelos múltiplos retroespalhamentos dos galhos e folhas, conforme ilustrado na Figura 4.7.

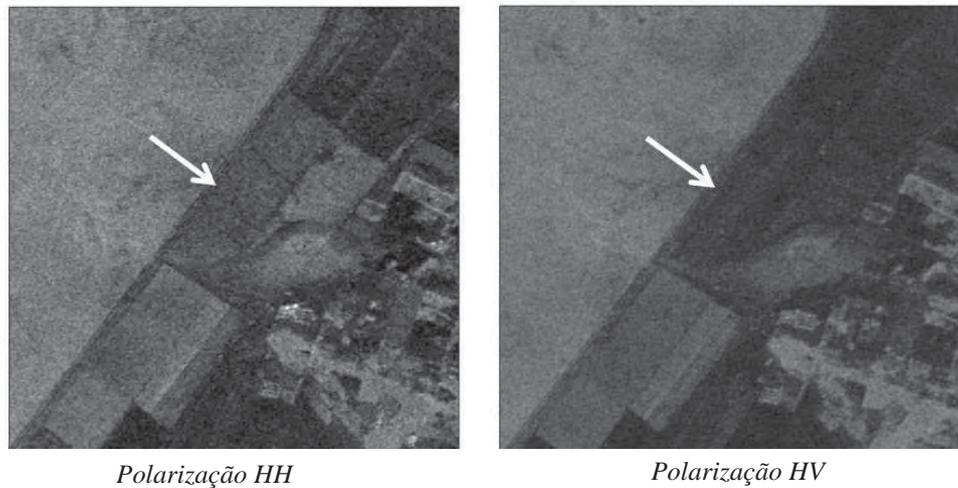


Fig. 4.7 Diferenças das tonalidades de cinza dos alvos de uma área agrícola vista em imagens de radar com duas diferentes polarizações, obtidas pelo satélite japonês ALOS PALSAR.

4.3 Geometria de Imageamento

Além da polarização da onda, no imageamento do terreno por radar aerotransportado ou a bordo de satélite, alguns parâmetros sobre o envio do pulso de radar pela antena são muito importantes na definição das características da imagem. Esses parâmetros relacionam-se com a geometria de imageamento formada entre os ângulos de envio do pulso de radar e as direções e rugosidades das superfícies dos alvos. São eles: direção de azimuth, direção de visada, ângulos de depressão, ângulo de visada e ângulos de incidência local (Figura 4.8).

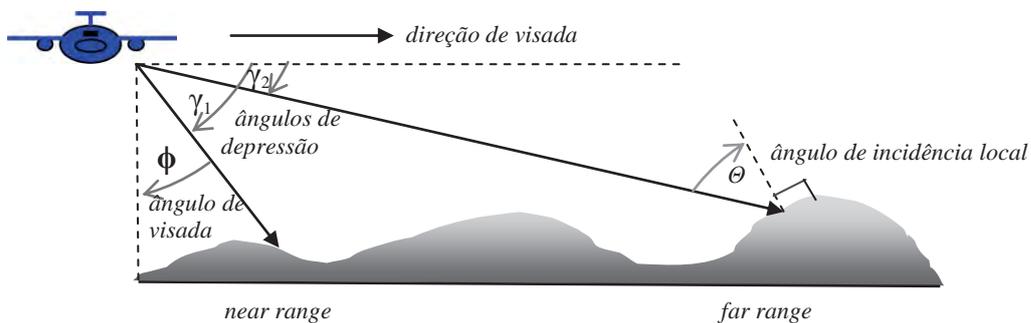


Fig. 4.8 Elementos geométricos da configuração de imageamento por radar.

- **Direção de azimuth.** É a direção de voo da plataforma, chamada de direção azimutal. O pulso de radar é enviado ortogonalmente à direção azimutal de voo, iluminando uma área no

terreno na forma de um lóbulo. Ao longo do lóbulo, a área inicial mais próxima à antena denomina-se de *near range* (alcance próximo) e a área mais distante é denominada de *far range* (alcance distante).

- **Direção de visada (alcance ou *range*).** A direção de visada ou direção de alcance é a direção de iluminação ao longo da qual o pulso de radar se propaga e é um parâmetro importante no imageamento dos sensores de radar de visada lateral. É importante para se ter uma melhor detecção do alvo, porque há uma relação direta entre a direção que o alvo está orientado no terreno, tal como a orientação de cristas ou alinhamentos de relevo, e a direção lateral que o pulso é emitido. A regra básica para se ter um melhor imageamento e um melhor contraste dos alvos é dirigir o pulso numa direção mais ortogonal possível à orientação dos alvos.

- **Ângulo de depressão (γ).** É o ângulo formado entre a linha de horizonte de voo e a linha que define a direção de visada. Note que na Figura 4.8 o ângulo de depressão varia do *near range* para o *far range*, mas geralmente considera-se como valor o ângulo médio de depressão.

- **Ângulo de visada (ϕ).** É o complemento do ângulo de depressão. É medido entre a linha vertical projetada da antena à superfície do terreno e a linha de visada.

- **Ângulo de incidência local (θ).** É o ângulo formado entre o pulso de radar e a vertical ao plano da superfície no ponto onde o pulso toca o terreno. Sendo assim, é dependente da declividade do terreno, não sendo um ângulo de valor fixo.

4.4

Resolução Espacial

As medidas de resoluções espaciais dos sensores de radar são bem mais complexas que as dos sensores multiespectrais e termais. O elemento ou célula de resolução espacial de um radar de visada lateral é controlado por dois parâmetros independentes:

i) o comprimento do pulso, que é determinado pela duração de tempo t que a antena emite os pulsos de energia;

ii) a largura angular do feixe do pulso enviado pela antena.

Como são parâmetros independentes, cada um deles determina uma resolução espacial, havendo duas medidas de resoluções espaciais: uma na direção de alcance ou direção de iluminação de propagação do pulso e outra na direção transversal ao lóbulo, que é a direção azimutal da linha de voo. São, respectivamente, denominadas de resolução em alcance (*range*) e resolução azimutal. Podem também ser ditas como resoluções longitudinal e transversal em relação ao lóbulo de iluminação. Na resolução em alcance calcula-se o comprimento do elemento de resolução e na resolução azimutal calcula-se a largura.

4.4.1

Resolução em Alcance (*Range*)

A resolução em alcance é medida ao longo da direção de iluminação do pulso de onda. Como pode ser visto na Figura 4.9, o valor calculado para a resolução espacial em alcance é proporcional ao comprimento do pulso τ (determinado pela duração de transmissão do pulso), multiplicado pela velocidade da luz (c) e inversamente proporcional ao co-seno do ângulo de depressão (γ). A equação para determinar a resolução em alcance no plano do terreno é dada por:

$$R_r = \frac{\tau \times c}{2 \cos \gamma}$$

eq.4.2

onde, R_r = resolução em alcance (*range*)
 τ = tempo de duração do pulso
 c = velocidade da luz
 γ = ângulo de depressão.

Na Figura 4.9 os alvos 1 e 2, situados na posição *near range* e os alvos 3 e 4, situados na posição *far range*, estão igualmente distanciados entre si, no terreno. Eles são iluminados pelo pulso de onda com um ângulo de depressão de 50° e de 30° , respectivamente. Considerando um comprimento do pulso $\tau = 0,1 \times 10^{-6}$ segundos, a resolução em alcance, calculada de acordo com a equação 4.2, será igual a 17,3 metros em *far range* e de 23,3 metros em *near range*. Supondo que no terreno os pares de alvos estejam separados de uma distância de 20 metros, somente os alvos 3 e 4 em *far range* serão resolvidos, isso é, vistos como dois alvos separados. Os alvos na posição *near range*, apesar de estarem mais próximos da plataforma, não serão resolvidos, formando uma imagem superposta.

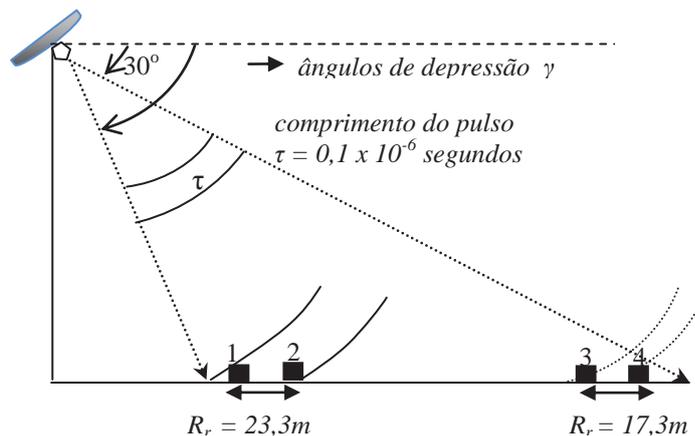


Fig. 4.9 Variação da resolução em alcance em função dos ângulos de depressão da antena de radar. (Adaptado de Lillesand *et al.*, 2008).

4.4.2 Resolução Azimutal

A resolução azimutal é medida na direção paralela à direção da linha de voo (direção azimutal). Há dois modos de se calcular a resolução azimutal: pelo tamanho da antena ou pela medida angular do feixe de onda transmitido pela antena.

Como se pode ver na Figura 4.10, em radares de abertura real (RAR) a largura do lóbulo é estreita em *near range* e mais larga em *far range*. Quanto mais estreita a largura do lóbulo, melhor é a resolução azimutal. A largura do lóbulo é diretamente proporcional ao comprimento de onda (λ) do pulso transmitido, isso é, quanto menor o comprimento de onda, mais estreito é o lóbulo. Inversamente, maiores comprimentos de onda resultam em lóbulos mais largos. Também se sabe que a largura do lóbulo é proporcional ao comprimento da antena (L). Quanto maior for o tamanho da antena, menor é a largura do lóbulo e, conseqüentemente, melhor a resolução azimutal. A equação matemática que relaciona o

comprimento de onda (λ) e o tamanho da antena (L) para se calcular a resolução azimutal (R_{AZ}) é dada por:

$$R_{AZ} = \frac{S \times \lambda}{L} \quad \text{eq. 4.3}$$

onde, S = distância da antena ao ponto no terreno no alcance inclinado.
 L = tamanho da antena

Usando a equação 4.3 para calcular a resolução dos objetos situados em *near range* e *far range* numa situação como a apresentada na Figura. 4.10 (a distância A a B é a mesma), podemos facilmente deduzir que a resolução azimutal em *near range* é melhor do que em *far range*, em razão das diferenças de distâncias dos alvos à antena medidas no plano inclinado S . As duas torres na posição em *near range* são individualizadas, ou resolvidas, enquanto que as duas torres na posição em *far range* não são resolvidas. Dessa forma, para melhorar a resolução azimutal ou se diminui a distância entre o radar e o alvo (diminui a altura de voo) ou se aumenta o tamanho da antena, o que nesse caso é um problema.

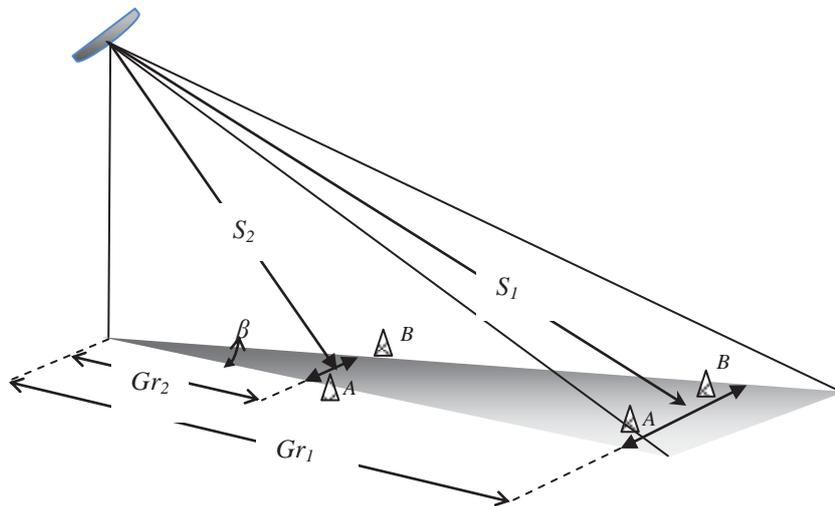


Fig. 4.10 Dependência da resolução azimutal em função das distâncias S medidas no plano inclinado, ou da abertura angular β do lóbulos de iluminação do feixe de radar.

Quanto à medida da resolução azimutal (R_{AZ}) em função do ângulo de abertura do feixe de radar, também é facilmente percebido na Figura 4.10, que quanto menor for a abertura angular β , mais estreito é o feixe de radar e melhor a resolução. O cálculo é feito pela seguinte equação, onde Gr é a distância no terreno:

$$R_{AZ} = Gr \times \beta \quad \text{eq. 4.4}$$

De acordo com a equação 4.4 as torres nos pontos A e B seriam resolvidas em Gr_1 , mas não em Gr_2 , ou seja, à distância Gr_1 elas resultam em sinais separados, enquanto à distância Gr_2 elas seriam vistas simultaneamente e superpostas.

Por outro lado, a abertura angular β do feixe é diretamente proporcional ao comprimento de onda (λ) do pulso transmitido e inversamente proporcional ao tamanho da antena (L):

$$\beta = \frac{\lambda}{L}$$

eq. 4.5

As relações entre as equações 4.3, 4.4 e 4.5 indicam que para se ter uma melhor resolução azimutal é preciso que sejam utilizadas antenas bastante longas, com dezenas ou centenas de metros, o que é inviável de se alojar em aviões ou satélites. Mas, um sensor imageador de radar com uma grande antena, só é possível com o uso de pequenos comprimentos de onda e restrito a voos de baixa altitude, o que limita o tamanho da área recoberta. A solução foi encontrar uma maneira de simular grandes antenas em antenas pequenas, capazes de serem transportadas por qualquer tipo de plataforma. Disso, resultou a mudança da tecnologia dos radares imageadores de abertura real (RAR) para os radares de abertura sintética (SAR).

4.5 Radar de Abertura Sintética

Os radares de abertura sintética, que são a tecnologia hoje utilizada para todos os sistemas de radares transportados em aviões ou satélites, empregam uma antena de tamanho físico pequeno que sintetiza uma antena de tamanho de centenas de metros. Isso é conseguido por modificações nos registros dos dados e por técnicas de processamento de sinais. Em detalhe, essa operação é bastante complicada. É suficiente mostrar que se usa o movimento da plataforma ao longo da linha de voo, para transformar uma antena pequena em uma matriz de antenas, que matematicamente são unidas para detectar o alvo (Figura 4.11). A antena real de tamanho pequeno é mostrada em diversas posições sucessivas ao longo da linha de voo, fazendo com que o alvo seja visto várias vezes (*looks*), como está representado à direita da Figura 4.11. Um objeto posicionado em *near range* é visto proporcionalmente por menores números de elementos de antena e quando na posição *far range* é visto por maiores números de elementos de antena. Essas posições sucessivas são tratadas matematicamente e eletronicamente, como se elas fossem simplesmente elementos de uma única antena longa, e isso resulta em uma resolução azimutal constante ao longo do lóbulo do feixe de radar, independente da distância dos alvos à antena.

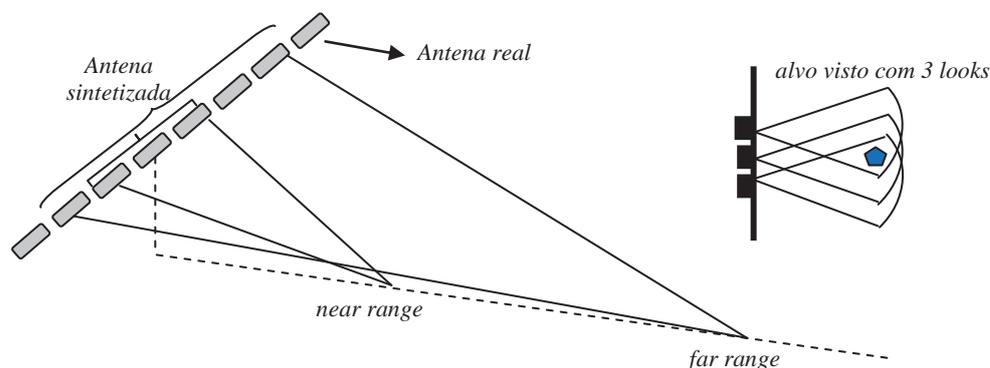


Fig. 4.11 Múltiplos elementos de uma antena (*looks*) que sintetizam uma grande antena. Em *near range* três elementos de antena e em *far range* seis elementos. (Adaptado de Lillesand *et al.*, 2008).

4.6 Distorções Geométricas

A visada lateral das imagens de radar é como uma visada oblíqua. A imagem é originalmente construída pelo registro dos sinais medidos no plano inclinado, o que causa uma deformação dos alvos, comprimindo ou achatando as formas dos objetos que se situam mais próximos à antena. Custosos processamentos corrigem esse tipo de distorção, transformando a imagem do plano inclinado (*slant range*) para o plano horizontal no terreno. Outros dois tipos de distorção, de caráter mais complexo, também ocorrem devido às medidas das distâncias dos objetos ao sensor serem feitas no plano inclinado. *Layover* (inversão de relevo) e *foreshortening* (encurtamento de rampa) são dois tipos de distorções. Para entendê-los, basta observar a relação da inclinação da frente de onda com a inclinação da encosta frontal do relevo, como são apresentados na Figura 4.12. No exemplo, os morros são de relevos simétricos. Considerando-se que os radares utilizam medições do tempo de retorno do sinal, a duração de tempo que o feixe de radar leva para iluminar a frente de uma encosta, de sua base ao topo, é o fator que determina a sua posição e a sua dimensão na imagem.

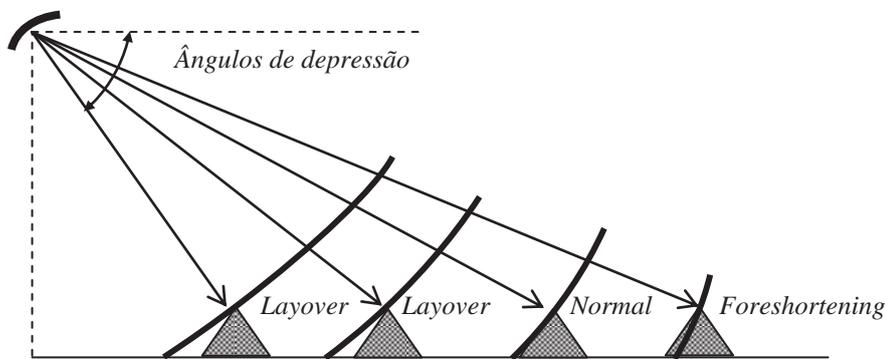


Fig. 4.12 Ilustração das distorções geométricas em imagens de radar conhecidas como *layover* (inversão de relevo) e *foreshortening* (encurtamento de rampa). A primeira posição que a frente da onda toca o ponto no terreno é função da inclinação da frente da onda com a inclinação das faces do relevo. À exceção da posição normal, as demais indicam distorções na forma dos objetos que serão vistos na imagem de radar.

Na inversão de relevo (*layover*) a frente de onda atinge primeiro o topo do morro para depois atingir a base. Portanto, o sinal de retorno do topo do morro chega primeiro ao sensor. Como a imagem de radar determina a posição do alvo em função do tempo de ida e de retorno do sinal, e sabendo que a imagem é uma superfície em duas dimensões, o topo do morro aparecerá na imagem antes da base. Observe na Figura 4.12, que a inversão de relevo ocorre nos morros que estão mais próximos do sensor, ou seja, com ângulos de depressão maiores. Por isso, o *layover* é mais intenso em imagens de radar de satélites. O efeito dessa distorção é mostrado na Figura 4.13, onde o relevo aparece na forma de “V” com alto retorno do sinal (tons claros), mascarando por completo a forma real do relevo. Quando a frente de onda incide normal à face do relevo, não ocorre deformação.

O encurtamento de rampa (*foreshortening*) se expressa como uma compressão ou encurtamento da encosta frontal, relativo à encosta dorsal do relevo. Esse efeito ocorre quando o ângulo de incidência local é menor que o ângulo de iluminação, mas maior que zero. Isso faz com que a face de encosta voltada para a antena apareça na imagem em tons bem claros, indicando forte potência do sinal de retorno e não por causa de qualquer outra característica do relevo. Com a diminuição do ângulo de incidência local, a geometria faz com que a extensão da vertente (topo para base) diminua, aumentando assim, a intensidade

do encurtamento da rampa. Na Figura 4.14 as encostas frontais aparecem como faixas estreitas e alongadas, com tonalidades claras, enquanto as encostas dorsais aparecem com tonalidades escuras. Essas faixas alongadas e claras correspondem ao encurtamento de rampa. Se por um lado a visada inclinada traz esses inconvenientes, por outro lado, ela é a razão principal das imagens de radar serem consideradas como imagens muito eficientes para a análise das texturas de relevo. O raio de onda inclinado ilumina as faces frontais das encostas de relevo e geram sombras nas faces opostas. Essa condição de iluminação gera pares iluminado/sombreado (claro/escuro) que são responsáveis por criarem uma percepção visual tridimensional do relevo.

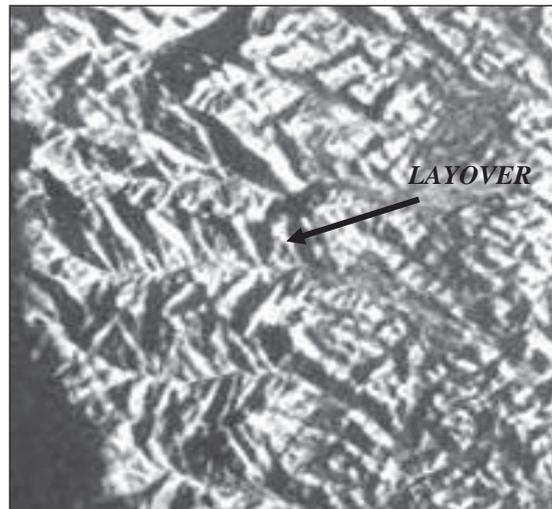


Fig. 4.13 Formas em V de relevo como se fossem artefatos que surgem nas imagens de radar pelo efeito de *layover*. (Copiado de: Lima, 1995 estampa 4 pág. 32).

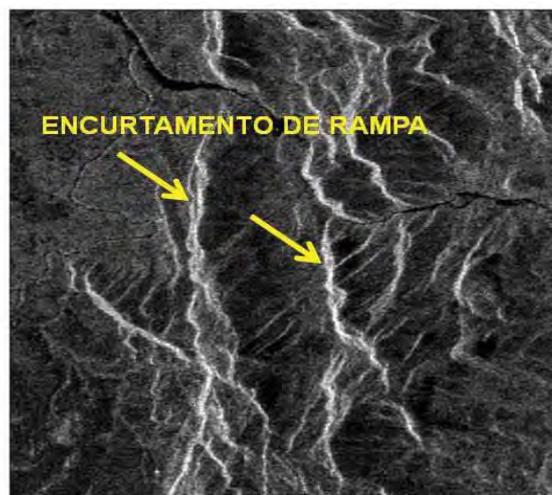


Fig. 4.14 Feições de encurtamento de rampa (faixas estreitas, alongadas e claras) em uma imagem de radar do satélite japonês ALOS PALSAR da região de Chapada dos Veadeiros, Goiás.

4.7 Ruído Speckle

A qualidade radiométrica das imagens de radar é afetada por um parâmetro instrumental que diz respeito à coerência de onda. Luz coerente é aquela formada por ondas de mesma frequência, fase e direção. Por isso, a luz solar é incoerente. No radar, a onda emitida é altamente coerente. Devido a essa propriedade, um tipo de ruído denominado *speckle* está sempre associado aos sensores de radar. O *speckle* é um ruído multiplicativo que é proporcional à intensidade do sinal recebido. Em uma célula de resolução no terreno pode existir um número muito grande de alvos difusores, aleatoriamente distribuídos, de tal forma que esses alvos podem interferir uns aos outros, construtivamente e destrutivamente. A interferência destrutiva causa o cancelamento do sinal refletido e a interferência construtiva a sua soma, fazendo aparecer variações súbitas na intensidade da imagem, que é o ruído *speckle* (Figura 4.15). O efeito visual na imagem é um padrão granulado do tipo sal e pimenta que degrada a qualidade visual da imagem para fins de interpretação (Figura 4.16). O *speckle* pode ser reduzido com múltiplas visadas (*looks*), porém, o aumento de *looks* causa degradação na resolução espacial. Outra maneira é o uso de filtros adaptativos como forma de reduzir a presença do referido ruído.

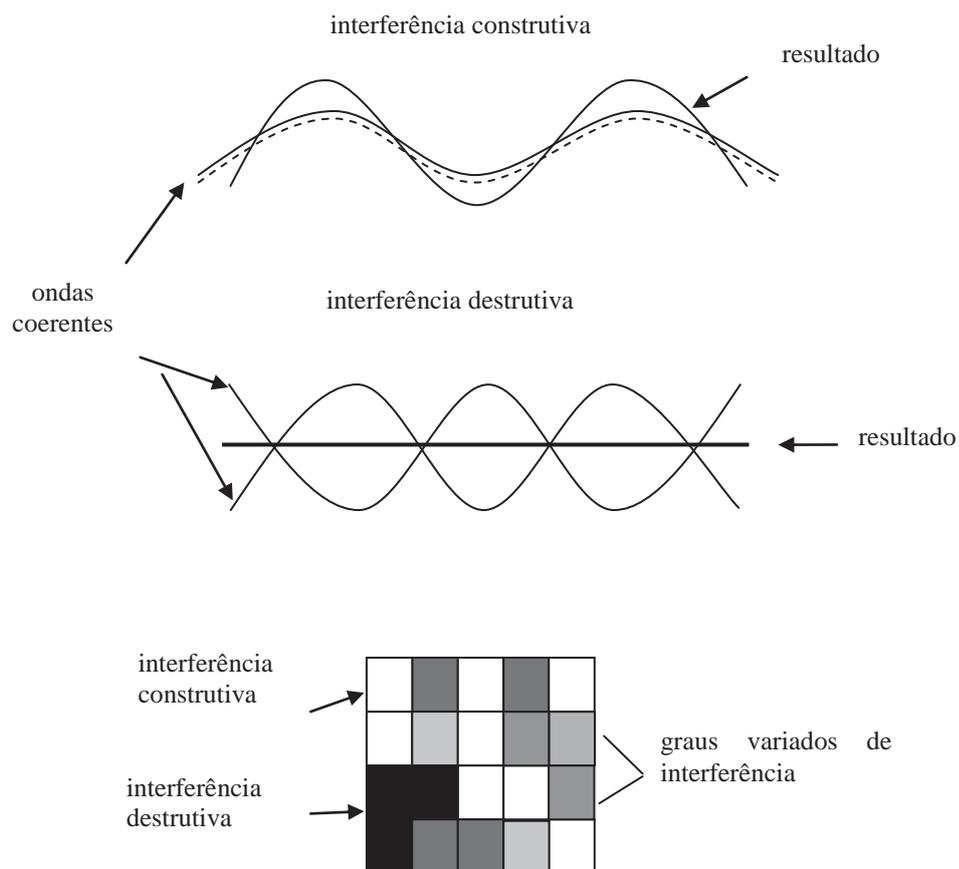


Fig. 4.15 Interferência construtiva e destrutiva da onda coerente de radar que é retroespalhada aleatoriamente pelos múltiplos alvos presentes em uma célula de resolução do pulso.



Fig. 4.16 Presença do ruído *speckle* (aspecto de sal e pimenta em toda a imagem) em uma cena do satélite canadense RADARSAT-1 da região de Lagoa dos Patos, RS.

4.8

Interação do Pulso de Radar com as Superfícies dos Objetos

Em termos de conteúdo de informação do dado as imagens de radar diferem das imagens ópticas e termais. Isso tem a ver com a natureza dual da radiação eletromagnética: onda e energia. Segundo o modelo corpuscular da radiação eletromagnética, onde $E = hc/\lambda$, a energia contida nas micro-ondas é muito pequena. Por ser muito pequena é insuficiente para interagir ao nível dos átomos e moléculas dos materiais e assim possibilitar a obtenção de informações sobre a composição do material. Consequentemente, as informações extraídas das imagens de radar são quase exclusivamente dependentes de uma relação entre o tamanho da onda com as variações texturais e estruturais das superfícies do terreno. Em outras palavras, as informações estão relacionadas com as formas dos objetos, podendo-se inferir muito pouco sobre as suas composições. Essa interação é classificada de interação macroscópica, como visto no capítulo 1. Por isso, em termos de método de interpretação, particularmente na interpretação geológica do relevo, as imagens de radar se aproximam muito dos métodos aplicados para as fotos aéreas (Paradella *et al.*, 2005). Alguns parâmetros do sensor e da geometria de imageamento são importantes nesse processo de interação macroscópica do pulso de radar. Os principais são: o comprimento da onda; a direção de visada; e o ângulo de incidência local do pulso no terreno.

4.8.1

Em Relação ao Comprimento de onda

O comprimento de onda é importante para se determinar uma propriedade macroscópica do terreno, que no sensoriamento por radar é denominada de rugosidade da superfície. Uma superfície pode ser lisa ou rugosa. Numa imagem de radar, uma superfície rugosa é um refletor difuso que retroespalha o sinal em todas as direções, que é a condição

mais comum para os alvos terrestres. Para isso acontecer, o tamanho da onda deve ser menor que as variações de altitude da superfície. E uma superfície é classificada de lisa quando não há o retorno do sinal retroespalhado em direção à antena. Nesse caso, a superfície tem um comportamento especular e ocorre quando o tamanho da onda é muitas vezes maior que as variações de altitude da superfície. Os espelhos de água calmos são exemplos típicos de superfície lisa.

Na Figura 4.17, tomada por um sensor de radar com comprimento de onda de 23,5 cm, o lago (A) aparece em tons de cinza escuro, pois por ser uma superfície lisa causa uma reflexão especular da radiação eletromagnética incidente. Os demais alvos (B) exibem retroespalhamentos difusos e as variações em cinza identificam as variações de intensidade de retorno do sinal dos diferentes alvos presentes na cena. Um caso particular de radiação difusa é a reflexão de canto (C). Alvos como edificações, orientadas perpendicularmente à radiação incidente, refletem quase que toda a radiação incidente de volta para a antena. Esses alvos são conhecidos como refletores de canto e o fenômeno é conhecido como *double bouncing*.



Fig. 4.17 Imagem de radar da banda L (comprimento de onda de 23,5 cm) e polarização HH do satélite japonês ALOS PALSAR, mostrando alvos especulares (escuros; A) e difusores (tons de cinza claros; B). Em C, um tipo especial de alvo difusor conhecido como refletor de canto (no caso particular dessa imagem, composto por edificações que refletem praticamente toda a radiação incidente de volta para a antena).

Pode-se medir a rugosidade de uma superfície em termos de altura h das pequenas variações da altitude da superfície. A medida h possui escala centimétrica, o que significa que as variações topográficas do relevo sempre serão maiores dos que os comprimentos das ondas usados em radar, ou seja, são superfícies difusoras. A Figura 4.18 mostra os critérios para se determinar como se comportam as superfícies e os respectivos cálculos para classificá-las como lisa (reflexão especular), intermediária (reflexão difusa média) e rugosa (reflexão

difusa forte). Na figura foram considerados um comprimento de onda de 5,6 cm e um ângulo de depressão de 40°.

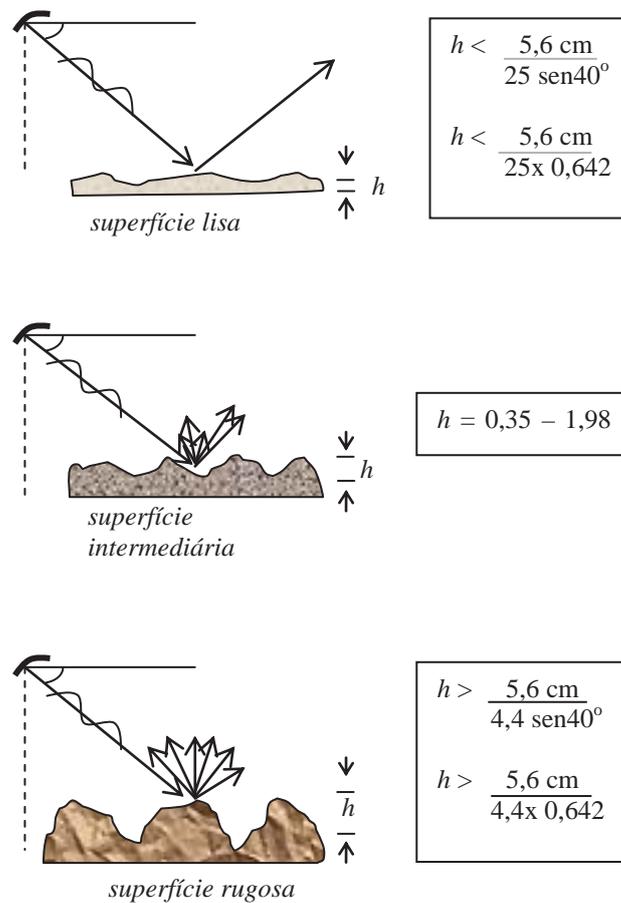


Fig. 4.18 Critérios para determinação de superfície lisa e com rugosidades intermediária e alta.

Convém salientar que a obtenção de estimativas de rugosidade de terreno no campo, para interpretar ou validar imagens de radar, não é uma tarefa simples. Alguns estudiosos têm utilizado suportes de madeira, nos quais se desenham grades regulares centimétricas com espaçamento conhecido. Esse suporte é colocado a alguns centímetros de profundidade em relação à superfície do terreno, nivelado e fotografado. O desvio-padrão da irregularidade do terreno (unidades em centímetros) corresponde à rugosidade do terreno.

Na Figura 4.19 é mostrada outra possibilidade de medir a rugosidade do terreno. Trata-se de um aparato de alumínio composto de dois conjuntos de 100 chumbinhos redondos com um centímetro de diâmetro, que ao serem dispostos no terreno conseguem reproduzir as irregularidades da superfície (no caso desse aparato, irregularidades ao longo de um perfil de 1 metro de comprimento).

Ainda com relação ao tamanho da onda, há uma particularidade quando se trata de coberturas vegetais densas. Os sinais retroespalhados pelas árvores têm dois componentes: reflexão de superfície (das copas) e reflexão de volume, que é a que interage com os componentes internos (galho e troncos). Estabelece-se que quando maior for o comprimento da onda, maior é a penetração na vegetação. As bandas P teriam assim, um grande poder de penetração em vegetação densa, podendo trazer informações do solo subjacente.



Fig. 4.19 Aparato de alumínio construído pelo Departamento de Agricultura dos Estados Unidos (USDA) para estimar rugosidade de um terreno ao longo de um perfil de um metro. Foto: E. E. Sano.

4.8.2 Em Relação à Direção de Visada

A direção de visada do sensor, ou a direção de iluminação ao longo da qual o pulso de radar se propaga, é um parâmetro crítico, principalmente, para estudos geológicos, porque há uma relação direta da direção de visada com a direção das estruturas geológicas. Ela é também importante para qualquer tipo de alvo que tenha uma orientação dominante no terreno, como linhas de plantio de culturas agrícolas ou direções de arruamentos urbanos. A Figura 4.20 mostra claramente esse fato. Observe como as feições lineares de relevo, que representam fraturas e falhas nas rochas, aparecem com maior densidade na imagem tomada na direção de iluminação para leste. Para isso, a regra básica para obter uma imagem com bom contraste acerca da orientação dos alvos, é dirigir o pulso numa direção de visada mais ortogonal possível à orientação dos alvos. Por exemplo, uma crista de relevo orientada na direção N-S terá as suas formas de relevo mais bem evidenciadas, quando a iluminação dos feixes de radar tiver uma orientação E-W ortogonal à direção das cristas. Se a iluminação é ortogonal à crista, a face voltada frontalmente ao pulso será intensamente iluminada e deverá ter um alto retorno do sinal, registrando um tom de cinza claro na imagem. Ao contrário, a face oposta será bem menos intensamente iluminada ou quase nada iluminada (sombreada), não havendo quase nada de retorno de sinal, e o registro será de uma imagem com tom de cinza escuro ou preto. É gerado, portanto, um par claro/escuro, que é a condição ideal para que o olho humano perceba melhor a dimensão em 3-D, conforme mencionado anteriormente.

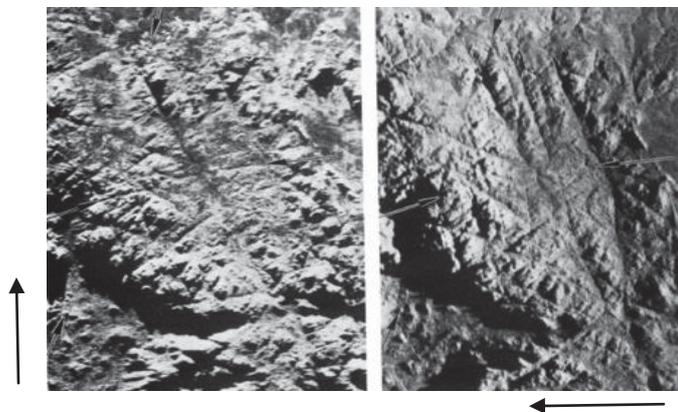


Figura. 4.20 Realce das direções estruturais dos lineamentos de relevo em função da direção de iluminação. (Disponível em: [Http://rst.gsfc.nasa.gov/Sect8/_4html](http://rst.gsfc.nasa.gov/Sect8/_4html)).

4.8.3

Em Relação ao Ângulo de Incidência Local

O terceiro parâmetro que controla a interação macroscópica é o ângulo de incidência local, formado pela inclinação do pulso de onda e a linha perpendicular à superfície do terreno, em cada ponto do terreno onde a onda incide. Em um relevo não plano o ângulo de incidência local descreve a relação entre o pulso de radar e a declividade superficial das encostas de relevo. Serão inúmeros os ângulos de incidência, não havendo condições e nem a necessidade do intérprete saber os valores de cada ângulo de incidência. Um diagrama dessa relação é apresentado na Figura 4.21. Os diferentes ângulos de incidência local que ocorrerão ao longo da encosta resultarão em diferentes intensidades de retorno do sinal para o sensor, que na imagem se apresentarão em diferentes tons de cinza, e que dá ao intérprete a noção da forma textural da encosta. Quanto menor for o ângulo de incidência local, mais intenso será o retorno do sinal.

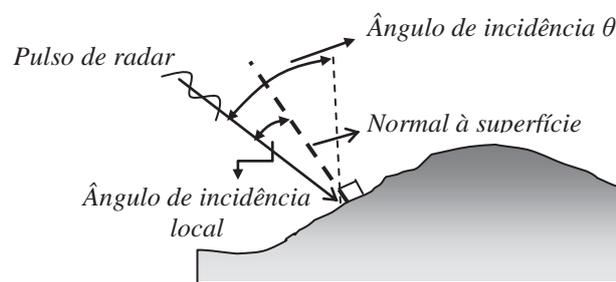


Fig. 4.21 Relação entre a inclinação do pulso da onda e a normal à superfície do terreno onde a onda incide, como forma de medir o ângulo de incidência local.

4.9

Constante Dielétrica

Há uma condição única para que os alvos tenham um retorno forte de sinal, independente das condições ideais de tamanho da onda, da rugosidade da superfície ou do ângulo de incidência. É quando um alvo tem uma alta constante dielétrica. Constante dielétrica corresponde à capacidade dos materiais em formar dipolos na presença de um campo elétrico externo e em armazenar e conduzir energia elétrica. Os alvos naturais, para terem altas constantes dielétricas, precisam conter água livre na sua estrutura (umidade), isso porque a água tem uma alta constante dielétrica, próxima de 80. Rochas e solos, em suas condições naturais (secos), possuem uma baixa constante dielétrica, entre 3 a 8. Quanto maior for a constante dielétrica do material, maior é a interação do campo elétrico do pulso de micro-ondas com a molécula de água e mais intenso é o retorno do sinal. Há dessa forma, uma relação direta de proporcionalidade entre a constante dielétrica e a intensidade do pulso de micro-ondas refletido. Por isso, as vegetações fotossinteticamente ativas que armazenam água em suas estruturas foliares internas apresentam tons de cinza muito claros nas imagens de radar (Figura 4.22). Solos úmidos respondem da mesma maneira, o que torna a imagem de radar uma excelente opção para a separação de solos úmidos e secos. Uma área com solos úmidos aparece com tons de cinza claros na imagem de radar, enquanto nas imagens da faixa óptica aparece com tons escuros devido à forte absorção da radiação eletromagnética nos comprimentos de onda de alta energia. Entretanto, estimar umidade de solo por meio de imagens de radar, que pode ser importante para diversas aplicações como modelagens

hidrológicas, não é uma tarefa simples por causa das interferências das condições de rugosidade e de cobertura vegetal e, portanto, tem sido objeto de pesquisa por parte de diversos autores (e.g., Moran *et al.*, 2004).



Fig. 4.22 Imagem de radar R99B aerotransportado (comprimento de onda de 23 cm, multipolarizada), mostrando as matas de galerias em tons de cinza claros devido à constante dielétrica alta da vegetação.

Essa propriedade da constante dielétrica explica a extraordinária imagem de radar adquirida pelo SIR-A (*Shuttle Imaging Radar*) em novembro de 1981. A parte da cena colorida na Figura 4.23 é uma subimagem Landsat de uma parte do deserto do Arizona. Pelo fato de as areias secas terem uma baixa constante dielétrica, as ondas de radar conseguiram penetrá-las, cerca de 3,5 metros de profundidade, o que é mostrado pela imagem de radar na faixa central em tons de cinza. O que se vê são paleocanais subsuperficiais que se encontram soterrados pela areia e, portanto, invisíveis na imagem Landsat. Esse exemplo é sugestivo para se pensar nas possibilidades do uso de imagens de radar como meio para a identificação de paleocanais que possam ter interesses prospectivos, como para depósitos aluvionares antigos, por exemplo, de cassiterita, bastantes conhecidos dos geólogos brasileiros. O sucesso disso está condicionado à existência de solos bem secos e de alta porosidade.

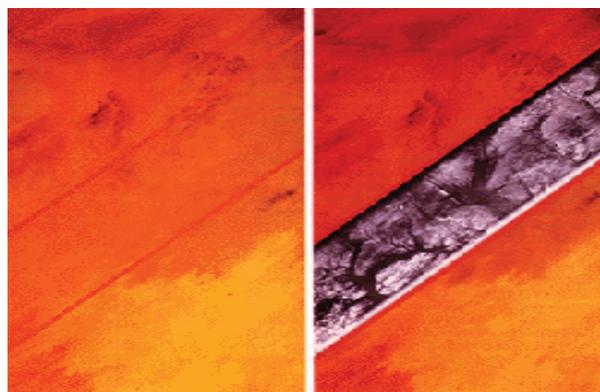


Fig. 4.23 A imagem à esquerda composição colorida Landsat da região de Flagstaff, Arizona, Estados Unidos. No centro da imagem da direita, uma imagem de radar mostrando paleocanais de drenagem sob manto de areia seca. Devido à penetração que o pulso tem em areias secas com constante dielétrica baixa, foi possível identificar a presença de paleocanais. (Disponível em: <http://pubs.usgs.gov/gip.desert/remote.clima.giv>).

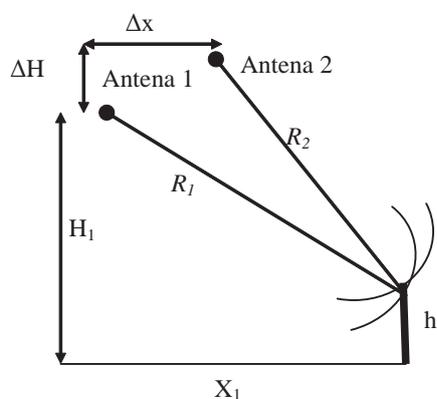
4.10 Interferometria

Atualmente, existem diversas maneiras de se obter modelos de elevação da superfície terrestre que podem ser usados para vários fins, incluindo como um dos mais importantes a construção de cartas topográficas. Os modelos topográficos tradicionais, geralmente de alto custo, vêm cedendo espaço aos métodos mais automatizados como o sistema de posicionamento global (GPS) e à interferometria de radar de abertura sintética - InSAR. O interesse pelo método interferométrico teve início há mais de três décadas (Graham, 1974), e sem dúvida, pode-se debitar esse interesse à difusão do uso das imagens de radar aerotransportado e à proporcionada pelos programas de sensoriamento remoto orbitais JERS-1 e RADARSAT-1, iniciados na década de 1990.

Em sensoriamento remoto, a construção de “modelos de elevação de terreno” remonta aos princípios da fotogrametria, tendo como base a diferença de paralaxe resultante da observação dos pontos do terreno a partir de dois diferentes ângulos de visada (foto estereoscópica). O mesmo princípio de paralaxe é a base do método interferométrico. A diferença é que o método interferométrico por radar é dado pela interseção entre as circunferências que contêm o ponto P no espaço, cada uma centrada em uma antena de radar (usa-se duas antenas), e o plano vertical que contém a antena e o ponto P.

Uma das questões básicas dos modelos de elevação produzidos por imagens interferométricas é a sua precisão. Zebker *et al.* (1994) avaliaram imagens de radar do satélite JERS-1 para a geração de DEM e sugeriram a possibilidade de um mapeamento altimétrico global com imagens deste satélite, o que viria a ser feito em 2000 pelo ônibus espacial *Endeavour* na missão *Shuttle Radar Topography Mission – SRTM*.

A interferometria InSAR consiste na obtenção de complexas imagens registradas em diferentes tempos por duas diferentes imagens. As duas imagens da mesma cena são geradas simultaneamente por cada uma das antenas alojadas na plataforma, avião ou satélite, com uma pequena diferença de ângulo de visada. Para isso, elas são montadas em posições um pouco diferente entre elas. Cada pixel das imagens é representado por um número complexo que contém a amplitude do sinal de retorno e a sua fase. A Figura 4.24 mostra, esquematicamente, a geometria do módulo interferométrico. A diferença de fase $\Delta\phi$ é dada pela equação 4.6, em função da diferença dos percursos R_1 e R_2 . Por sua vez, R_1 e R_2 podem ser obtidos em função da posição da plataforma em relação à posição do alvo, por meio de relações de triângulo retângulo, o que resulta nas equações 4.7 e 4.8.



$$\Delta\phi = -\frac{4\pi}{\lambda} (R_2 - R_1) \quad \text{eq. 4.6}$$

$$R_1 = \sqrt{x_1^2 + (H_1 - h)^2} \quad \text{eq. 4.7}$$

$$R_2 = \sqrt{(x_1 - \Delta x)^2 + (H_1 + \Delta H - h)^2} \quad \text{eq. 4.8}$$

Fig. 4.24 Geometria do modo InSAR.

FORMATOS DAS IMAGENS DE SENSORIAMENTO REMOTO

5

Paulo Roberto Meneses

5.1 Imagem Digital

As imagens de sensoriamento remoto devem ser vistas como uma forma de documentos que representam, em escala e sobre um plano 2D, os acidentes e as feições naturais e artificiais da superfície terrestre, a partir da medição de um processo físico da radiação eletromagnética. A energia da radiação eletromagnética conduz de forma analógica a informação sobre os objetos e no sensor um conversor analógico/digital converte essa informação em um valor digital, codificado por uma unidade denominada de pixel. A forma digital do dado é que possibilita o uso de computadores para processar as imagens, com o objetivo principal de representar porções bem definidas do espaço terrestre, utilizando-se de processamentos matemáticos, estatísticos e probabilísticos dos dados. Os limites do espaço são configurados pelos pixels, os quais, como veremos, estão organizados na disposição de linhas e colunas. Embora estejamos falando de valores numéricos (imagem digital), os limites de qualquer porção da imagem não são matemáticos. Não são limites como o que vemos em uma carta topográfica, esses sim, limites matemáticos, geralmente definidos por meridianos e paralelos. Então, percebemos que há uma clara distinção entre a representação dos dados de uma imagem com a representação dos dados do espaço terrestre pelas cartas topográficas. Daí a razão de nos referirmos à localização dos objetos em uma imagem por meio de coordenadas espaciais dos pixels (linhas e colunas). A imagem de sensoriamento remoto, qualquer que seja ela, não possui um sistema de referência de projeção cartográfica. Por isso, é aconselhável conhecer algumas características do formato dos dados das imagens, antes de se iniciar o processamento dos dados.

Como foi apresentado nos capítulos anteriores, a imagem de um sensor é obtida pela varredura do terreno em linhas sequenciais, cada linha sendo amostrada por uma área unitária (pixel). O sensor registra os pixels no formato de uma grade retangular ou quadrada, e o valor do pixel correspondente ao valor de radiância, emitância ou de retroespalhamento dos alvos é convertido no sensor para um valor digital discreto e finito. O valor digital do pixel é uma média dos valores de radiância, emitância ou retroespalhamento, dos diferentes alvos que podem estar contidos no pixel. Os pixels podem ser pixels puros (um só objeto) ou pixels misturas. Em terra, estações terrestres de rastreamento gravam o sinal digital transmitido do satélite por telemetria, e em laboratórios a imagem no formato *raster* é produzida para distribuição aos usuários.

Os algoritmos de processamento veem esse formato como uma matriz de dados composta por milhares de linhas e colunas, na qual o valor de cada célula da matriz é definido pelas coordenadas que o pixel ocupa na matriz e pelo seu valor digital. Genericamente, pode-se definir qualquer imagem como sendo uma função bidimensional representada por $f(x,y)$ (Gonzales e Woods, 1992). Quando x,y e os valores de amplitude f são quantidades discretas (números inteiros), a imagem é uma imagem digital. Nas imagens de sensoriamento remoto x,y referem-se às coordenadas espaciais da linha e coluna do pixel e o valor de f em qualquer ponto x,y é a medida da energia radiante refletida, emitida ou retroespalhada.

Na forma digital, o valor da função $f(x,y)$, é representado por um número digital quantizado em bits, que assume somente valores inteiros positivos, como é mostrado na Figura 5.1. Uma imagem $f(x,y)$ possível de ser processada por computadores e exposta na tela do monitor, tem de ser digitalizada tanto espacialmente como em amplitude de níveis de brilho (ou cinza). Digitalização de coordenadas x,y refere-se à “amostragem de imagem”, e digitalização de amplitude refere-se à “quantização de nível de brilho”.

Ao olharmos para a Figura 5.1 podemos perguntar: por que não executar o processamento em tipos de dados fracionários (*floating-point*) que pode representar qualquer valor? O problema é o espaço em disco. Maior o intervalo de valores dos dados, mais espaço em disco é preciso. Por exemplo, tipo de dados em *byte* usa somente um único byte para representar o valor de cada pixel. Tipos de dados em *integer* usam 2 bytes para cada pixel, enquanto *floating-point* usa 4 bytes. Assim, *floating-point* consome duas vezes mais espaço em disco do que o tipo *integer*.

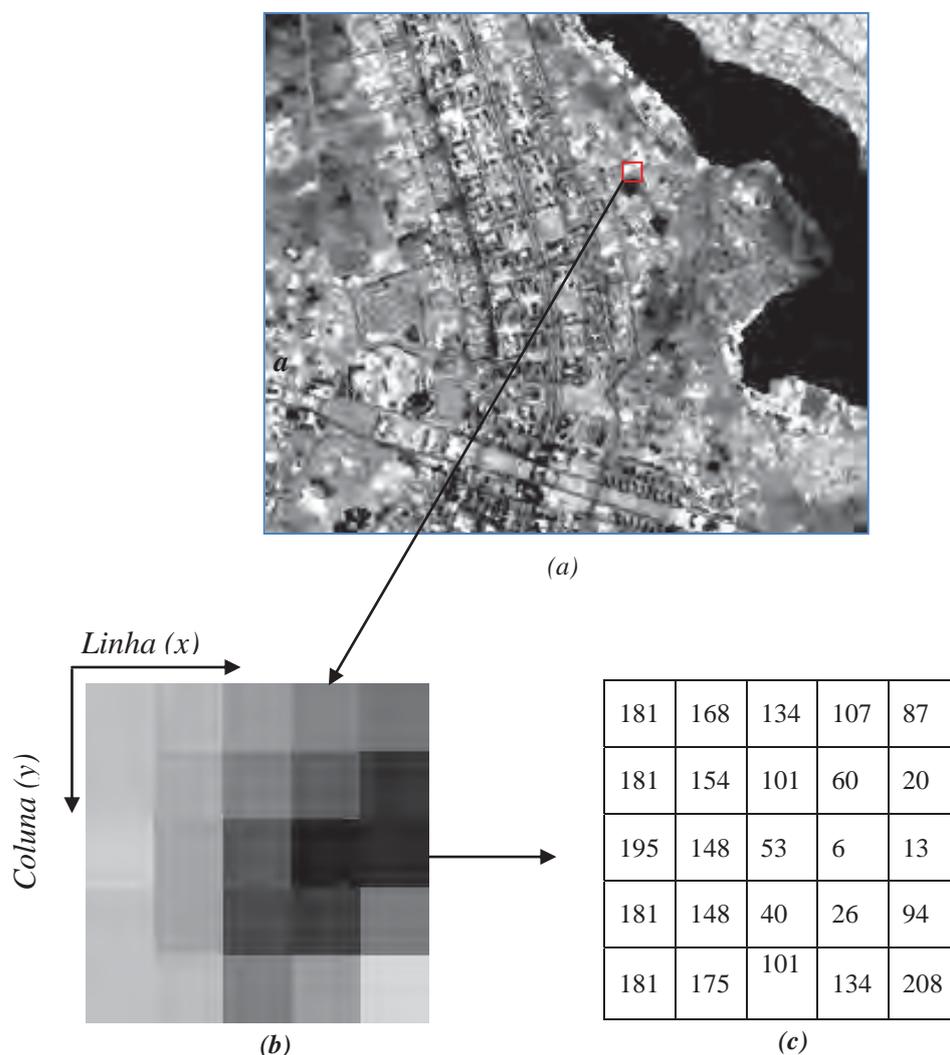


Fig. 5.1 Imagem digital (a) com área em zoom de grupo de pixels em valores de cinza (b) e correspondentes valores digitais (c).

Nas imagens de sensoriamento remoto o primeiro pixel da imagem situa-se na posição do canto extremo superior esquerdo. Assim, as linhas são contadas de cima para baixo e as

colunas da esquerda para a direita. Essa convenção é utilizada, pois a maioria das imagens é obtida no sentido de órbita descendente do satélite, de norte para sul. Nesse caso, o topo da imagem indica o sentido para norte. Quando uma imagem é obtida no sentido ascendente da órbita, para visualizá-la no monitor e orientá-la para norte, faz-se uma rotação na imagem.

O tamanho de uma imagem é uma expressão do tipo: *linha x coluna (byte) x número de bandas*.

5.2

Formatos de Arquivos

Os programas comerciais de processamento de imagens como ENVI, ER-MAPPER, PCI, SPRING (domínio público), IDRISI, ERDAS IMAGINE, e demais, usam o formato de dados *raster* consistindo de um arquivo binário (base dois) que contém os dados da imagem, acompanhado de um pequeno arquivo texto que descreve algumas informações sobre os dados da imagem (*header*). Nos seus formatos nativos, eles aceitam dados (imagens) em *byte*, *signed e unsigned integer*, *long integer*, *floating point*, *integer*, *64-bit*, *complex ou double complex*, e outros. Em geral, os dados *raster* são armazenados no disco em fluxo binário de *bytes* em três tipos básicos de formatos: bandas sequenciais (BSQ), bandas intervaladas por linhas (BIL) ou bandas intervaladas por pixels (BIP).

BSQ (*Band SeQuencial*) é o formato mais simples, onde cada linha dos dados é seguida imediatamente pela próxima linha na mesma banda espectral. Esse formato é ideal para acesso espacial de qualquer parte de uma banda da imagem. Por isso, é preferida se o interesse é trabalhar com bandas individuais de grandes áreas.

BIL (*Band Interleaved by Line*) armazena a primeira linha da primeira banda, seguida pela primeira linha da segunda banda, e assim por diante, intervalada pelo número de bandas. É preferida para alguns tipos de processamentos mais pesados, como a transformação de imagens digitais para imagens de reflectância. Esse formato assegura um compromisso de desempenho entre processamento espacial e espectral, sendo recomendado.

BIP (*Band Interleaved by Pixel*) armazena o primeiro pixel de todas as bandas em ordem sequencial, seguida pelo segundo pixel para todas as bandas, e assim por diante, intervalada ao número de pixels. É preferida se o interesse é trabalhar com todas as bandas de uma área relativamente pequena.

Para serem expostas no monitor de vídeo nos três canais de cores, vermelho, verde e azul, as imagens são processadas por três hardware *Look-Up Tables* (LUT), que é uma forma de dispor os dados em um arranjo ou arranjos associados, que em termos de ganho de tempo de processamento é significativo. Sua funcionalidade é criar uma tabela de novos valores para a imagem, que consiste em converter os números digitais inteiros da imagem para inteiros de níveis de cinza de cada banda, conforme a expressão abaixo.

$$LUT(nd)_{(0,255)} = NC$$

eq. 5.1

5.3 Formatos de Salvamento

O salvamento de imagens é um procedimento corriqueiro durante uma seção de trabalho de processamento de imagens, e a forma de salvar um dado é um procedimento controlado pelo *software* em uso. O importante é conhecer em que tipos de formatos as imagens podem ser salvas, quando é preciso transferi-las para outros *software*.

A maioria dos programas de processamentos de imagens de sensoriamento remoto assegura ao usuário o salvamento das imagens nos formatos nativos de outros programas. Por exemplo, uma imagem processada no programa ENVI, pode ser criada com um arquivo de saída nos formatos nativos ArcView Raster, ER Mapper, ERDAS IMAGINE, PCI, IDRISI, SPRING, ou nos formatos para visualização de imagens. A Tabela 5.1 mostra os *software* de uso mais comuns. Na tabela, o arquivo descritor contém informações que permitem ler os dados da imagem no formato do arquivo nativo.

Tabela 5.1 Principais *software* de processamento de imagens.

<i>Software</i>	Formato Nativo	Arquivo descritor	Fabricante
IDRISI	.RST	.RDC	Clark Labs
ENVI	.IMG	HDR, TFW	RSI – Research Systems Inc.
MULTISPEC		.STA	Purdue Research Foudantion
ERDAS	.LAM, .IMG		Leica Geosystems
SPRING	.GRB		INPE - Instituto Nacional de Pesquisas Espaciais
ARCVIEW	.BIL		ESRI – Environmental Systems Research Institute
PCI	.PIX		Geomatic
ERDAS ER-MAPPER	.ERS		ERDAS – Earth Resource Data Analysis System

Além desses formatos nativos de programas de processamento de imagens, há opções de salvamento nos formatos comuns para visualização de imagens. A escolha do formato deve garantir que se preserve o máximo possível a imagem a ser salva, em termos de qualidade e quantidades de cores, contrastes, tamanho máximo do arquivo, e outros.

Os formatos mais usados são dos tipos JPEG, BMP, TIFF, PNG. Ramos (2000) destaca algumas informações referentes a cada um desses arquivos, que em resumo são apresentadas abaixo, segundo o referido autor:

JPEG (*Joint Pictures Expert Group*). É um tipo de arquivo para armazenamento de imagens com esquema de 24 bits. Isso significa que esse formato aceita 16,8 milhões de cores. Devido à limitação da visão humana em distinguir, no máximo, entre três a cinco mil cores, são subtraídas algumas informações das cores, preservando somente o que o olho humano pode enxergar. Esse processo é conhecido como compressão, mas não há perda da qualidade da imagem, com a vantagem de gerar um arquivo não muito grande.

PNG (*Portable Network Graphics*). É uma versão concorrente do JPEG com esquema de cores de 24 bits, 16,8 milhões de cores. A vantagem sobre o formato JPEG é que a compressão dos dados é mais eficiente, não causando perda de qualidade a cada salvamento, o que possibilita maior fidelidade à imagem original.

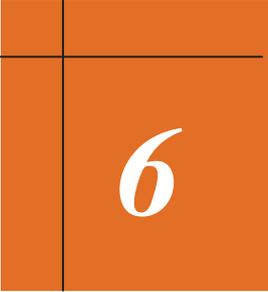
BMP (*Bit MaP*). Desenvolvido para aplicações no sistema Windows é um formato muito simples, com mínimas possibilidades de erro na interpretação dos arquivos. Como não há compressão de dados, a qualidade da imagem é a melhor possível, mas em compensação o

tamanho dos arquivos BMP é muito grande. Utiliza o esquema de 24 bits de cor para imagens com 16 milhões de cores simultâneas, 16 bits para imagens com 65.536 cores e 8 bits para imagens com 256 cores.

TIFF (*Tagged Image File Format*). Foi desenvolvido como uma tentativa de se criar um padrão para imagens geradas por equipamentos digitais (ex. escaneador). É um formato capaz de armazenar imagens em preto e branco, em escalas de tons de cinza e em paletas de cores com 24 ou 32 *emphbits*. Tem a vantagem de ser reconhecido por qualquer tipo de programa de processamento de imagens. O formato TIFF é baseado em entidades lógicas (campos TIFF), cada uma consistindo de uma etiqueta (Tag), cada um com um significado específico, que descreve atributos e parâmetros dos dados de uma imagem.

ASCII (*American Standard Code for Information Interchange*). Muitas vezes pode ser solicitado ao usuário o salvamento de arquivos que não são imagens, mas de dados obtidos durante o processamento, e que podem ser armazenados na forma de um arquivo texto. O formato ASCII é usado para essa função. É um tipo de formato binário de codificação de caracteres (letra, número ou símbolo) que são representados por oito bits. O sistema totaliza 128 caracteres. São exemplos de arquivos ASCII, gráficos, coordenadas x,y ou x,y,z de dados, cabeçalhos de imagens, anotações, e outros.

DISTORÇÕES E CORREÇÕES DOS DADOS DA IMAGEM



6

***Paulo Roberto Meneses
Tati de Almeida***

6.1 O que é Processamento de Imagens

Um segmento importante do processamento digital de imagens consiste na execução de operações matemáticas dos dados, visando as suas transformações em imagens de melhores qualidades espectrais e espaciais e que sejam mais apropriadas para uma determinada aplicação. O que significa que o processamento de imagens de sensoriamento remoto é orientado para cada tipo de problema. Por exemplo, uma técnica que é eficaz na remoção de ruídos presentes em uma imagem, da qual interessa apenas a sua textura e não tanto a identificação de bordas, não é eficaz para identificar as altas frequências que caracterizam as mudanças de padrões em áreas urbanas.

O processamento de imagens é configurado por algoritmos especializados, que disponibiliza para o usuário a aplicação de uma grande variedade de técnicas de processamento. Os algoritmos tratam matematicamente a imagem como um dado diretamente relacionado ao processo físico que o criou. Porém, a representação e o processamento matemático da imagem não é 100% a representação do mundo real. Por isso, sempre caberá ao usuário e não apenas ao computador, a análise e a interpretação dos dados contidos na imagem.

O formato matricial das imagens facilita operações matemáticas e estatísticas para se analisar o grande volume de dados que possuem as imagens de sensoriamento remoto. Praticamente, todos os *software* especializados em processamento de imagens de sensoriamento remoto dividem as técnicas de processamento digital em dois tipos básicos: *realce e classificação*, às quais antecede uma fase de pré-processamento, cujo objetivo é corrigir preliminarmente os erros que os dados originais possam apresentar. Não há um fluxo de processamento pré-definido que o usuário seja obrigado a fazer. Por exemplo, o usuário que deseja gerar um mapa temático necessitará de informações precisas da localização dos alvos que ele deseja investigar e por isso, as correções das distorções geométricas da imagem são imprescindíveis. Outro usuário que queira extrair dos dados as informações espectrais dos alvos para identificar a natureza de suas composições, estará mais preocupado em corrigir as distorções causadas pela atmosfera. Ainda outro usuário poderá partir diretamente para uma classificação não supervisionada, a fim de rapidamente, ter uma avaliação da distribuição das classes de alvos dominantes na área. Por isso, a Figura 6.1 deve ser vista como um quadro sucinto das principais técnicas de processamento que os *software* dispõem, e não como um fluxo de processamento a ser seguido. Os usuários de sensoriamento remoto sempre devem ter em mente que no processamento de imagem o bom desempenho dos resultados obtidos em uma área, não necessariamente, pode ser reproduzível para outras.

As técnicas de pré-processamento são, essencialmente, funções operacionais para remover ou corrigir os erros e as distorções introduzidos nas imagens pelos sistemas sensores devidos a erros instrumentais (ruídos espúrios), às interferências da atmosfera (erros radiométricos) e à geometria de imageamento (distorções geométricas).

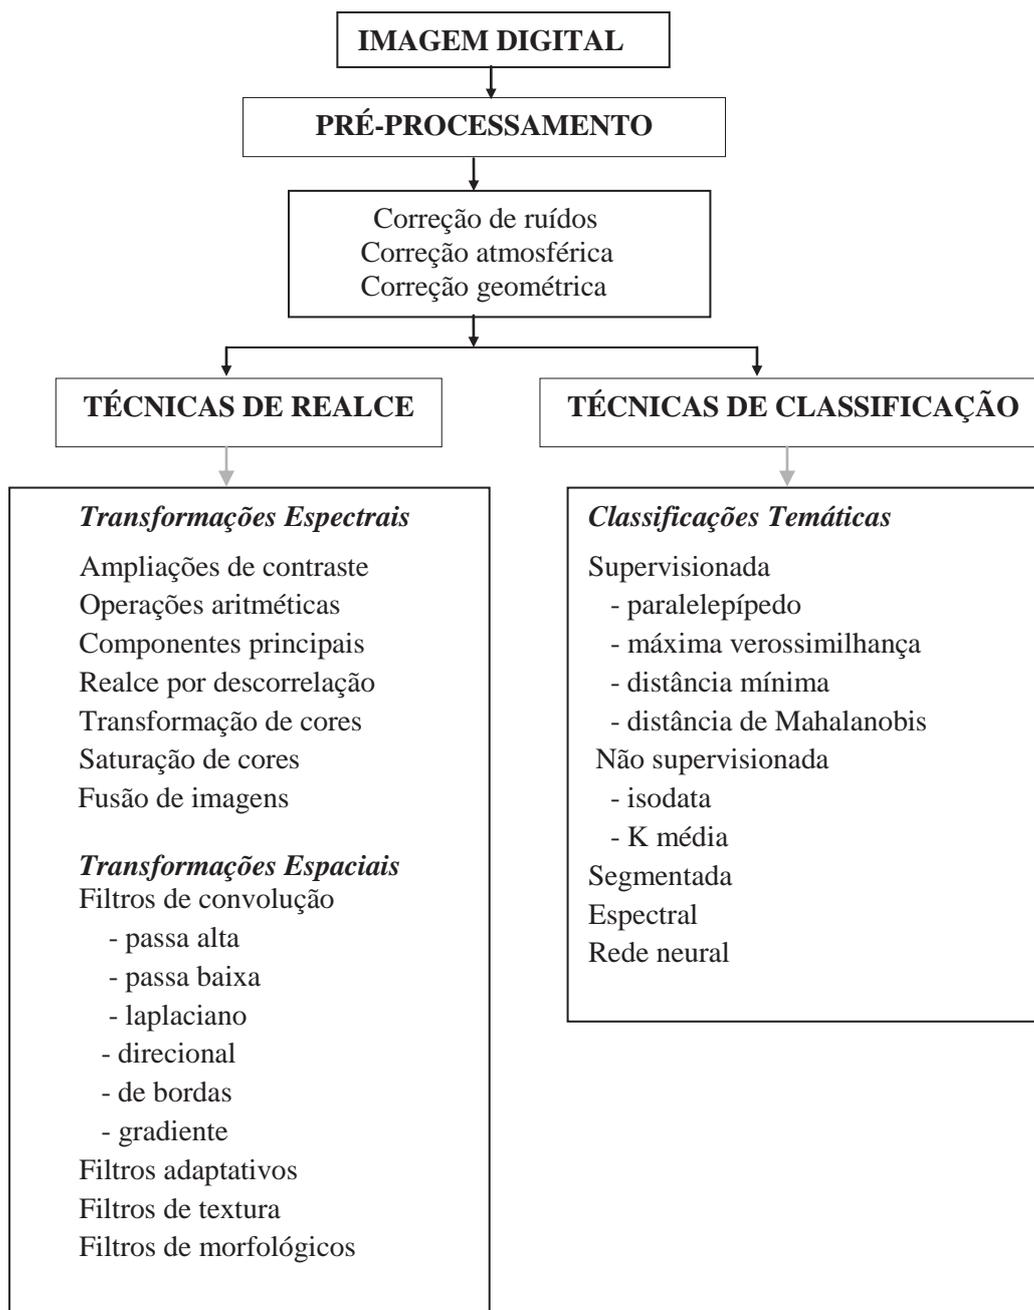


Fig. 6.1 Apresentação das principais técnicas de processamento de imagens segundo um modelo geral de divisão dos tipos de processamento.

As técnicas de transformação no domínio espectral e espacial listadas na Figura 6.1 têm a função básica de preparar para o analista uma imagem de alto contraste visual, a fim de facilitar a interpretação da cena, poder explorar com melhores recursos toda a informação contida na imagem e extrair informações de interesse e/ou relacioná-las com parâmetros estatísticos, num processo que objetiva otimizar ao máximo a análise dos dados, em termos de eficiência, tempo e custo. Os dados são trabalhados em função dos valores digitais de cada pixel individual (domínio espectral) ou em função dos conjuntos de pixel vizinhos (domínio espacial). Os resultados são novos arranjos de valores digitais representando melhoramentos

na qualidade visual das imagens. As técnicas de classificação temática tratam a imagem por meio de complexos modelos estatísticos e probabilísticos, a fim de gerar um mapa temático com uma participação bastante reduzida do intérprete no processo do mapeamento.

No conjunto, essas técnicas de processamento são um grande esforço para tornar mais acessível, numa forma interativa homem-máquina, a extração de informações que no mínimo seriam difíceis de serem obtidas com o uso de métodos clássicos de interpretação. Desde o início do sensoriamento remoto orbital, muitos pesquisadores perceberam essa dificuldade, devido à maioria dos materiais ou alvos mostrar baixos contrastes espectrais de reflectância, emitância e retroespalhamento da radiação eletromagnética. Somente com cuidadosos processamentos computacionais pode-se extrair a informação no limite mais ideal de análise. Além do mais, se considerarmos o volume de dados que integra uma cena correspondente a um conjunto de multibandas, haverá centenas de milhões de dados registrados, e não há como imaginar uma análise sem os recursos de processamento.

Este capítulo inicia a discussão das técnicas de processamento de imagens apresentando, primeiramente, os métodos de pré-processamento para a correção das imagens. Cada capítulo que segue abordará as técnicas de processamento seguindo, aproximadamente, o quadro mostrado na Figura 6.1.

6.2 Pré-processamento de Imagens Digitais

Muitos dos problemas identificados nas fotografias aéreas ocorrem de formas bastante semelhantes com as imagens digitais de sensoriamento remoto. São várias as fontes que geram esses problemas, a maioria devido aos erros e defeitos que os sensores possam apresentar ao longo de sua vida útil, e por perdas de estabilidade da plataforma que aloja o sensor. Mas há fontes de erros que independem da plataforma ou mau funcionamento do sensor. A atmosfera é uma dessas fontes externas de erros, que pode gerar com intensidades diferentes, severas distorções nos dados das imagens. No conjunto, os erros ou distorções que as imagens estão sujeitas, vão se apresentar nas deformações de escala, incorreções nas posições espaciais dos pixels, perda de contraste entre os alvos ou registros incorretos dos valores digitais dos pixels.

Quando o intérprete, analista ou usuário utiliza a imagem para obter a informação que procura, frequentemente é necessário corrigir a imagem, ou compensá-la dos erros que apresenta. Algumas dessas correções são realizadas antecipadamente à distribuição das imagens, enquanto outras cabem, exclusivamente, à decisão do usuário.

As correções dessas distorções fazem parte do conjunto de funções de processamento que se denomina de pré-processamento. As técnicas de pré-processamento são assim denominadas, porque elas não visam transformações das imagens, as quais têm, como principal objetivo, melhorar a qualidade visual da cena. As correções dos diferentes tipos de erros que a imagem pode apresentar são modeladas de acordo com o tipo da estrutura dos erros, conhecendo-se qual é a fonte de distorção. Constitui uma importante etapa de processamento, porque nos processamentos subsequentes, tais como as transformações de realces espectrais, essas imperfeições seriam também realçadas.

A ordem da correção da imagem depende dos objetivos do trabalho ou da pesquisa que o intérprete propôs fazer, podendo iniciar pela correção radiométrica, atmosférica ou geométrica, ou todas serem realizadas. Por isso, os itens a seguir não devem ser vistos como uma sugestão de ordem de pré-processamento.

6.2.1 Eliminação de Ruídos

As imagens podem conter erros aleatórios de pixels ou erros coerentes de linhas de pixels que, normalmente, se mostram como pixels ou linhas com valores saturados (claros), ou sem sinal (escuros). É reconhecido como um erro do valor digital do pixel. São denominados de ruídos e, tipicamente, esses ruídos espúrios e imprevisíveis são decorrentes de erros instrumentais. Nem sempre essas formas de ruídos são percebidas pelo analista, e por isso devem ser corrigidas, antecipadamente, nos laboratórios de produção de imagem, antes de ser distribuídas para o usuário. Quando isso não acontece cabe ao usuário processar a eliminação do ruído usando as opções de algoritmos que os *software* de processamento de imagem oferecem. Os ruídos, normalmente, se apresentam em três formas: como linhas ruidosas, pixels ruidosos ou conjunto sistemático de linhas ruidosas, que se denomina de *striping*.

Linhas ruidosas consistem na má qualidade de pixels ao longo de uma linha ou mesmo da perda total de informação ao longo de toda uma linha ou de algumas linhas, devido a problemas diversos, como o de saturação do detector na medida do sinal, falha na aquisição dos dados ou erro na transmissão ou registro de dados em Terra. É um tipo de ruído aleatório, isso é, não tem um padrão definido. A linha ruidosa é reconhecida na imagem pela aparência de uma linha escura, sinal perdido, ou clara, sinal saturado, como mostra a Figura 6.2. Filtros de mediana poderiam ser usados para remover esse tipo de ruído, mas há o inconveniente de eles alterarem muitos outros pixels da imagem.

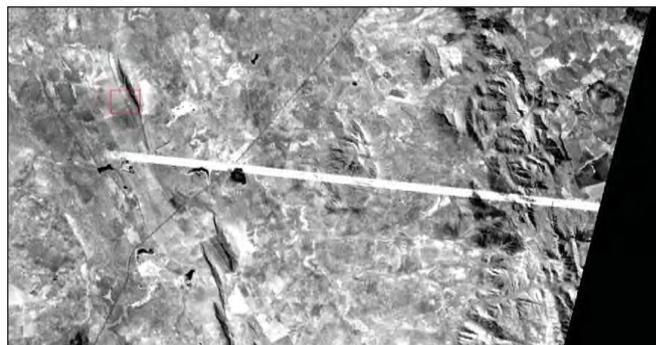


Fig. 6.2 Linhas ruidosas por saturação máxima do sinal.

O método mais usado para corrigir ou recompor linhas de pixels ruidosos é substituir a linha ruim pelo valor médio dos pixels correspondentes das linhas anterior e posterior. Se aceita isso porque na natureza os alvos possuem uma alta correlação espacial, portanto com alta probabilidade de repetição de suas propriedades espaciais e espectrais, por grandes extensões de áreas no sentido longitudinal e transversal das linhas.

Pixels ruidosos isolados podem ser substituídos pelas médias dos vizinhos mais próximos, desde que haja segurança que os pixels vizinhos sejam pixels bons. O procedimento de correção segue a mesma suposição para corrigir as linhas ruidosas.

Em ambos os casos, deve-se calcular as médias das linhas superior e inferior, ou as médias dos pixels vizinhos em torno do pixel ruidoso individual. O algoritmo deve ser capaz de, antes de efetuar a correção, testar realmente se existe ruído presente na imagem. O esquema abaixo demonstra esse procedimento para a correção de um pixel ruidoso. Para se fazer o teste, verifica-se a diferença das médias dos pixels vizinhos, comparando-as com o valor do pixel ruidoso.

ND ₁	ND ₂	ND ₃
ND ₄	ND	ND ₆
ND ₇	ND ₈	ND ₉

$$\text{Média 1} = (ND_1 + ND_7 + ND_3 + ND_9)/4$$

$$\text{Média 2} = (ND_2 + ND_8 + ND_4 + ND_6)/4$$

$$DIF = [Md_1 - Md_2]$$

Se $|ND - MD_1|$ ou $|ND - MD_2| > DIF$, então $ND' = MD_2$ ou $ND' = MD_1$

Se $|ND - MD_1|$ ou $|ND - MD_2| < DIF$, então $ND' = ND$

O *striping* consiste num tipo de ruído coerente, cujo efeito é o aparecimento de faixas horizontais regularmente espaçadas nas imagens, dando a aparência de uma persiana que mostra abruptas diferenças de níveis de cinza, originadas por diferenças das respostas do conjunto de detectores de uma banda. Por exemplo, as bandas do visível e do infravermelho refletido do sensor ETM do satélite Landsat 7 são constituídas, cada uma, de dezesseis detectores rigorosamente iguais que varrem simultaneamente dezesseis linhas no terreno. Caso um ou alguns desses dezesseis detectores, por algum motivo descalibra-se, as suas respostas em termos de valores de radiância serão notavelmente diferentes para aquelas linhas, em relação às outras linhas imageadas pelos outros detectores. A Figura 6.3 mostra o efeito desse tipo de ruído. Para a correção de *striping* é assumido que os detectores de uma banda produzam sinais estatisticamente similares, ou seja, que não mudem significativamente a sua média e desvio padrão dentro de um espaço equivalente às linhas imageadas pelo conjunto de detectores. Um dos detectores é escolhido como referência e a média (μ) e o desvio-padrão (σ) são calculados. As médias e os desvios-padrões de cada um dos outros detectores são linearmente ajustados aos valores do detector de referência. Por ser uma distorção severa, normalmente, o *striping* é corrigido nos laboratórios de produção de imagens. A transformação para o detector i , segundo Showengerdt (1997), tem a formulação abaixo, que é aplicada a todos os pixels daquele detector.

$$DN_i^{novo} = \frac{\sigma_{ref}}{\sigma_i} (DN_i - \mu_i) + \mu_{ref}$$

eq. 6.1

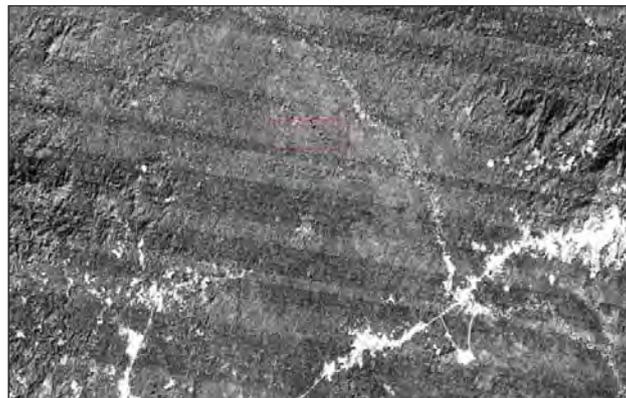


Fig. 6.3 Imagem com a presença de faixas de linhas ruidosas conhecidas como *striping*, causadas pela descalibração dos detectores de uma banda.

6.2.2 Correção Atmosférica

Mais comprometedor do que os ruídos aleatórios ou coerentes, são as degradações que alteram radiometricamente a imagem por completo. A fonte de erro dessa degradação ou distorção radiométrica é a atmosfera, cuja intensidade de efeitos é dependente do comprimento de onda, da data de imageamento e da trajetória da radiação. A atmosfera afeta a radiância medida em qualquer ponto da imagem, de duas maneiras aparentemente contraditórias. Primeiro, ela atua como um refletor, adicionando uma radiância extra ao sinal que é detectado pelo sensor. Segundo, ela atua com um absorvedor, atenuando a intensidade de energia que ilumina o alvo na superfície. Quando a atenuação é acima de um valor, a transparência da atmosfera torna-se opaca em determinados comprimentos de onda, impossibilitando a obtenção de imagens. Portanto, quando temos uma imagem, nela devemos apenas verificar a degradação que pode ter sido causada pelo espalhamento atmosférico, avaliando quanto de radiação foi adicionada ao pixel e que sabemos não ser proveniente do alvo. Na maioria das vezes, os efeitos do espalhamento atmosférico são sempre o de diminuir o contraste entre os alvos presentes na imagem. Nesse caso, o valor do sinal detectado pelo sensor pode ser expresso como a equação 6.2.

$$L_{sensor} = \frac{\rho ET}{\Pi} + L_{atm}$$

eq. 6.2

onde, L_{sensor} = radiância total medida no sensor

ρ = reflectância do alvo

E = irradiância sobre o alvo

T = transmitância da atmosfera

L_{atm} = radiância (aditiva) da atmosfera

Diante de qualquer circunstância, a radiância medida pelo sensor difere da radiância real do material, devido ao efeito aditivo do espalhamento dos raios causados pelos aerossóis, gases e moléculas d'água da atmosfera (L_{atm}). O efeito aditivo é o que se denomina de *haze* e que reduz o contraste da imagem. Desde que as condições atmosféricas são um processo dinâmico de rápida mutação, é fácil imaginar que de acordo com as suas mudanças haverá uma correspondente variação na reflectância dos materiais da superfície terrestre, de imagem para imagem ou entre imagens de datas diferentes. Quando essas condições atmosféricas são acentuadas, a análise das informações contidas nas imagens é imprecisa.

No esquema da Figura 6.4, à semelhança do que vimos na Figura 1.11, são mostradas as várias maneiras pela qual o espalhamento atmosférico influencia as imagens coletadas de alta altitude. O fluxo de radiação solar ao atravessar a atmosfera pode ser parcialmente espalhado, antes que atinja a superfície terrestre (*a*). Como consequência a superfície terrestre é irradiada diretamente pelo fluxo solar e indiretamente pelo fluxo espalhado do céu. Quando a área irradiada do alvo reflete a radiação na direção do campo de visada do sensor, ao atravessar de volta a atmosfera, ela é novamente espalhada (*c*). A essa radiação se soma o fluxo espalhado da atmosfera (*b*) que não é proveniente do alvo da superfície. Esse tipo de radiação fornecerá ao sensor uma contribuição adicional à reflectância que nada tem a ver com o alvo em si. A contribuição também poderá provir de pontos da superfície terrestre, fora do campo de visada do sensor (*d*). Essas contribuições adicionais reduzem o contraste da cena, retirando alguns detalhes mais finos e causando certa confusão na discriminação entre os alvos presentes na cena.

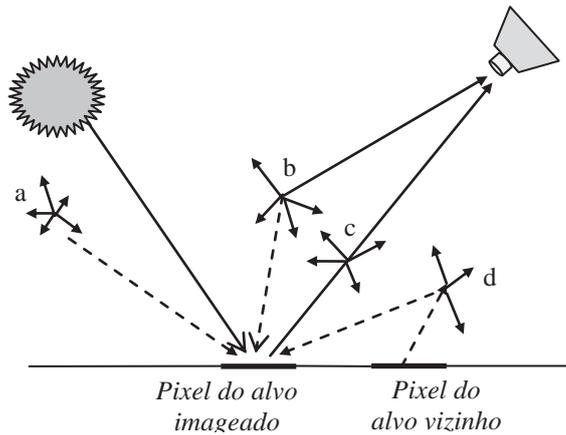


Fig. 6.4 Modos de espalhamento da radiação pela atmosfera, contribuindo com o aumento da reflectância do alvo que chega ao sensor.

Torna-se óbvio que para uma interpretação confiável das imagens de satélite é necessário remover os efeitos que a atmosfera introduz. Uma rigorosa solução desse problema não é possível sem conhecer com exatidão os parâmetros que caracterizam o estado atmosférico da área, principalmente, quando o intérprete precisa identificar as naturezas de composição dos constituintes dos materiais, por meio da análise de suas reflectâncias. Esses parâmetros atmosféricos precisam ser conhecidos no momento em que o sensor adquiriu a imagem. O ideal seria dispor de frequentes medições locais com estações meteorológicas ou com equipamentos de radiossondagem, para no mínimo, estimar se as condições atmosféricas são muito claras, moderadas, *hazy* ou muito *hazy*. Como obter esses dados é um problema para a maioria das áreas, foram desenvolvidas técnicas de processamento opcionais de correção atmosférica, com resultados satisfatórios, estimadas a partir dos próprios dados das imagens multibandas. Esses métodos se aplicam às imagens multiespectrais com bandas de ampla largura espectral, como as imagens do CBERS, Landsat ou SPOT.

6.2.2.1

Subtração do escuro (*Dark Subtraction*)

Dentre as várias técnicas propostas, a correção atmosférica pelo uso do limite inferior dos valores digitais do histograma de cada banda, tem sido considerada a mais aceita. É assumido que cada banda da imagem deveria conter alguns pixels com valores próximos ou iguais a zero, cujas origens mais comuns seriam as áreas de sombras de relevo. Mas, devido aos efeitos do espalhamento atmosférico é adicionado um valor de brilho a todos os pontos da imagem, e as áreas sombreadas deixam de exibir pixels com valores zero ou bem próximos de zero. Conseqüentemente, se os histogramas de cada banda fossem analisados, os pixels com valores digitais mais baixos não seriam zero, como mostra a Figura 6.5. Os histogramas aparecem deslocados da origem, sendo a quantidade de deslocamento proporcional ao inverso do comprimento de onda elevado à quarta potência, conforme prevê o espalhamento Rayleigh de uma atmosfera com espalhamento molecular.

Na Figura 6.5 é visto que o espalhamento aditivo decresce dos menores para os maiores comprimentos de onda. Identificado o valor adicionado aos histogramas de cada banda individual, esse valor deve ser subtraído da banda, porque o espalhamento causa às imagens uma aparência desfocada ou de névoa, devido à perda de contraste da imagem. A

correção dessa distorção atmosférica é chamada de *haze removal* ou *dark subtraction*. Não é aconselhável usar essa técnica para imagens de áreas pequenas, porque seriam menores as chances de se ter relevos sombreados.

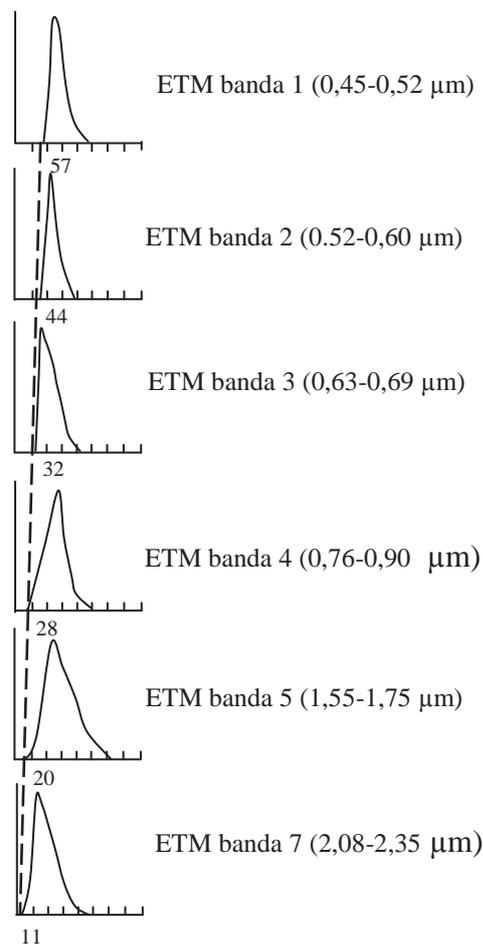


Fig. 6.5 Histogramas das bandas do sensor ETM com a indicação do valor digital que mede a quantidade de espalhamento atmosférico adicionada ao sinal (Adaptado de Richards e Jia, 2006).

O método *dark subtraction* também não se aplica aos sensores hiperespectrais. As imagens desses sensores, em número de centenas de bandas de larguras espectrais bem estreitas, são altamente sensíveis ao espalhamento atmosférico. A correção radiométrica das imagens exige complexos algoritmos de processamento, com entrada de dados de parâmetros específicos das condições atmosféricas e do sensor. O processo não só envolve a correção atmosférica, mas a transformação da imagem digital para imagem de reflectância, possibilitando comparar os espectros de reflectância obtidos em laboratório ou no campo, com os espectros de reflectância extraídos da imagem. Esse assunto será tratado adiante, quando forem discutidas as técnicas espectrais de classificação de imagens hiperespectrais.

6.2.3 Correção das Distorções Geométricas

A correção das distorções geométricas trata, prioritariamente, da remoção de erros sistemáticos presentes em todos os tipos de imagens de sensoriamento remoto. Isso é

realizado em duas etapas distintas. Inicialmente, na primeira etapa de correção são eliminadas as distorções geométricas sistemáticas que são introduzidas no momento de aquisição das imagens devidas à rotação, inclinação e curvatura da Terra e devida à instabilidade da plataforma. Efetivamente, essa primeira etapa é o que se deve denominar de processo de correção geométrica de imagens. Como depende de uma série de parâmetros da exatidão de posicionamento da plataforma, que o usuário não tem conhecimento e nem acesso, a correção geométrica fica a cargo dos laboratórios de produção de imagens, pois para se efetuar uma boa correção geométrica, devem-se conhecer as fontes de erros que interferem no processo de aquisição da imagem. A escolha do modelo matemático mais adequado depende, fortemente, desse conhecimento.

Com a imagem corrigida geometricamente, inicia-se a segunda etapa do processo, para se corrigir as distorções geradas pela visada cônica dos sensores, e que deve ser realizada pelo usuário. O objetivo é inserir na imagem um sistema de projeção para se estabelecer um referencial de coordenadas que possibilite localizar na imagem a posição geográfica dos alvos. Isso constitui o que se denomina de georreferenciamento de imagens, que consiste apenas no uso de transformações geométricas simples, usualmente transformações polinomiais, para estabelecer um mapeamento entre as coordenadas espaciais da imagem e as coordenadas geográficas de cartas topográficas.

6.2.3.1 Correção geométrica

Para avaliar porque as distorções geométricas ocorrem, é necessário, primeiramente, imaginar que uma imagem é formada de linhas sequenciais de pixels. Uma imagem registra N linhas de M pixels, dispondo as linhas sucessivamente, uma abaixo da outra. Como normalmente o IFOV (*instantaneous field of view*) que determina a área de resolução no terreno (resolução espacial) é quadrado, por exemplo, 20 x 20 m, a formatação da imagem é o mesmo que arranjar os pixels em uma grade, tal como mostrado na Figura 6.6. Os pontos de intersecções da grade são as posições dos pixels e o espaçamento entre os pontos da grade é igual ao IFOV do sensor.

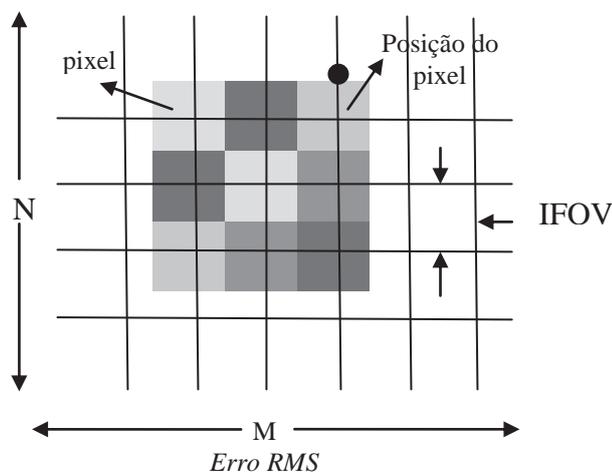


Fig. 6.6 Grade usada para formatar os pixels da imagem digital.

As distorções geométricas são os desajustes dessa grade de pixels. Na imagem digital isso deve ser entendido como a mudança de posição do pixel na grade. Como o pixel é visto por um valor de brilho ou de nível de cinza, se ele mudou de posição pode-se, então, dizer que aquele pixel na grade teve uma mudança de valor de brilho. Devido à alta altitude dos satélites de sensoriamento remoto, uma pequena mudança da plataforma pode causar grandes distorções de posição dos pixels na imagem. As fontes de distorções geométricas são mais diversas do que as radiométricas, as principais sendo devido à:

- a) rotação da terra durante o tempo de imageamento
- b) instabilidades dos eixos de posicionamento da plataforma
- c) curvatura da Terra
- d) campo de visada do sensor

No caso da distorção devido à rotação da Terra a natureza e magnitude da fonte de distorção são conhecidas, e assim fica fácil elaborar um modelo matemático para estabelecer uma fórmula de correção geométrica. Durante o tempo de imageamento gasto para um sensor obter uma imagem, a Terra está rotacionando de oeste para leste, de modo a provocar um deslocamento relativo das linhas de imageamento para oeste, como mostra a Figura 6.7. A quantidade de deslocamento para oeste depende da velocidade relativa do satélite, da dimensão da área imageada e da latitude da área. Como se conhece os dados para se calcular a magnitude do deslocamento em cada situação, que são a velocidade angular do satélite e a velocidade de rotação da Terra, é possível modelar, especificamente, esse tipo de distorção, e fazer uma correção para as linhas serem deslocadas para a direita, numa posição que assegure que as feições estejam em correta posição, relativa uma com a outra, ao longo de toda a imagem. O deslocamento das linhas é da ordem de uma dezena de quilômetros para os satélites tipo Landsat ou CBERS. As imagens distribuídas já vêm processadas com a correção necessária.

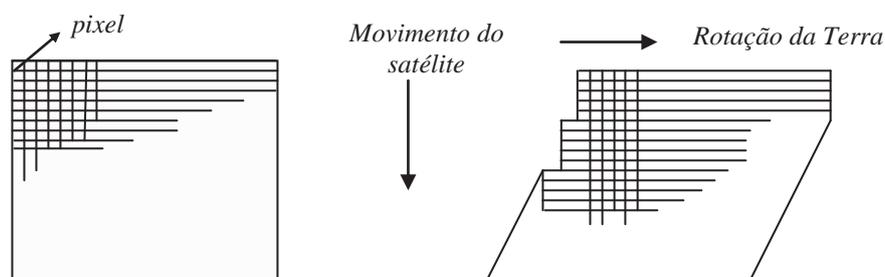


Fig. 6.7 Deslocamento das linhas de imageamento devido ao movimento de rotação da Terra no sentido oeste – leste.

As distorções geométricas causadas pela variação de altitude provocam distorções de escala da imagem, enquanto as distorções provocadas por variações dos eixos de atitude do satélite (inclinação, rolamento, arfagem), causam rotações transversais e longitudinais relativas à linha de voo do satélite (Figura 6.8) Essas distorções são semelhantes às que ocorrem em aerolevantamentos fotográficos. Informações telemétricas das efemérides da plataforma são continuamente enviadas para as estações terrestres de rastreamento e computadas para aplicar a correção necessária.

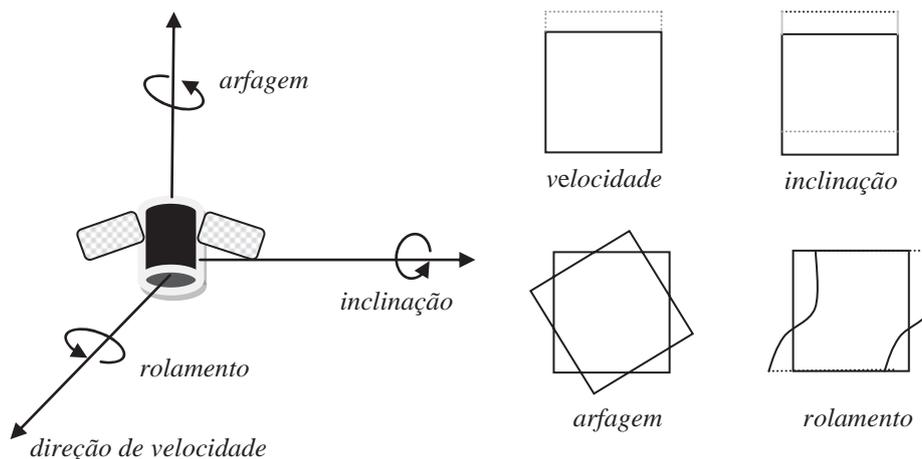


Fig. 6.8 Efeitos das distorções geométricas causadas pelo movimento da plataforma.

A distorção devido à curvatura da Terra é dependente da largura da faixa de imageamento da órbita do satélite, mas a maior influência é o efeito da geometria do plano de inclinação da superfície da Terra sobre a faixa imageada. Para os sensores que possuem um pequeno ângulo FOV ($\pm 7,5^\circ$) como o HRV do satélite SPOT, o ETM do Landsat, ou o CCD do CBERS, com uma largura da faixa de imageamento no terreno entre uma a duas centenas de quilômetros, a distorção não é relevante. Para ângulos FOV da ordem de 40° a 50° a distorção da imagem passa a ser considerável, pois a largura da faixa de imageamento pode atingir mais de 2000 km. O tamanho do pixel ao longo da linha de varredura pode ser de 3 a 5 vezes maior que o tamanho do pixel a nadir. É o caso do sensor MODIS (*MODerate resolution Imaging Spectroradiometer*).

As fontes de distorções geométricas devido ao grande campo de visada do sensor são bem conhecidas dos fotointérpretes. Elas introduzem nas imagens dois tipos de distorções: (i) aumento da área do pixel situado no extremo da imagem; (ii) deslocamento das posições dos pixels ao longo da linha de varredura. Ambas são inerentes a todos os tipos de sensores, em função de a visada ser do tipo central ou cônica, à semelhança dos sensores fotográficos. Portanto, nesses casos a correção da imagem trata, prioritariamente, da remoção de erros introduzidos pelos campos de visada óptica do sensor. É importante em sensoriamento remoto quando a imagem é integrada com outras fontes de informações (ex: imagens geofísicas), ou em estudos multitemporais, por serem as imagens tomadas por diferentes sensores ou em datas diferentes.

A Figura 6.9 ilustra a geometria que os ângulos β (IFOV) e θ (FOV) condicionam esses dois tipos de distorção. No caso de aumento da área do pixel, vê-se pela figura que os pixels ao longo da linha de varredura são amostrados a incrementos regulares definidos pelo ângulo de visada instantâneo β (IFOV), na extensão definida pelo movimento do ângulo de visada θ (FOV). Como resultado, a área efetiva do pixel na extremidade (T) é maior do que na posição nadir (N). A visada do pixel é como se ele fosse um trapézio. A distorção é semelhante a uma visão panorâmica. Dessa forma, haverá uma pequena variação de escala entre as áreas do terreno a nadir N e *off-nadir* T . Como demonstrado trigonometricamente na Figura 6.9, se a dimensão do pixel a nadir é p , então a sua dimensão na direção de varredura estabelecida pelo ângulo θ será $p_\theta = \beta h \sec^2 \theta$. Para pequenos valores de θ esse efeito é negligenciável. Por exemplo, no satélite Landsat 7 o maior valor de θ é $7,5^\circ$, de modo que o pixel (T) na extremidade da linha tem um pequeno incremento de tamanho ($p_\theta = 1,02$) do

pixel a nadir. Quando os pixels são arranjados para compor a grade de pixel da imagem digital, como visto na Figura 6.6, eles são transcritos com o mesmo tamanho, enquanto a área equivalente do terreno não é, mas isso não é tão relevante porque o incremento no tamanho do pixel é pequeno.

Relevante, de fato, é o deslocamento que os pixels sofrem em função dessa geometria de imageamento. Na Figura 6.9 o arco centrado no sensor, que passa pelo ponto N posiciona S a um ângulo de visada θ normal à superfície e à mesma altura h que o ponto N . Nesse caso, os pixels em N e em S medidos na visada inclinada, seriam do mesmo tamanho, sem qualquer distorção. Mas como a imagem é medida no terreno, o ponto S é a projeção inclinada na posição T . Se projetar S verticalmente ao terreno poder-se-á, então, medir a sua distância a T . Essa medida configura o deslocamento que os pixels progressivamente sofrem ao longo da linha de imageamento. Conforme demonstrado por Richards e Jia (2006), para se medir o deslocamento, basta calcular o valor do arco SN da Figura 6.9, S sendo a posição projetada na qual o pixel T no terreno mostraria ter-se deslocado. $SN/TN = \theta/\tan \theta$ é o grau de distorção transversal à linha. No caso do satélite Landsat, para $(\theta/\tan \theta)_{\max} = 0,99$ os pixels nas extremidades da linha, isso é, a 92,5 km distantes a leste ou oeste da posição nadir, estarão deslocados cerca de 314 metros da posição real no terreno. Essa é uma distorção geométrica significativa.

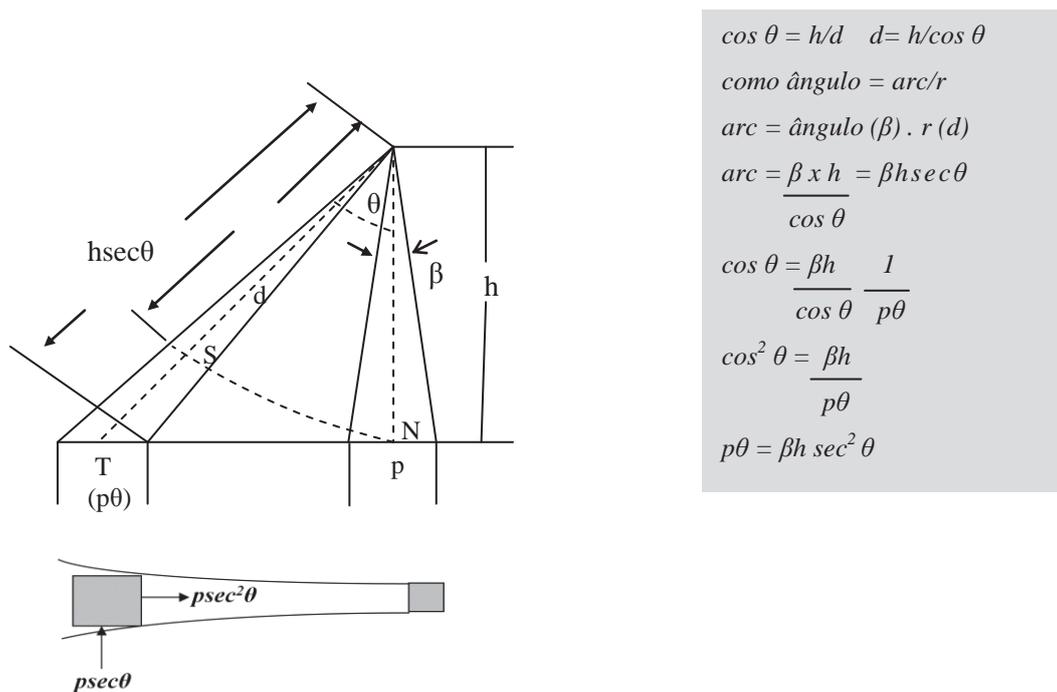


Fig. 6.9 Distorção geométrica da imagem devido à visada cônica, causando deslocamento e aumento da área do pixel.

O efeito do deslocamento de pixel é a deformação visual da imagem. Como os pixels são registrados a uma separação angular igual ao IFOV, no ponto nadir N onde $\cos \theta$ é igual a 1, os centros dos pixels são espaçados p . A um ângulo θ na posição T , os centros de pixels serão espaçados $p \sec^2 \theta$. Assim, colocando-se os pixels sobre uma grade uniforme haverá um maior número de pixel por área próxima ao nadir, do que nas áreas extremas da linha de

imageamento. Dessa forma, a imagem sofrerá uma compressão transversal à linha de varredura, com os alvos deformando-se, como ilustra a Figura 6.10.

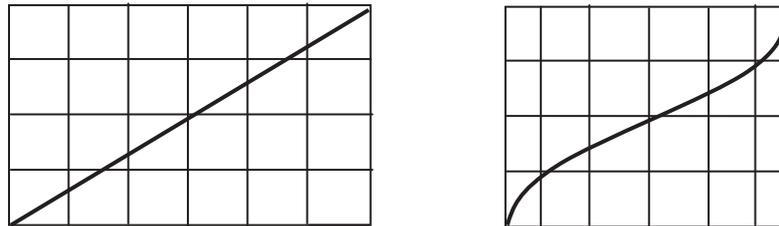


Fig. 6.10 Efeito de distorção da imagem por compressão da linha de varredura devido à taxa angular de varredura constante. (Adaptado de Richards e Jia (2006).

6.2.3.2 Georreferenciamento

Apesar do bom desempenho dos métodos de correção geométrica de sistema, as imagens corrigidas ainda apresentam erros de posicionamento, porque os dados recebidos para a correção de sistema têm uma margem de imprecisão, e mesmo porque, são feitas aproximações na integração dos dados de atitude do satélite. O processo de georreferenciamento das imagens elimina o erro de posicionamento remanescente. Essa é a etapa final do processamento de correção das distorções geométricas da imagem, e deve ser executada pelo usuário.

Georreferenciar uma imagem é tornar suas coordenadas conhecidas num dado sistema de referência, processo que se inicia com a obtenção de coordenadas em um sistema de projeção (coordenadas de mapa E-W ou latitude e longitude) e as equivalentes coordenadas espaciais de pontos da imagem a ser corrigida. O georreferenciamento tem desta forma a finalidade de inserir nas imagens um sistema de projeção de coordenadas. Por isso, nada mais é do que um processo de transformação geométrica da imagem, e não um processo de correção geométrica. Em processamento de imagens, o georreferenciamento é executado simultaneamente, em uma única operação em todas as bandas. Por isso, as imagens devem estar co-registradas. Registro é o processo que envolve a superposição de uma mesma cena que aparece em duas ou mais imagens (imagens de bandas diferentes ou imagens de datas diferentes), tal que os pontos correspondentes nessas imagens coincidam espacialmente.

O problema consiste em associar dois sistemas de coordenadas (imagem-mapa), através de uma transformação geométrica. Portanto, o georreferenciamento não usa informações inerentes à aquisição da imagem como se viu anteriormente. Quando o georreferenciamento é concluído, a imagem passa a possuir coordenadas definidas por um sistema de projeção geográfica. Todos os pixels poderão, então, serem lidos por coordenadas geográficas, tal como se localiza um objeto ou uma feição numa carta topográfica. O georreferenciamento é uma operação sempre necessária para se fazer a integração da imagem a uma base de dados espaciais num sistema de informação geográfica.

O modelo mais comum de georreferenciamento de imagens consiste em estabelecer relações matemáticas entre as posições dos pixels na imagem e as correspondentes coordenadas desses pixels no terreno, via mapas geometricamente corretos (cartas topográficas). A correção é processada igualmente para todas as bandas, porque é assumido que as bandas de um sensor são perfeitamente co-registradas em coordenadas de linhas e colunas. O processo de correção é realizado em duas etapas: (i) a primeira etapa consiste em

determinar a correta localização espacial de um pixel na imagem distorcida; (ii) a segunda etapa consiste em computar o novo valor de brilho para o pixel na imagem de saída corrigida, por meio de reamostragem ou interpolação de pixels da imagem original.

A primeira etapa começa com uma transformação conhecida como mapeamento direto, que estabelece um sistema de relação entre as coordenadas de imagem (linha e coluna) e as coordenadas geográficas de referência (latitude e longitude). Nesse processo as distorções existentes são corrigidas e se definem a geometria e o espaço geográfico a ser ocupado pela imagem corrigida. É preciso dispor de um mapa que recubra a área da imagem, a cartas topográfica sendo a mais indicada. Em termos conceituais o georreferenciamento baseia-se nos procedimentos a seguir, como descritos por Richards e Jia (2006). Definem-se dois sistemas de coordenadas cartesianas: um que define a localização de pontos de controle na carta topográfica (x,y – latitude e longitude); e outro sistema para a localização dos pixel s na imagem (u,v - linha e coluna) a ser corrigida, como no esquema da Figura 6.11. Considera-se então que esses dois sistemas de coordenadas podem ser relacionados por um par de funções de mapeamento espacial f e g tal que:

$$u = f(x, y) \tag{eq. 6.3a}$$

$$v = g(x, y) \tag{eq. 6.3b}$$



Fig. 6.11 Sistemas de coordenadas mapa-imagem para localização dos pontos de controle para o georreferenciamento da imagem.

Se essas funções de mapeamento são conhecidas nas suas formas, pode-se então localizar um ponto na imagem conhecendo-se sua posição no mapa. Com isso se monta uma versão corrigida da imagem original. Porém, como as formas das funções de mapeamento u e v não são conhecidas, elas são escolhidas como sendo na realidade, simples polinômios de 1º ou 2º grau. O uso de transformações polinomiais é bastante comum no georreferenciamento de imagens.

As transformações polinomiais fazem o vínculo entre as coordenadas de imagem e as coordenadas do sistema de referência. Se usarmos um polinômio de segundo grau, que tem duas variáveis, temos a seguinte expressão que relaciona coordenadas da imagem e coordenadas da carta (referência):

$$\begin{aligned} u &= a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2 \\ v &= b_0 + b_1x + b_2y + b_3xy + b_4x^2 + b_5y^2 \end{aligned} \tag{eq. 6.4}$$

Para que esse sistema de equações possa ser montado é preciso conhecer os valores dos coeficientes a_i e b_i . Esses coeficientes são estimados identificando-se as coordenadas de feições no mapa de referência que também podem ser identificadas nas imagens, ou vice-versa. São os chamados pontos de controle no terreno (*ground control points*). As coordenadas de imagem (linha, coluna) são obtidas quando o usuário clica sobre a feição na imagem, e anota, via *software*, os valores correspondentes das coordenadas de referência sacadas de cartas topográficas. Os pontos de controle devem ser feições discretas, tais como cruzamento de estrada, confluências de rios, interseções de linhas ou limites construídos pelo homem. Uma vez determinados os n pontos de controle e selecionada a transformação polinomial, um sistema de $2n$ equações é montado para resolver 6, 12, ou 20 parâmetros, dependendo do polinômio ser de 1^o, 2^o ou 3^o grau. Segundo Andrade (2000), os coeficientes a_i e b_i , em uma equação do primeiro grau, ou transformação afim no plano, modelam duas translações, duas rotações e dois fatores de escala, totalizando seis parâmetros.

A escolha da ordem da função polinomial depende da intensidade da distorção da imagem. Normalmente, transformações de 1^a e 2^a ordem são usadas nas imagens de sensoriamento remoto de pequena resolução espacial, visto que as suas distorções geométricas não são tão relevantes para os trabalhos em escalas regionais que essas imagens possibilitam. Já as imagens de alta resolução espacial requerem ordens polinomiais mais altas.

É exigido um número mínimo de pontos de controle, conforme seja a ordem polinomial, mas na prática aumentar o número de pontos de controle, aumenta a confiança no resultado sem a necessidade de aumentar o grau do polinômio. Deve-se também ter em mente que a distribuição dos pontos de controle é muito importante, desde que as transformações polinomiais tendem a se comportar, adequadamente, apenas na região onde se encontram os pontos de controle. O ideal são os pontos recobrirem todos os cantos e a área central da imagem.

Os coeficientes computados a partir dos pontos de controle são armazenados como uma matriz de transformação. O tamanho da matriz depende da ordem de transformação. A finalidade da transformação é resolver as equações polinomiais para as quais existe o menor erro possível, quando são elas usadas para transformar as coordenadas de referência dos pontos de controle, em coordenadas geográficas da imagem. O método da regressão dos mínimos quadrados é usado para calcular a matriz de transformação, a partir dos pontos de controle. Cada ponto de controle influencia os coeficientes, mesmo que não exista uma coincidência exata de cada ponto de controle com os coeficientes que representam o polinômio.

6.2.3.3

Avaliação dos erros da transformação polinomial

Nem sempre é possível derivar coeficientes que produzem erros zero. Isto porque, raramente, o usuário ao clicar com o mouse sobre a imagem para inserir um ponto de controle consegue uma perfeita precisão da localização do ponto, porque muitas das feições não são visualmente nítidas. E porque, também, nem sempre se consegue uma boa distribuição de pontos de controle que recubra toda a área da imagem. Essas limitações introduzem erros nos coeficientes para a transformação polinomial, que levam a uma imprecisão no georreferenciamento. Essa imprecisão pode ser representada, se imaginarmos sobrepor a grade de pixel da imagem à grade de pixel do mapa de referência. O que ocorreria é algo parecido com a Figura 6.12.

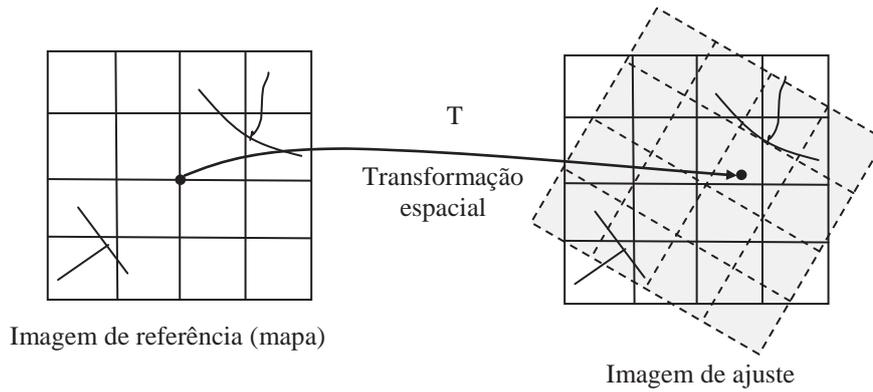


Fig. 6.12 Erro na sobreposição da grade da imagem à grade do mapa devido à imprecisão dos pontos de controle.

Matematicamente, calcula-se essa imprecisão de ajuste dos pontos de controle à função polinomial, medindo-se as distâncias mínimas ao quadrado entre as coordenadas de referência dos pontos de controle e a curva polinomial. O exemplo na Figura 6.13 mostra o ajuste dos pontos de controle a uma função polinomial de segunda ordem, que parece ser a melhor opção. Isso não impede que uma função polinomial de primeira ordem descrita por uma reta possa ser usada. Essa medida da distância de cada ponto de controle à curva é chamada de erro RMS (*root mean square*). O erro RMS pode ser avaliado para cada ponto de controle, individualmente, embora o erro total seja o mais importante.

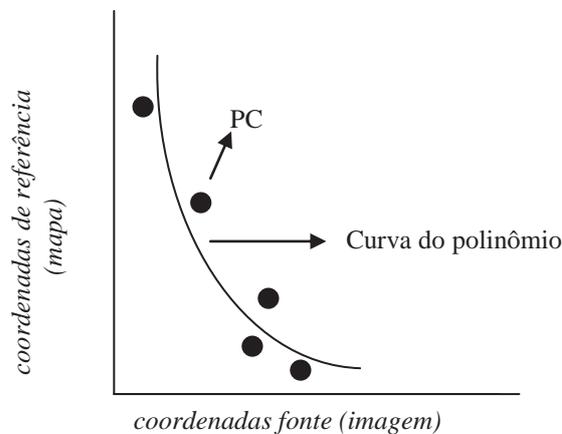


Fig. 6.13 Pontos de controle ajustados à ordem de transformação polinomial

A fórmula para se calcular o erro RMS dos pontos de controle é mostrada abaixo.

$$RMS = \sqrt{(x_i - x_r)^2 + (y_i - y_r)^2}$$

eq.6.5

onde, x_i e y_i são coordenadas retransformadas
 x_r e y_r são coordenadas de referência

Para se calcular o erro RMS mede-se o erro na direção X e na direção Y , para cada ponto de controle (PC), como mostra a Figura 6.14.

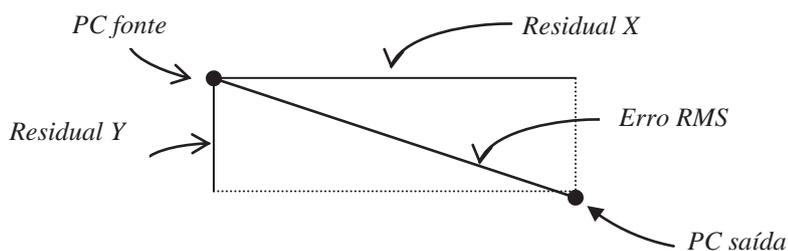


Fig. 6.14 Representação geométrica da medição do erro RMS de um ponto de controle.

O valor de RMS é expresso em números de pixels. Por exemplo, um erro RMS de valor dois, significa que o pixel retransformado está distante dois pixels do pixel de referência. Se os pontos de controle mostram valores altos de RMS na direção X ou na direção Y, deve-se adicionar mais pontos naquela direção. A Tabela 6.1 mostra os tipos de informações que o usuário tem acesso *on line* conforme os pontos de controle são adquiridos. Os dados são referentes ao georreferenciamento de um segmento de imagem.

Tabela 6.1 Pontos de controle e erros computados (usado o *software* ENVI).

PC	MAPA X	MAPA Y	IMAGEM X	IMAGEM Y	PREDIÇÃO X	PREDIÇÃO Y	ERRO X	ERRO Y	RMS
1	205725	8252491,25	4718,25	3090,75	4717,053	3091,732	1,196	0,982	1,548
2	210650	8249958,75	4880,43	3177,00	4880,726	3176,720	0,296	-0,279	0,407
3	218050	8249100,00	5126,60	3207,00	5126,271	3206,383	-0,328	-0,617	0,699
4	209500	8244975,00	4841,29	3342,14	4841,44	3342,333	0,054	0,193	0,201
5	207975	8246950,00	4791,00	3277,00	4791,302	3276,412	0,302	-0,587	0,661
6	211750	8252959,00	4918,50	3078,00	4918,317	3077,387	-0,182	-0,612	0,639
7	207000	8255400,00	4759,00	2995,83	4759,223	2995,159	0,923	-0,670	1,141
8	211750	8255200,00	4919,17	3002,17	4919,076	3002,546	-0,093	0,376	0,387
9	215475	8249700,00	5040,83	3184,33	5041,054	5041,054	0,244	1,215	1,296
Erro RMS Total = 0,876									

Na maioria dos casos um perfeito ajuste para todos os pontos de controle requer uma transformação de alta ordem, mas que se mostra muitas vezes, desnecessária. Ao invés de aumentar a ordem, tem-se a opção de tolerar certa quantidade de erro. Portanto, quase sempre, ao se georreferenciar uma imagem, existirá uma pequena diferença entre as coordenadas da imagem retransformada e as coordenadas de referência, conhecido como erro interno. O erro interno é o erro residual, aquele que não se consegue eliminar totalmente, quando se tenta sobrepor uma imagem a um mapa.

O erro RMS, para cada ponto, serve para avaliar cada ponto de controle que o usuário escolheu. Esse é calculado pela fórmula da distância.

$$R_i = \sqrt{XR_i^2 + YR_i^2}$$

eq. 6.6

onde, R_i = erro RMS para ponto de controle
 XR_i^2 = residual X YR_i^2 = residual Y

E o erro RMS total é o somatório dos erros residuais de todos os pontos de controle.

$$RMS_{total} = \frac{1}{n} \sum_{i=1}^n nXR_i^2 + YR_i^2$$

eq. 6.7

Os valores de tolerância de erro RMS que normalmente são aceitos para os pontos de controle são:

- ✓ imagens ópticas com pixel de 30 m – erro RMS ≤ 2 pixel = 60 metros.
- ✓ mapas na escala 1:25.000 – precisão próxima de 20m
- ✓ GPS – precisão de aproximadamente de 10m

É sempre recomendável começar com uma transformação de 1ª ordem. Pode-se computar repetidamente a transformação até conseguir um erro RMS aceitável. A maioria das correções das imagens é de 1ª ou 2ª ordem. Após cada computação da transformação e do erro RMS, existem quatro opções:

1. Jogue fora o ponto de controle com o maior erro RMS, assumindo que este é o ponto de controle de menor precisão. Outra matriz de transformação pode, então, ser computada dos pontos de controle restantes. Entretanto, se esse é o único ponto de controle em uma determinada região da imagem, isso pode causar um erro maior.
2. Tolere uma quantidade maior de erro RMS.
3. Selecione somente os pontos que você tem maior confiança.
4. Aumente a ordem da transformação, criando alterações geométricas mais complexas na imagem. Uma matriz de transformação é computada, e que acomoda os pontos de controles com um erro menor.

Richard e Jia (2006) explicam que nem sempre uma ordem de transformação maior possa ser a mais adequada para a correção de uma imagem. A Figura 6.15 desses autores mostra os ajustes dos pontos de controle às curvas de diferentes ordens polinomiais. Aparentemente, a curva de 3ª ordem seria a melhor escolha, porque é a que passa mais próxima aos pontos de controle. Mas, se mais pontos fossem plotados é presumível que a tendência dos pontos seguiria mais próxima à reta de 1ª ordem, enquanto a curva de 3ª se desviaria dessa tendência. Isto é essencial para se obter a melhor correção dos dados da imagem.

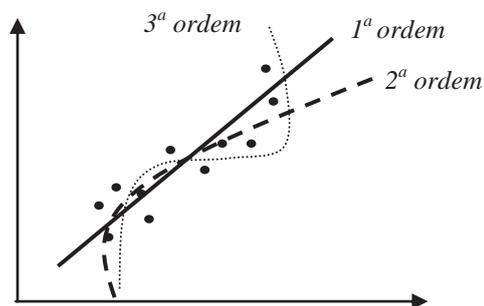


Figura 6.15 Escolha da ordem polinomial para melhor ajuste. (Adaptado de Richards e Jia, 2006)

Uma transformação de primeira ordem é uma transformação linear, que pode mudar a localização em x e/ou y, ou a escala da imagem em x e/ou y. Transformações de 2ª ordem ou ordens maiores são transformações não lineares, usadas para converter Lat/Long para uma

projeção plana ou em imagens cobrindo uma área grande para compensar a curvatura da Terra. Transformações de 3ª ordem devem ser usadas em imagens com severas distorções, como as fotos aéreas e imagens de alta resolução espaciais tomadas *off nadir*. O processo de corrigir distorções não lineares é também conhecido como “*rubber sheeting*”.

6.2.3.4 Reamostragem

Concluído essa primeira etapa do georreferenciamento, o próximo passo no processo é encontrar pontos na imagem, correspondentes para cada localização na grade de pixel previamente definida sobre o mapa. Isso é feito automaticamente sem interferência do usuário. O espaçamento da grade deve ser escolhido de acordo com o tamanho do pixel da imagem. Na suposição de que os pontos localizados na imagem correspondem exatamente aos centros de pixels, então esses pixels com seus valores de brilho são simplesmente transferidos da imagem original para a apropriada localização na grade, para construir a imagem corrigida. É o que mostra a Figura 6.16.

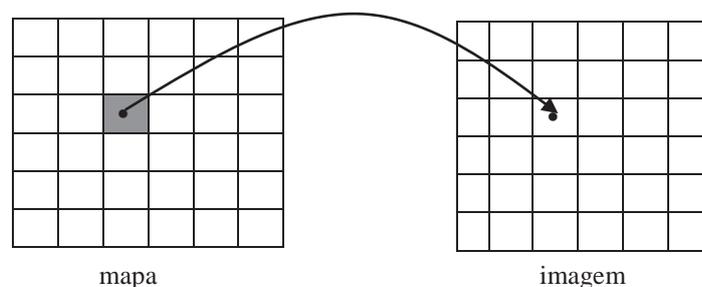


Fig. 6.16 Condição na qual os pixels alocados na imagem correspondem exatamente aos centros de pixel da grade.

Mas como se espera, os centros da grade de pixels do mapa de referência não são transferidos para a exata localização do centro de pixels na imagem. Isto é, a grade de pixel do mapa, raramente, coincide perfeitamente com a grade da imagem. Como já visto, os erros RMS calculam essa imprecisão. É preciso, então, encontrar uma solução, a qual se resume em encontrar quais são os valores de brilho dos pixels a serem escolhidos para substituírem os valores de brilho na nova grade. Essa técnica é o que se denomina de reamostragem ou interpolação dos valores de brilho da imagem. Pode-se definir reamostragem como o processo de extrapolar os valores digitais para os pixels da imagem corrigida, a partir dos valores digitais dos pixels fontes. Isso quer dizer que os níveis de cinza que compõem a imagem corrigida residem na imagem de entrada. Segundo D’Alge (2001), baseado, fortemente, na idéia de otimização computacional, esta é uma fase que pode ser denominada de mapeamento inverso, que permite que se retorne à imagem original para que se definam os níveis de cinza que compõem a imagem corrigida. A reamostragem é a última etapa do processo de georreferenciamento.

A Figura 6.17, apresentada em Brito e Coelho (2002), exemplifica esse processo de mapeamento inverso. Na figura, a grade de pixel da imagem original está representada em linhas contínuas e a grade de pixel da imagem corrigida em linhas tracejadas. O pixel destacado na imagem original (coluna 430, linha 289) influencia radiometricamente, pelo

menos, os quatro pixels vizinhos da imagem retificada (colunas 427 e 428 e linhas 288 e 289). O problema da reamostragem se resume em determinar qual destes quatro pixels vizinhos deverá assumir o valor de brilho do pixel em destaque, na imagem original.

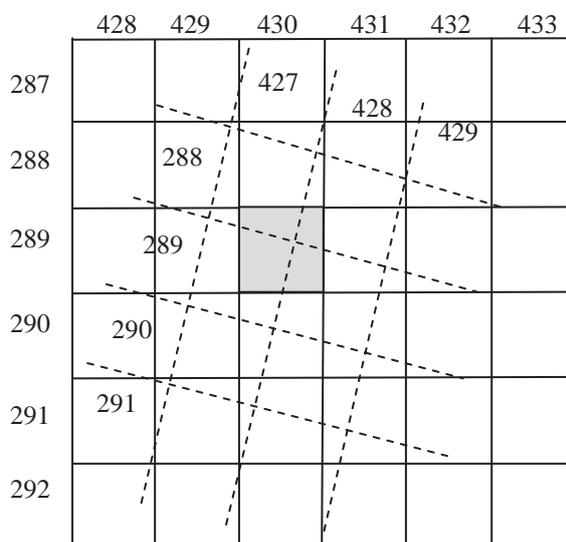


Fig. 6.17 Reamostragem do valor de brilho da imagem corrigida a partir do brilho da imagem original. (Fonte: Brito e Coelho, 2002).

No processo de reamostragem dos pixels para determinar qual dos pixels vizinhos assumirá o valor de brilho, vários métodos de interpolação foram desenvolvidos: interpolação vizinho mais próximo; interpolação bilinear; interpolação por convolução cúbica.

A interpolação com reamostragem vizinho mais próximo, também conhecida como interpolação de ordem zero, apenas transfere para a imagem reamostrada o valor de brilho do pixel da imagem original que estiver mais próximo. No exemplo da Figura 6.17, este pixel será o da coluna 427, linha 289. De acordo com Schowengerdt (1997) este método introduz descontinuidades geométricas (erros) na imagem reamostrada da ordem de 0,5 pixel, que é irrelevante para a visualização da imagem. Sua principal vantagem é a rapidez de processamento e de não requerer nenhum cálculo para derivar o pixel de saída. Além disso, esta reamostragem não altera os valores radiométricos da imagem original.

A interpolação com reamostragem bilinear (primeira ordem) toma por base os valores de brilho dos quatro vizinhos mais próximos ao centro do novo pixel (imagem corrigida). Duas interpolações lineares são executadas ao longo das linhas para encontrar o valor a ser interpolado. Utilizando uma janela de dimensão 2 x 2 é calculada a média ponderada das distâncias dos centros dos quatro pixels ao centro do pixel de saída, para determinar a intensidade do valor de brilho do pixel de saída. O efeito é uma suavização da superfície, acompanhada de uma alteração dos valores de brilho da imagem original, o que pode ser problemático para subseqüentes análises numéricas. Sua vantagem em relação ao método vizinho mais próximo é a melhor precisão geométrica e o desaparecimento de descontinuidades, segundo Novo (1989).

A interpolação por convolução cúbica utiliza os dezesseis pixels ao redor. Segundo Andrade (1998) a interpolação é realizada ajustando polinômios cúbicos a cada coluna, para depois interpolar um novo polinômio cúbico a estes resultados. Incorre em menor erro de interpolação. A reamostragem cúbica produz um aumento de brilho nas áreas com bordas

bruscas, o que pode ser interessante para fins de fotointerpretação da imagem. Os dados são alterados mais drasticamente do que pelos outros métodos, podendo não ser recomendado se a imagem for usada para classificação, ou para análises numéricas que possam depender da precisão dos valores radiométricos originais. Dos três métodos é o mais preciso para gerar uma imagem geometricamente corrigida quando o trabalho envolver o uso de imagens de diferentes resoluções espaciais.

A Figura 6.18 mostra o resultado do georreferenciamento de uma imagem, usando um polinômio de ordem 1 e reamostragem por vizinho mais próximo, com oito pontos de controle. Podemos verificar se a correção da imagem foi ou não satisfatória, sobrepondo sobre ela um plano de informação vetorial da rede de drenagem. Uma vez que a imagem está georreferenciada, podemos inserir sobre ela uma grade de coordenadas, processo que é feito automaticamente após finalizada a sessão de georreferenciamento.

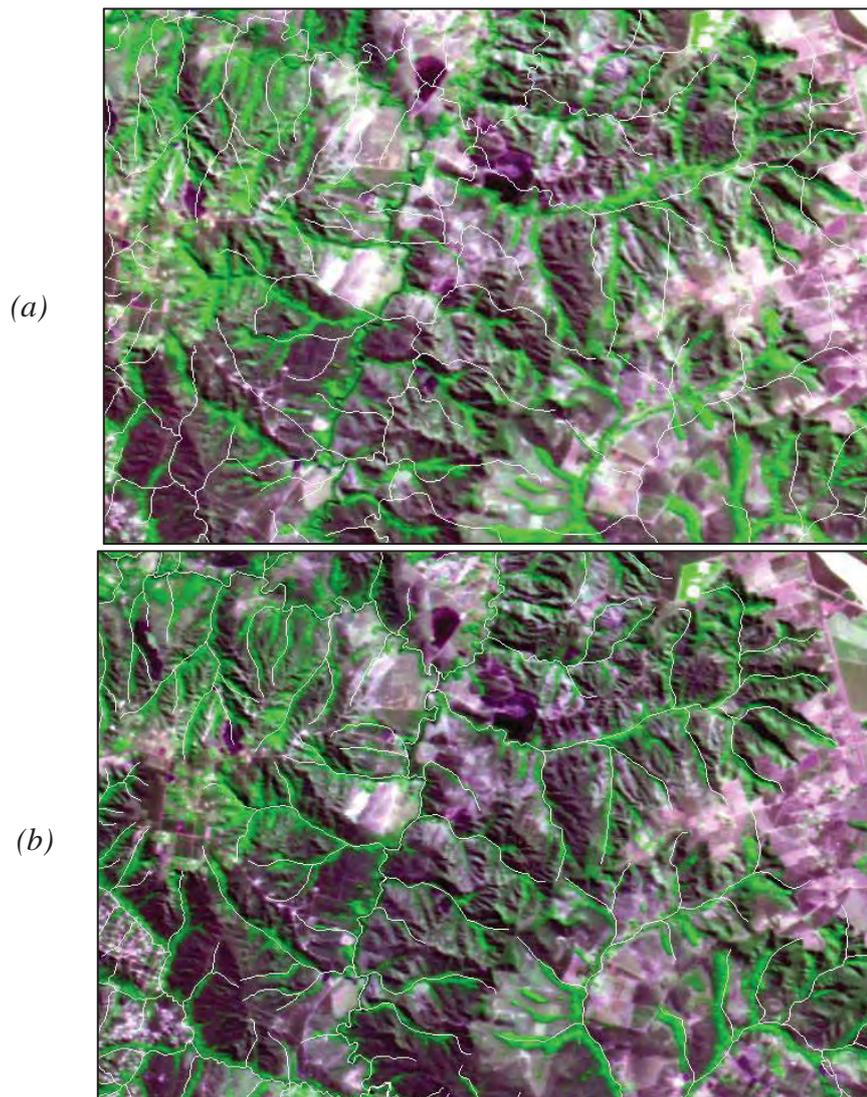


Fig. 6.18 Em (a) imagem original e em (b) o resultado do georreferenciamento, mostrando que sobreposição da rede de drenagem extraída da carta topográfica mostra bom ajuste com a imagem georreferenciada.

AMPLIAÇÃO HISTOGRÂMICA DE CONTRASTE

*Paulo Roberto Meneses
Tati de Almeida*



7.1 Introdução

Na interpretação o intérprete se utiliza de regras de análises baseadas nas propriedades texturais e espectrais das imagens dos objetos, para determinar quais são as suas classes, tipos ou naturezas, a partir de um processo dedutivo do conhecimento científico. O sucesso dessa operação depende, fundamentalmente, de como os materiais - rocha, solo, vegetação, água, e alvos urbanos evidenciam os contrastes destas propriedades, nas diferentes bandas espectrais de um sensor. Nem sempre os contrastes entre os objetos são totalmente percebidos pelo intérprete, porque com frequência, as variações de cinza dos pixels das imagens são restritas a uma pequena diferença digital. Isso pode ser constatado quando uma imagem original, que não tenha sido modificada por qualquer forma de processamento, é exposta na tela do computador. Visualmente, os valores dos níveis de cinza serão muito próximos entre si, e os detalhes texturais e espectrais da imagem não são facilmente identificados, como mostram as imagens da Figura 7.1.

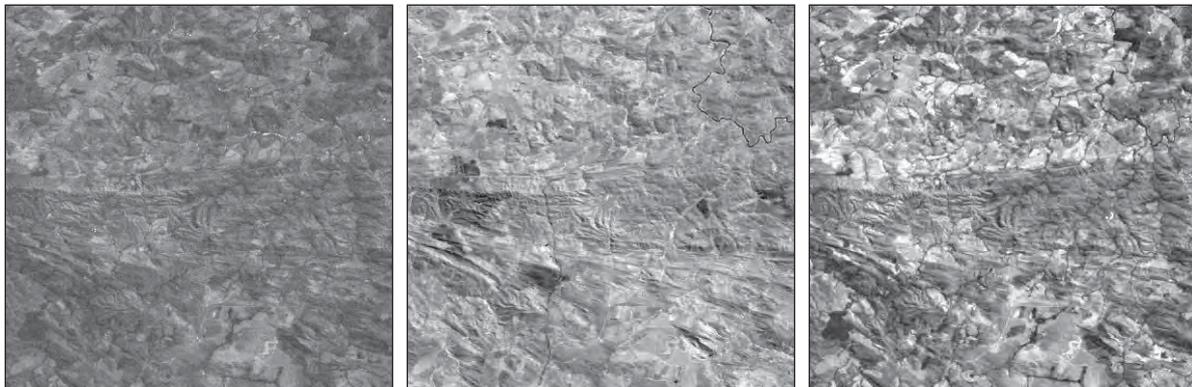


Fig. 7.1 Da esquerda para a direita imagens do sensor ETM-Landsat7 das bandas 1(visível), 4 (infravermelho próximo) e 7 (infravermelho de ondas curtas) exibindo baixos contrastes tonal e textural do relevo.

Como vimos, há basicamente dois processos para se realçar o contraste de uma imagem original. Há as técnicas que operam no domínio espectral e que são maioria, e as que trabalham no domínio espacial. No domínio espectral o realce da imagem é efetuado de tal forma que cada pixel da imagem aumente o seu contraste em relação ao pixel vizinho, independente do valor do pixel vizinho. São operações efetuadas pixel a pixel e que podem ser dita do tipo realce radiométrico. Os algoritmos dessa técnica embutem o conceito de um

espaço espectral multidimensional. No domínio espacial os realces são efetuados em dependência do valor do pixel em relação aos seus vizinhos, portanto, depende da distribuição espacial dos pixels. Nela se incluem as técnicas de filtragens de imagens. Esses dois processos de realces de imagens operam transformações do espaço espectral e da informação espacial da imagem, sendo por isso, consideradas como técnicas de transformação de espaço. Sem dúvida, para o intérprete, uma imagem realçada oferece melhores condições para assegurar uma interpretação de alta confiabilidade para elaboração de mapas temáticos.

Dentre as técnicas que operam no domínio do espaço espectral, se destacam como principais: i) realce de contraste por expansões histográficas; ii) operações aritméticas de bandas; iii) transformações do espaço de cores; iv) descorrelação de bandas; v) principais componentes. Cada uma dessas técnicas envolve uma concepção algorítmica bem específica sobre a forma de realce espectral da imagem, e os resultados têm diferentes aplicabilidades na análise da informação da imagem. Por isso, neste livro considerou-se tratá-las em capítulos individuais.

Neste capítulo são apresentadas as formas de realces de contraste por expansões histográficas, que são consideradas como uma das técnicas mais simples de realce de imagens, mas nem por isso, menos úteis e eficazes. Na maioria das vezes é o primeiro tipo de processamento que se deve realizar, pois permite facilmente avaliar quais bandas contém as melhores informações que o intérprete está interessado. A simplicidade das operações histográficas é que ela não promove uma transformação total da imagem, mas apenas um reescalonamento dos níveis de cinza dentro do intervalo de quantização da imagem. Tem o único propósito de melhorar a qualidade visual da imagem que será exposta na tela do computador. Devido a sua simplicidade, e considerando que as imagens originais têm baixos contrastes espectrais, quase todos os sistemas comerciais de processamentos de imagens acionam uma ampliação de contraste automático quando a imagem original é carregada na tela, a fim de produzir uma imagem com forte impacto visual.

Há diversas formas, matemáticas e estatísticas, para se obter imagens com bons contrastes, a partir da expansão do histograma de cada banda original. Não há um esforço intencional para melhorar a fidelidade da imagem, como é feito na correção das distorções geométricas. Também não há uma qualidade de imagem contrastada que possa servir de padrão para as diferentes finalidades de aplicação. A escolha do melhor método de expansão histográfica está condicionada às características fisiográficas de cada área, ao objetivo específico do trabalho e à própria capacidade do analista em interpretação de imagem. Embora sejam razoavelmente simples, elas são essenciais para a função prática que se destinam: serem usadas na formação de composições coloridas de alto contraste, por meio da combinação de três bandas realçadas, através de um processo semelhante à percepção da imagem colorida formada pela visão humana, com as combinações das cores azul, verde e vermelha da luz solar refletida pelos objetos. Daí a preferência de qualquer fotointérprete por imagens de composições coloridas realçadas. As operações de realces por meio de expansões de histogramas deverão, previamente, ser feitas em cada banda separadamente, sempre procurando aumentar ao máximo os seus contrastes. Dessa forma, quando as cores forem destinadas a essas bandas para se construir uma composição colorida, elas serão capazes de evidenciar, visualmente, as sutis variações espectrais dos materiais. Pela simplicidade como são rapidamente executadas com um grau elevado de independência pelo analista, possibilitam uma alta interatividade homem-máquina. É compreensível que a discussão sobre as técnicas de modificação de histogramas, para aumento de contraste, seja seguida da discussão de como é formada uma composição colorida com multibandas.

7.2

Representação Histogramática da Imagem Digital

Os valores digitais das bandas individuais de um sensor podem ser computados na forma de um gráfico de barras, onde as alturas das barras indicam a quantidade de números de pixels presentes na imagem, com um determinado valor de brilho. Isso é uma representação estatística da distribuição de frequências de uma variável quantitativa na forma de histograma. O histograma é usado em qualquer estudo para representar uma grande quantidade de dados numéricos, como meio para analisar as informações de forma mais fácil e simples, do que por meio de uma grande tabela. A Figura 7.2 é um típico histograma de uma imagem de sensoriamento remoto, através do qual o usuário pode obter algumas informações que estão contidas na imagem, tais como, a intensidade de contraste entre os alvos ou a quantidade de classes que a imagem pode distinguir. O histograma contém apenas informação radiométrica da imagem, e nenhuma informação espacial. Um experiente intérprete, ao localizar uma barra no histograma, poderá estimar a classe de alvo que representa e a área total ocupada na imagem, mas não saberá onde o alvo se encontra, ou mesmo, se está concentrado em uma única área ou disperso em pequenas áreas através da imagem.

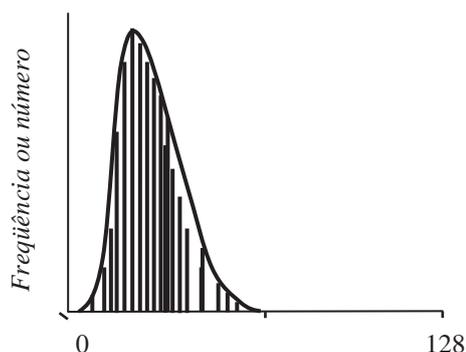


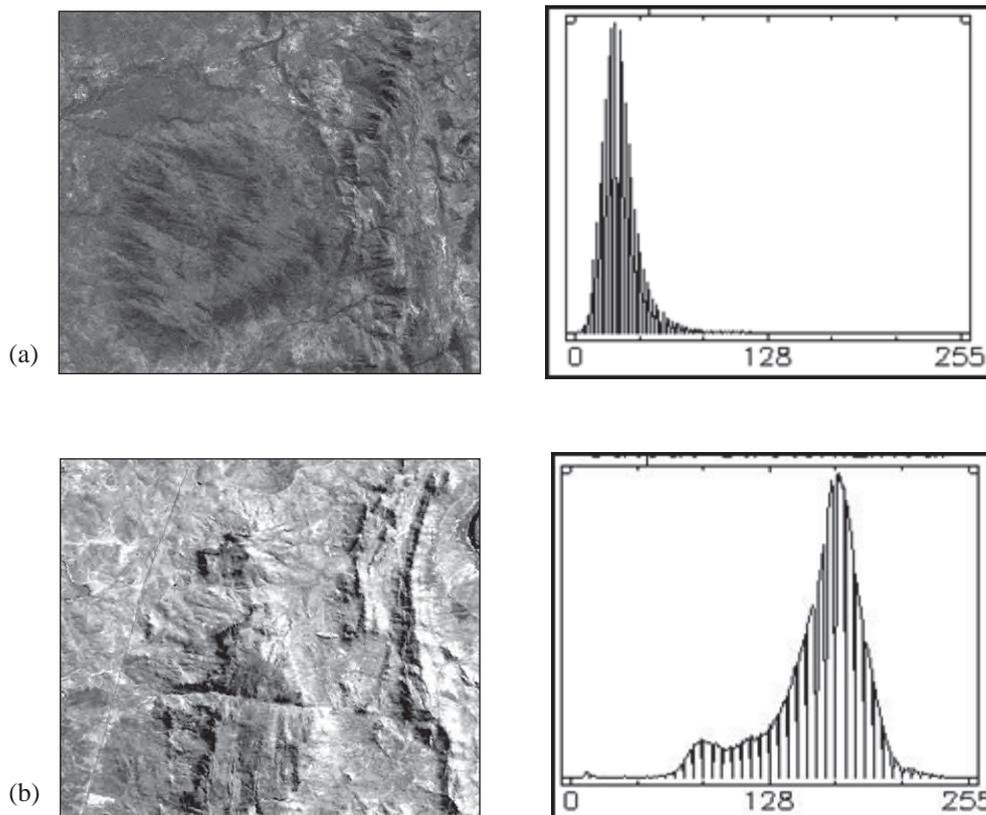
Fig. 7.2 Histograma da imagem de uma banda com os valores de brilho ou níveis de cinza no eixo X definidos pela resolução radiométrica do sensor e no eixo Y o número de pixels por classe de brilho.

A análise de um histograma envolve basicamente três parâmetros: a tendência central, a variabilidade e a forma. A tendência central da distribuição de frequências de brilho da imagem é caracterizada pelo valor do intervalo digital de quantização da imagem (ex. 8 bits=256, 10 bits=1024). Uma das maneiras de representar o que é típico da distribuição é através do valor mais frequente da variável, chamado de moda, que corresponde à barra mais alta ("pico"), e do valor da média da variável amostrada. Média e moda se igualam somente se o histograma for análogo a uma distribuição normal gaussiana, o que raramente se vê nas imagens de sensoriamento remoto. A média está relacionada com uma grandeza que indica algo sobre o nível de reflectância dos alvos presentes na cena. Para se descrever adequadamente a distribuição de frequências de uma variável quantitativa, é necessário dizer, também, o quanto esses valores variam (variabilidade), ou seja, quão dispersos eles estão. Se os valores digitais estão concentrados, a imagem mostra pouca variabilidade de brilho.

Estatisticamente, a variabilidade é a medida da variância, a qual dá uma idéia de qual é o contraste da imagem. Sabe-se que o contraste depende do comportamento espectral dos alvos, e varia com o comprimento de onda. Essas informações são automaticamente computadas durante o processamento da imagem, e podem ser acessadas pelo usuário, em

relatórios de estatística dos dados das imagens. A forma do histograma informa como os dados estão distribuídos em torno da média ou da moda, ou se preferir, onde está a concentração dos dados. Em muitos casos de imagens de sensoriamento remoto, apenas o conhecimento visual da forma do histograma de uma banda, já fornece uma boa informação sobre o comportamento espectral da cena.

Os exemplos na Figura 7.3 mostram que esses três parâmetros classificam os padrões de histogramas das bandas nos tipos: unimodal, bimodal, simétrico e assimétrico, e se abertos ou fechados. No caso *a* da Figura 7.3, o histograma tem uma forma simétrica com média baixa de valores de níveis de cinza e com distribuição fechada, ou seja, baixa variância, a imagem tendo classes de alvos com baixa reflectância e baixo contraste, com aparência visual escura. No caso *b* a média é alta, isso é, visualmente, a imagem é clara, com uma variância moderada, portanto, com um moderado contraste espectral dos alvos. O caso *c* é de uma imagem com uma distribuição mais equilibrada de tons de cinza escuros e claros em relação à média centrada próxima a 128, e a maior abertura de histograma indica uma variância mais alta, isso é, a imagem tem um contraste mais alto e, portanto, com maior nível de informação. No caso *d*, o histograma tem uma forma bimodal, sugerindo no mínimo a presença de dois conjuntos de alvos com distintos valores de reflectância. E no caso *e*, a forma assimétrica do histograma indica que a parte mais à esquerda da curva histogrâmica representa alvos de baixo contraste espectral e com maior concentração de distribuição dos dados, enquanto a parte mais à direita tem um maior contraste espectral dos objetos e uma maior distribuição.



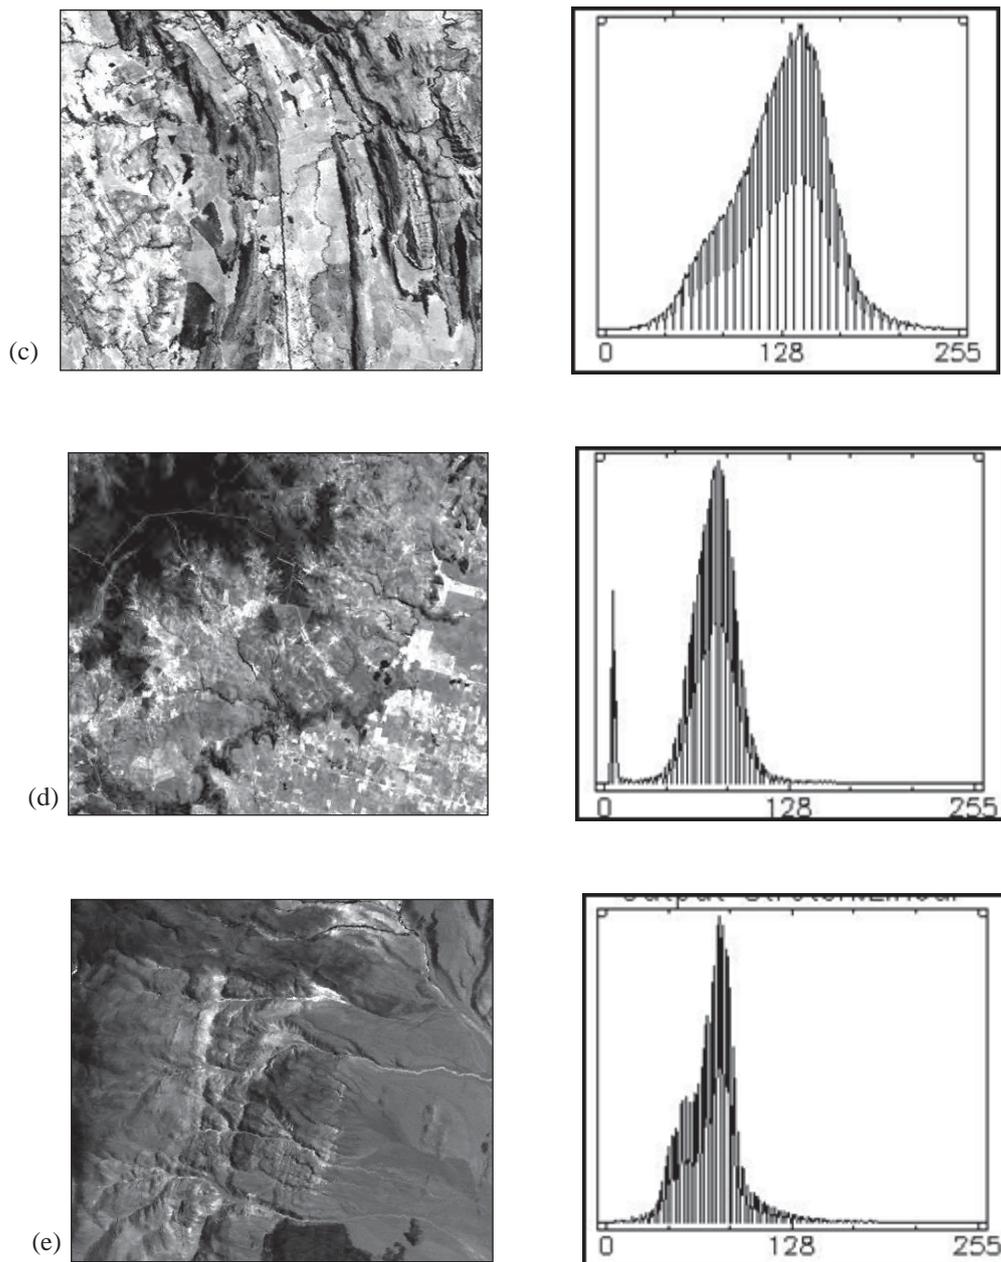


Fig. 7.3 Histogramas de imagens exemplificando variações de tendência central da distribuição dos dados, variabilidade e forma.

Em termos de processamento de imagens, a importância de conhecer essas características do histograma é que elas ajudam o analista a selecionar o tipo mais apropriado para se expandir o histograma, a fim de se obter bons realces de contrastes. Como cada banda espectral tem uma particular forma de histograma, opções diferentes de ampliação de contraste, por expansão de histogramas, poderão ser escolhidas para as diferentes bandas de um sensor.

Há duas classes de algoritmos de expansão de histograma que são as mais empregadas: lineares e não lineares. Os lineares são: linear por saturação e linear por partes. Os não lineares são: gaussiano, equalização, raiz quadrada, logaritmo e exponencial. Os realces lineares conseguem manter a radiometria da imagem, enquanto os realces não lineares

distorcem a radiometria da imagem. É uma máxima em processamento de imagens que o bom desempenho dos resultados obtidos em uma área, não necessariamente, pode ser reproduzível para outras áreas.

7.3 Expansão linear por saturação

Os sensores são instrumentos concebidos para registrar em qualquer faixa espectral uma ampla variação de intensidade de radiância refletida, emitida ou retroespalhada. Acontece que na natureza, frequentemente, a maioria dos conjuntos de alvos distribuídos em uma área não apresenta altos contrastes de reflectância. Na prática, isso mostra que quando a imagem original é exposta no monitor de vídeo, o analista tem dificuldades para discriminar visualmente as classes de níveis de cinza. Contribui também para isso, a baixa capacidade de percepção visual do olho humano para discriminar tons de cinza. Como foi visto nos exemplos da Figura 7.3, apenas uma pequena proporção do intervalo máximo de valores de brilho de uma imagem (nível de quantização) é ocupada. Sensores como a câmera CCD do CBERS ou o sensor multiespectral ETM do Landsat possuem um nível de quantização de 256 valores digitais para representar os valores de brilho ou radiância, enquanto observa-se nos histogramas das imagens de suas múltiplas bandas que o intervalo médio das variações de níveis de brilho ocupa ao redor de 60 valores. A necessidade de se ter um intervalo digital grande é para que os alvos possam ser detectados sem levar à saturação dos detectores. E tendo-se um amplo intervalo de valores digitais, como de 0 a 255, ou ainda maior, há uma boa margem de espaço para expandir o histograma, aumentando-se o contraste espectral dos alvos.

A maneira de aumentar esse contraste é reescalando a amplitude de cada pixel através de uma regra básica de expansão de histograma. A imagem modificada ou realçada é assumida de ser restrita ao mesmo número de pixels da imagem original, apenas expandindo seus valores de brilho para o intervalo total de quantização da imagem. Por isso, o que se realiza é uma saturação em preto e em branco, de um modo que o nível de brilho de saída é o nível que mais se aproxima do exato mapeamento de um nível de brilho de entrada. Esse efeito resulta numa escala de níveis de brilho de saída muito mais diferenciados. Fica claro que ao se efetuar a expansão linear na imagem, a mesma intensidade de expansão é aplicada igualmente para os pixels que tenham o mesmo valor de brilho, o que significa ser impossível aplicar numa imagem diferentes transformações histográficas para as áreas com os mesmos valores de brilho. Se acontecer do realce produzir valores de brilho fora do intervalo definido pela função de transformação, esses valores serão saturados ao nível máximo ou ao nível mínimo permitido, e por isso é dito ser realce ou expansão linear por saturação.

A função de mapeamento linear por saturação, equação 7.1, é uma função de 1º grau que faz destinar novos valores de brilho (y) para cada pixel da imagem original (fx). Na função matemática de primeiro grau o coeficiente a determina a inclinação da reta e exerce, efetivamente, o efeito de ampliação do histograma original, enquanto o coeficiente b define o *offset* ou deslocamento do histograma à origem. Para $a > 1$ quando $b = 0$ tem-se somente uma ampliação de contraste na imagem de saída; quando $b > 0$ acrescenta-se à ampliação de contraste um deslocamento dos níveis de cinza, a fim de centralizar o histograma próximo à média de 128. A Figura 7.4 mostra que o valor de brilho de saída (V_s) pela transformação linear é calculado por simples relações trigonométricas, a partir dos valores do intervalo de brilho da imagem de entrada.

A equação linear é dada pela fórmula:

$$y = f(x) = ax + b$$

eq. 7.1

que é expressa computacionalmente por:

$$V_s = \frac{255}{Max - Min}(VB_e - Min)$$

onde, V_s = valor de brilho de saída
 VB_e = valor de brilho de entrada
 Max = valor de brilho máximo
 Min = valor de brilho mínimo

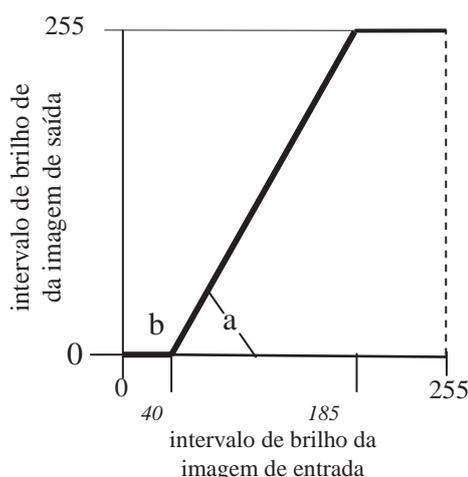


Fig.7.4 Representação trigonométrica da expansão linear de contraste por saturação dos valores de brilho.

É importante considerar que o realce linear deve ser aplicado nas imagens que exibem histogramas com formas simétricas e unimodais. Para aplicar o realce linear o programa adquire o histograma de cada banda e determina os valores inferiores e superiores dos níveis de cinza ou brilho, que são fixados como valores de corte. Como o processo é iterativo, o analista pode, ao seu critério, redefinir os valores de corte, a fim de controlar o realce desejado. A função de transformação é aplicada a cada banda, fazendo com que, automaticamente, o valor de corte mínimo seja fixado ao valor de brilho zero e o valor de corte máximo ao valor de brilho 255, e qualquer valor dentro do intervalo é, linearmente, reescalado entre 0 e 255. Portanto, os pixels vizinhos aos valores min-max são mapeadas para preto e branco, respectivamente, a técnica consistindo desta forma num realce de contraste com saturação. Esse é um bom procedimento para manter a base de dados normalizada à escala total do intervalo dinâmico de brilho. Usualmente, o analista ao observar o histograma determina livremente qual é o valor mínimo e máximo do dado original, pois pode ele decidir que abaixo ou acima de certo valor digital, não há informação que lhe interesse.

Como exemplo prático a Figura 7.5 corresponde ao histograma de uma suposta banda, com os valores mínimos e máximos dos pixels da imagem de entrada fixados, respectivamente, em 5 e 25. O problema pode ser assim formulado:

valores brilho < 5 fixados a 0 (b=0)

valores brilho > 25 fixados a 255
 valores brilho > 5 e < 25 expandidos entre 0-255

portanto, segundo a função computacional de transferência de 1º grau

$$P/f(x,y) < 5 \quad y = 0$$

$$P/f(x,y) > 25 \quad y = 255$$

$$P/f(x,y) \in [5,25]$$

$$y = \frac{255}{25 - 5} (VBe - 5)$$

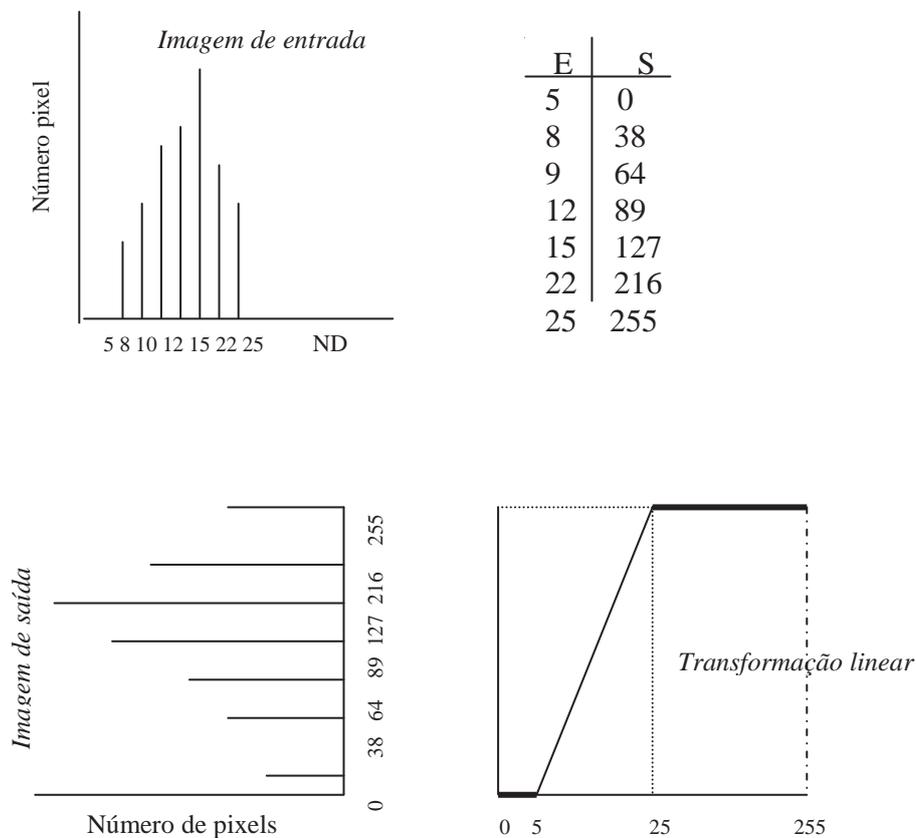


Fig. 7.5 Exemplo numérico e gráfico da ampliação dos valores de brilho de uma imagem pelo método de expansão linear.

Computacionalmente, os cálculos operacionais podem ser numericamente representados pela *Look up Table*, que relaciona os valores de brilho da imagem original aos correspondentes valores de brilho da imagem realçada. A LUT é feita mediante uma rotina computacional usando a equação de transformação selecionada para fazer o realce da imagem.

A Figura 7.6 mostra o resultado obtido de uma imagem realçada por ampliação linear, e seus respectivos histogramas. As duas barras no histograma da imagem original marcam o espaço no histograma onde todos os pixels com ND compreendidos entre os valores de corte mínimos e máximos optados pelo analista, serão expandidos para o intervalo total de 0 a 255.

A grande vantagem da função linear, como se observa nas imagens da Figura 7.6, é a manutenção na imagem realçada das relações originais de reflectância dos alvos. Não há alteração radiométrica da imagem. Por isso, a opção por ampliação linear é a mais preferida das opções para se aumentar o contraste espectral das imagens da maioria dos sensores multispectrais ópticos conhecidos. E, principalmente, quando na interpretação há interesse em estabelecer relações de análises comparativas da imagem com a reflectância dos alvos medida em campo ou laboratório. Não somente à geologia se deve dar preferência a esse tipo de contraste.

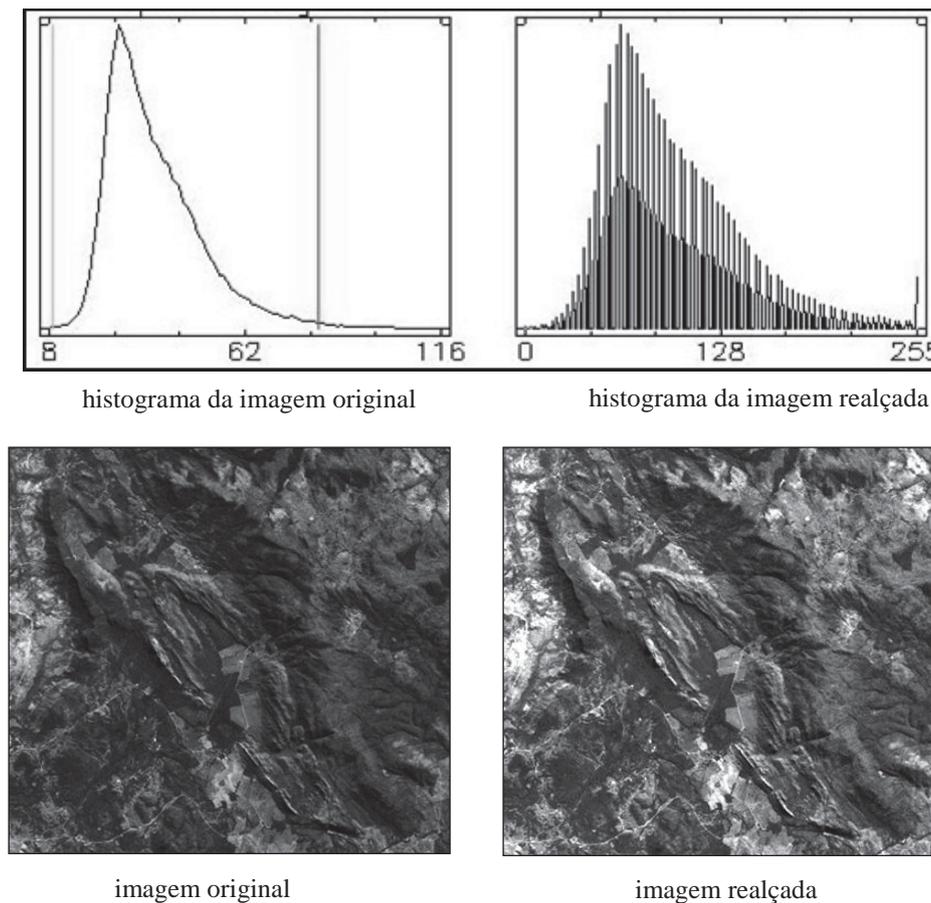


Fig. 7.6 Exemplo de realce de contraste por expansão linear histográfica de imagem ETM da banda 7 e respectivos histogramas da imagem original e modificada.

7.4 Expansão linear por partes

Como acabamos de ver, a técnica linear por saturação de contraste deve ser aplicada quando a imagem exibe um histograma com forma unimodal. Acontece algumas vezes que dependendo das características espectrais dos alvos presentes em uma área, o histograma pode se mostrar multimodal. Nesse caso, um procedimento similar de ampliação linear de contraste deve ser adotado, porém, separadamente, para cada concentração de níveis de brilho em torno de cada componente modal. Isso compreende em fazer um realce de contraste linear por partes. Considere os dois exemplos da Figura 7.7. No 1º caso, Figura 7.7a, tem-se um

histograma que exibe dois componentes modais, com a 1ª moda indicando uma grande concentração de pixels com níveis de brilho escuros, e a 2ª moda com menor número de pixels com valores de brilho mais claros. A maneira mais correta de realçar a imagem representada por esse histograma seria dar maior expansão à área de maior moda, região com níveis de cinzas mais escuros, e uma expansão menor da área com moda menor que é a dos níveis de cinzas mais claros. O procedimento para efetuar essa operação é mostrado no gráfico situado abaixo do histograma da Figura 7.7a, que mostra que o intervalo digital correspondente à moda da região escura, expande-se para um maior intervalo digital na imagem de saída. O 2º caso, Figura 7.7b, a maior expansão seria para a região de feições mais claras, que tem a maior moda. É o inverso ao do 1º caso, como mostra o procedimento exposto no gráfico abaixo do histograma.

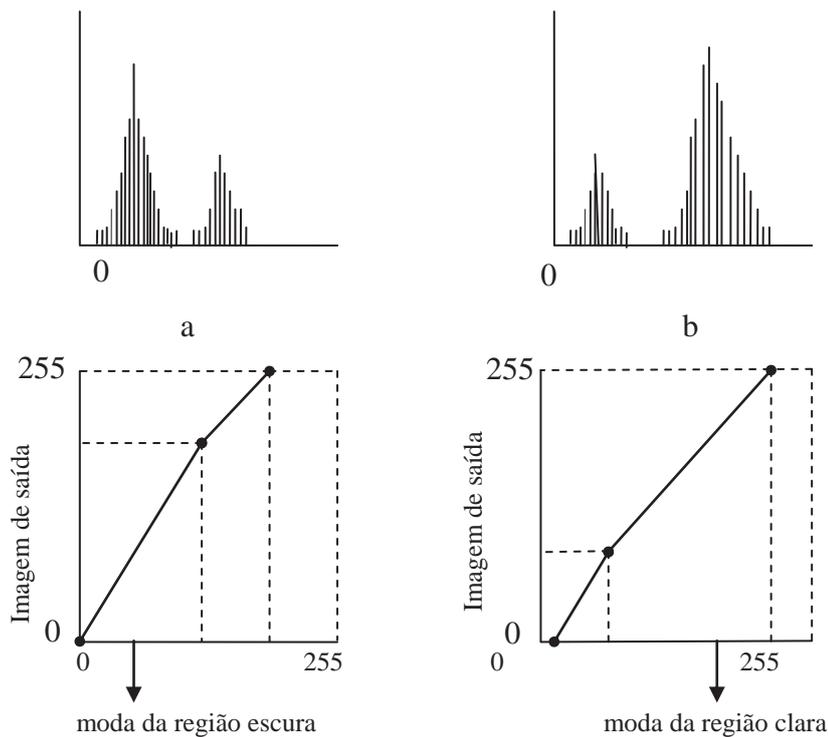
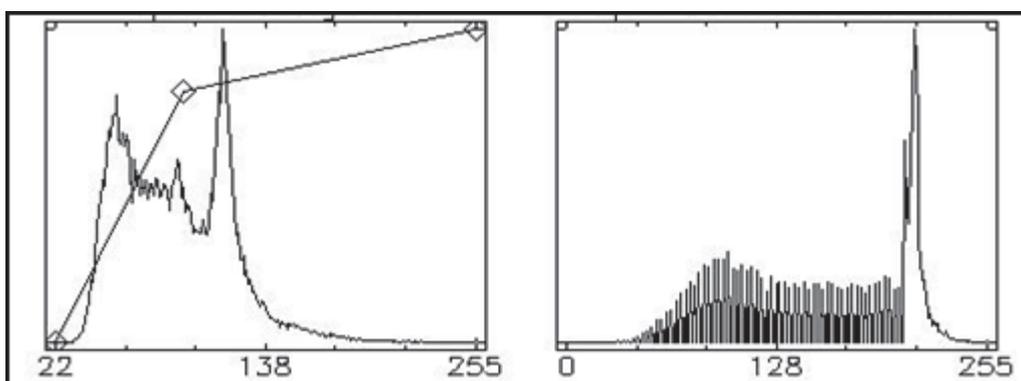


Fig. 7.7 Ampliação linear por partes com dois pontos de quebras. Nos dois exemplos a maior expansão linear de brilho é efetuada na região de moda maior.

Uma representação real dessa situação é apresentada na Figura 7.8 de uma área da cordilheira andina, com boa exposição de rochas. As áreas mais escuras são afloramentos de maciços rochosos e as áreas intermontanas, com tons de cinza medianos, são predominantemente coberturas inconsolidadas de sedimentos arenosos. No canto superior esquerdo da imagem há um depósito de sal (salar). Duas modas se destacam no histograma da imagem original e a ampliação linear por partes parece ser a opção correta. A opção neste exemplo foi para um forte aumento de contraste das áreas escuras, ampliando o intervalo digital da primeira moda (ND 22 a 98) para 0 a 215, e pouca expansão sendo efetuada nos alvos contidos da segunda moda, que têm desta forma, o contraste reduzido.

7.5 Expansão por Equalização

Quando o histograma da imagem é razoavelmente assimétrico, é impossível, simultaneamente, usando uma simples função linear, controlar o realce dos níveis de cinza medianos com maior população de pixels, e a quantidade de saturação nos extremos do histograma com menores populações. Para esse tipo de histograma será necessário usar uma transformação não linear para executar uma redistribuição dos valores de brilho, tal que os incrementos de ampliação do brilho da imagem sejam desigualmente distribuídos entre 0 a 255. Realces não lineares distorcem a radiometria da imagem e, portanto, são úteis apenas para interpretação visual.



histograma da imagem original

histograma da imagem realçada

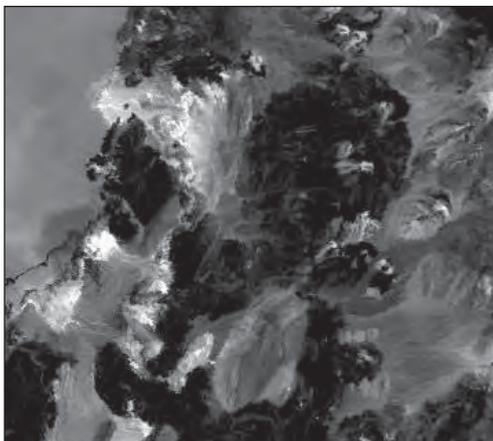


imagem original

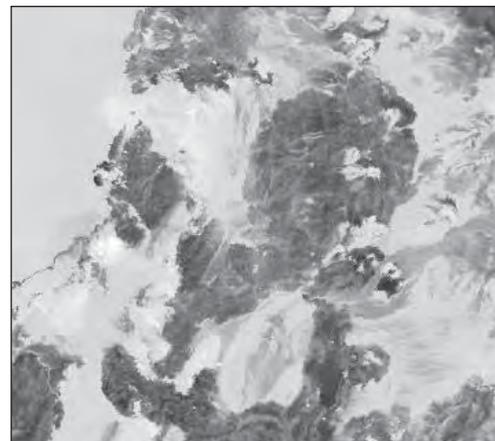


imagem com realce linear

Fig. 7.8 Ampliação linear por parte aplicada à imagem com duas modas distintas, como forma de expandir preferencialmente o agrupamento de pixels em torno da primeira moda.

Equalização refere-se ao fato de o histograma da imagem realçada ser aproximadamente igual em densidade (número de pixels/níveis de cinza), ou seja, a barra tem alturas aproximadamente iguais, dando a aparência de um histograma com uma forma quase

uniforme. Ao invés de ser uma modificação matemática presa à forma do histograma original, como condiciona a expansão linear, a equalização estabelece uma forma de histograma previamente concebida. Imagina-se que se o histograma tem barras da mesma altura, então ele mostrará uma imagem, onde há uma boa representação dos detalhes de todos os valores de brilho. Pode ser dito que a equalização de histograma é realizada com o objetivo de se normalizar a escala de brilho, o que traria resultados muito satisfatórios de realces de imagens. Na prática, verificamos que as imagens de sensoriamento remoto normalmente não exibem um histograma perfeitamente uniforme, tal como a técnica foi proposta. A equalização só conduz a histogramas efetivamente uniformes quando a gama de brilhos da imagem for contínua e se fosse infinito o número de pixels da imagem. Como consequência disso, a equalização tende a reduzir o contraste dos níveis muito claros e muito escuros, enquanto expande os níveis medianos que se transformarão em valores de brilho com maiores contrastes. A hipótese de haver uma vantagem dessa técnica em relação à forma de contraste linear é porque o estímulo de percepção visual do olho humano é não linear.

Em Richard e Jia (2006) encontra-se a demonstração matemática da função de mapeamento dos valores de brilho para calcular o contraste por equalização, que se resume na equação 7.2.

$$Y = \frac{L - 1}{N} C(x)$$

eq. 7.2

Na equação 7.2 Y representa os novos valores de brilho da imagem modificada. É exigido que o intervalo dos valores de brilho de Y seja de 0 a $L - 1$. N é o número total de pixels da imagem de entrada e $C(x)$ é o histograma acumulativo. Sendo assim, o aumento de contraste por equalização tem por base a função de distribuição acumulativa da imagem.

Os histogramas apresentados na Figura 7.9 correspondem à base de dados da Tabela 7.2. São dados de uma hipotética imagem com um total de 75 pixels, distribuídos em dezesseis classes de valores de brilho, apenas para simplificar os cálculos do exemplo que é apresentado. Os histogramas das figuras 7.9a, 7.9b e 7.9c são, respectivamente, da imagem original, dos valores acumulativos, e da imagem modificada.

A Tabela 7.1 contém os valores respectivos aos histogramas da Figura 7.9. A primeira coluna (i) são os valores das dezesseis classes de brilho da imagem original. Computado o valor acumulativo (iii) dos números de pixels da imagem de entrada (ii), primeiramente, calcula-se o valor do *novo fator de escala* (iv), que pela equação 7.1 corresponde à divisão $(L - 1)/N = 15/75 = 0,2$. Esses valores são aproximados para valores de brilho inteiros e discretos (v). Por último, para calcular a nova distribuição de número de pixels da imagem de saída, ou imagem realçada, relaciona-se os valores de brilho da coluna (v) com os números de pixels da coluna (ii). Aos valores de brilho que não há na coluna (v) são computados números de pixels zero. Observe no histograma da Figura 7.9c que o maior contraste ocorre para classes que ocupam a posição mais central do histograma. Portanto, o efeito da equalização aumenta o contraste no centro do histograma que tem mais densa população de pixels, enquanto reduz o contraste nas extremidades. Embora o pressuposto da equalização seja gerar uma forma histogrâmica com as classes (barras) com igual dimensão de número de pixel, isso não é totalmente conseguido, como se observa no histograma equalizado da Figura 7.8.

A equalização tem uma aplicação prática, além do simples propósito de aumentar o contraste de uma imagem. Nas aplicações de sensoriamento remoto é bastante comum haver a necessidade de se compor mosaicos com duas ou mais imagens, e neste processo, frequentemente as imagens tem entre si uma distribuição de brilho variada, ou por serem de datas diferentes ou por terem variações das condições atmosféricas de uma imagem para

outra. Nesse caso, para se ter um mosaico com aparência de brilho mais homogênea, é preciso realizar uma transformação nas imagens a fim de resolver as variações de brilho do mosaico. Essa tarefa se resume em equalizar os brilhos das imagens, por um processo igual ao apresentado, com a diferença de que o usuário deverá decidir pela escolha de uma imagem de referência, em relação à qual as outras imagens serão equalizadas. Todos os *software* de processamento executam essa operação de uma forma bastante automatizada, sem que o usuário tenha a necessidade de analisar os histogramas.

A função equalização tem uma restrição. Não deve ser aplicada em imagens que tenham uma área extensa e homogênea de brilho constante, como um grande corpo d'água. Isso porque a equalização tem como princípio criar um histograma uniforme na altura das barras, agrupando barras menores, e uma grande barra de uma única classe de alvo, interfere no histograma acumulativo, tendo como consequência a perda de contraste, o oposto pretendido.

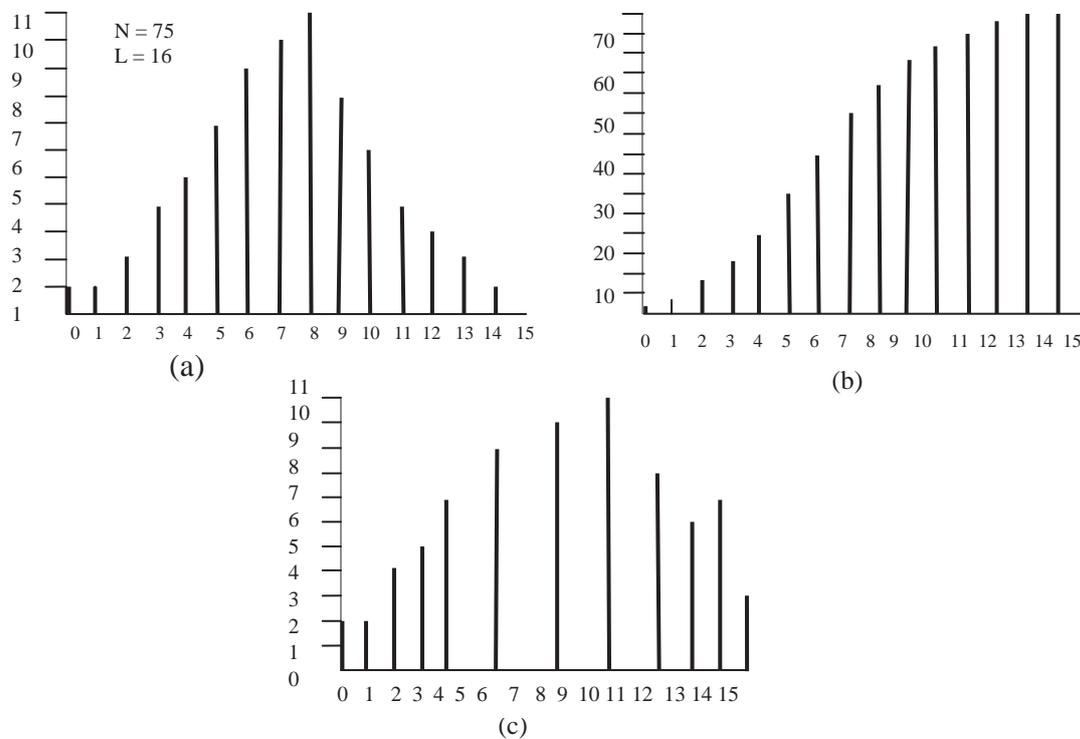


Fig. 7.9 Do topo para baixo, histogramas de uma imagem original imaginária, dos valores acumulativos e da imagem realçada por expansão por equalização.

Tabela 7.1 Dados do processo acumulativo de pixels para cálculo da equalização do histograma

(i) Brilho de entrada	(ii) Pixels por classe	(iii) Número pixel acumulativo	(iv) Novo valor de escala	(v) Aproximação do valor de brilho	(vi) Número pixel da imagem realçada
0	1	1	0,2	0	2
1	1	2	0,4	0	2
2	2	4	0,8	1	4
3	4	8	1,6	2	5
4	5	13	2,6	3	7

5	7	20	4,0	4	0
6	9	29	5,8	6	9
7	10	39	7,8	8	0
8	11	50	10,0	10	10
9	8	58	11,6	12	0
10	6	64	12,8	13	11
11	4	68	13,6	14	0
12	3	71	14,2	14	8
13	2	74	14,8	15	6
14	1	75	15,0	15	7
15	0	75	15,0	15	3

A Figura 7.10 é de uma imagem da banda 5 do sensor ETM-Landsat7, original e realçada, com expansão de histograma por equalização. Observe que na imagem equalizada a textura de relevo é mais notável, e as áreas onde houve perda acentuada de cobertura vegetal, expondo o solo, os valores dos pixels ficam saturados, haja vista que na imagem original já mostravam possuir valores de maior brilho.

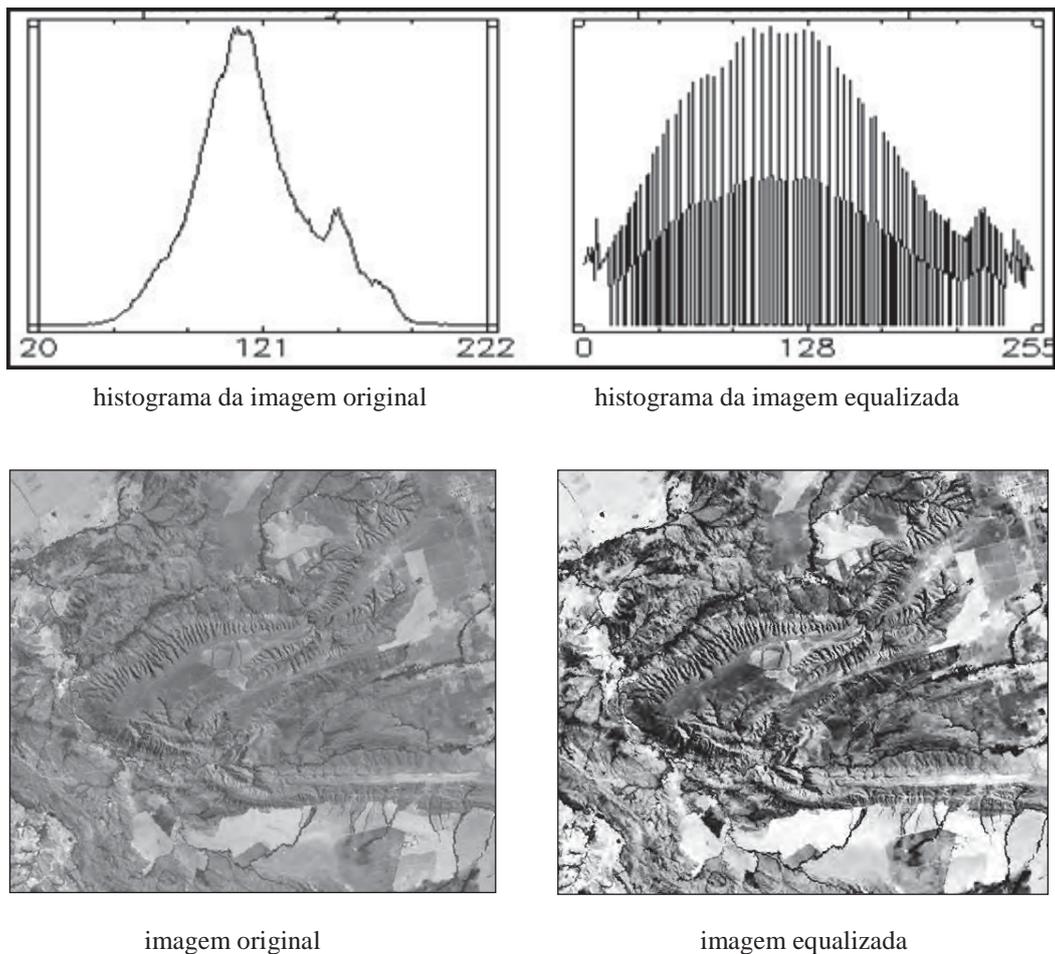


Fig. 7.10 Exemplo de realce de contraste de imagem por equalização e os histogramas equivalentes das imagens original e modificada.

7.6 Expansão Gaussiana

A proposta de expansão de histograma baseada em suposições gaussianas fundamenta-se nas formas dos histogramas que frequentemente são observadas nas imagens das diferentes bandas espectrais de sensoriamento remoto. Há uma tendência dos histogramas de muitas das bandas de um sensor apresentarem formas parecidas à de uma distribuição normal gaussiana ou log normal. Portanto, seria lógico imaginar que para algumas finalidades se poderia ajustar o mais próximo possível o histograma de uma imagem a uma forma pré-definida de um histograma com forma gaussiana. Tal qual o processo de equalização, que também força o ajuste do histograma da imagem original a uma forma histogrâmica pré-definida, o processo passa por um estágio de usar o histograma acumulativo da imagem original para se obter novos valores de distribuição de pixel da imagem de saída. É para isso, exigidos dois parâmetros para realizar um processamento estatístico de segunda ordem: a média e a variância. Segundo Schowengerdt (1977), ambos os parâmetros fornecem ao algoritmo meios convenientes para explicitamente controlar a média dos resultados, ao mesmo tempo em que varia o contraste controlando o desvio padrão. Aumentando o desvio padrão é conseguido um aumento da distribuição dos dados com aumento de contraste. A modificação gaussiana é um processo de normalização particularmente útil para igualar as imagens, em termos de média e desvio padrão, o que ajuda a obter composições coloridas, com bom equilíbrio de cores.

A função de densidade de probabilidade normal e sua forma analítica são mostradas na Figura 7.11. Os dois parâmetros que definem a distribuição são a média μ e o desvio padrão σ (equação 7.3). A área total sob a curva é unitária e a área dentro $+2\sigma - 2\sigma$ centrado na média é de 0,95, e a área de $+1\sigma - 1\sigma$ é de 0,68.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

eq. 7.3

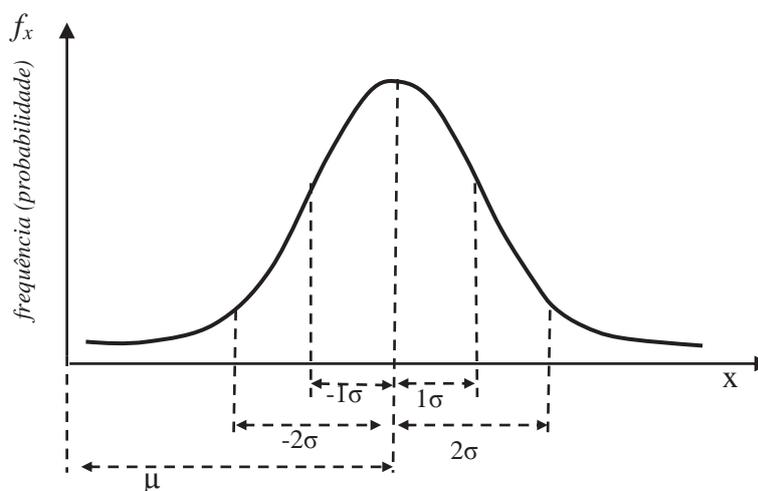


Fig. 7.11 Função de densidade de probabilidade normal, ou curva gaussiana.

A Figura 7.12 dá um exemplo de uma imagem realçada pela ampliação histogrâmica gaussiana. Como a curva de uma distribuição normal varia de menos infinito para mais infinito, no exemplo, um intervalo de ± 3 desvios padrões foi usado. Um maior ou menor número de desvios padrões pode ser especificado pelo usuário. O algoritmo define a priori qual é a probabilidade de cada classe de brilho da imagem original ser mapeada para novos valores de brilho, dentro de uma distribuição normal. Note no histograma transformado gaussiano que os extremos, áreas muito escuras ou muito claras, foram também realçados.

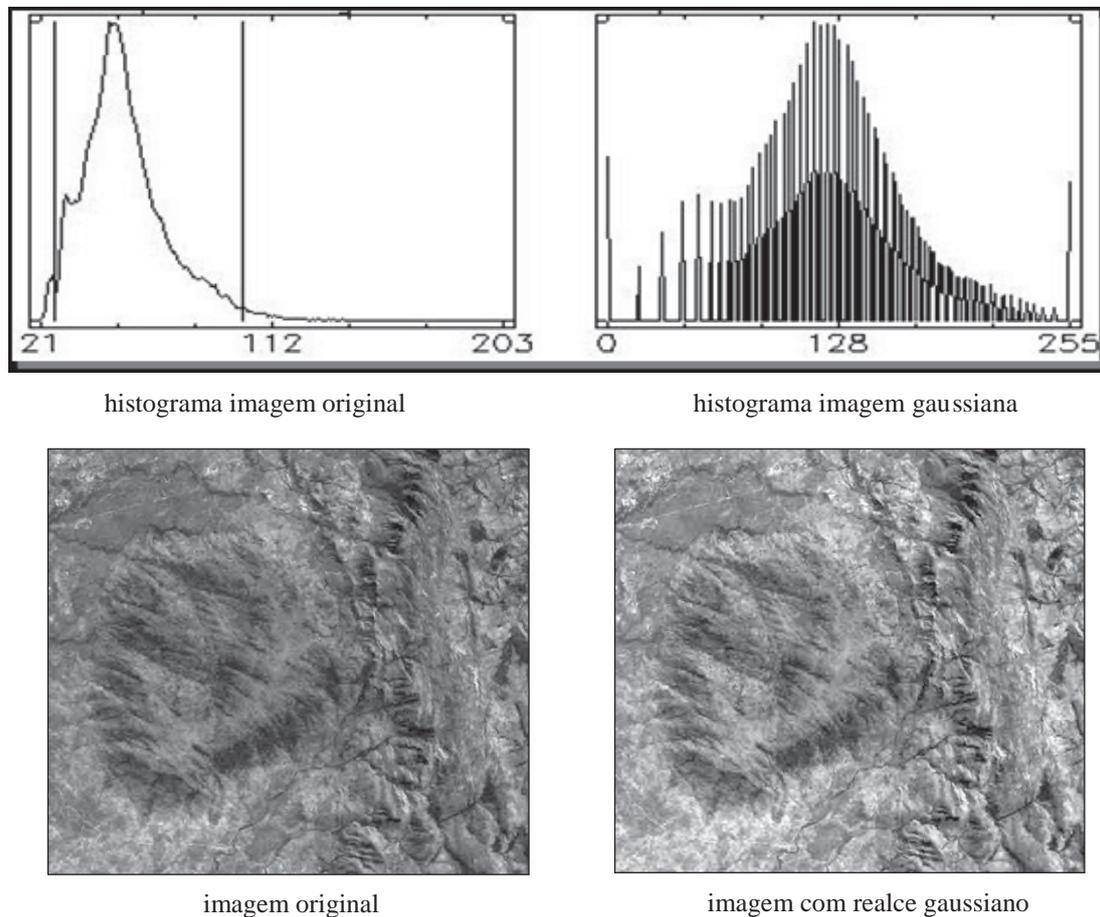


Fig.7.12 Exemplo de realce de imagem por ampliação gaussiana.

7.7 Função raiz quadrada

Quando algumas imagens apresentam uma distribuição dos dados marcadamente concentrada na porção de valores de brilho mais escuros do que nas porções mais claras, gerando um histograma de forma fortemente assimétrica para a esquerda, é desejável forçar uma maior intensidade de contraste, preferencialmente desta porção mais escura da imagem, e bem pouco da porção mais clara. A função de transformação não linear adequada a esse tipo de histograma é a raiz quadrada, que tem a seguinte formulação matemática:

$$g(l, p) = G \times \sqrt{g(l, p)} \quad \text{sendo} \quad G = \frac{255}{\sqrt{255}} = 15,9687$$

eq. 7.4

onde, $g(l,p)$ é o valor original do pixel e G é um fator de ajuste, a fim de manter os valores de brilho resultantes dentro do intervalo válido de quantização da imagem. Isso pode ser observado na Figura 7.13 pela inclinação da curva de transformação, que é mais acentuada no início do histograma, resultando maior separação das barras nesta região, com redução do número de barras na parte final, que é pouco realçada. Observe nas imagens correspondentes aos histogramas, que as áreas mais escuras na imagem original modificaram-se para valores de cinzas mais claros, visualmente mais discerníveis, aumentando a interpretabilidade da imagem.

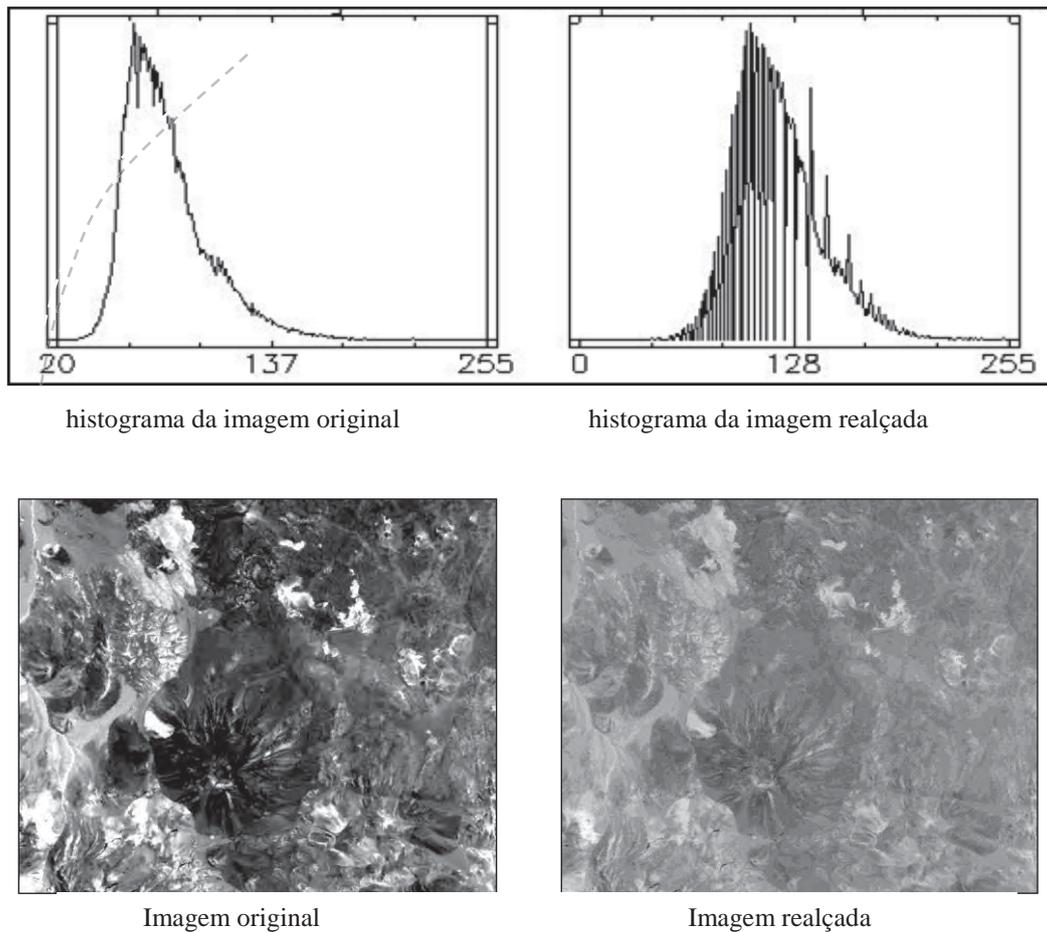


Fig. 7.13 Realce de contraste de imagem por meio de expansão histogrâmica função raiz quadrada de imagens com áreas de baixos valores de brilho.

Ao contrário, quando o histograma da imagem concentra os valores em níveis de brilho mais alto, a função de transformação passa a ser quadrática, que tem a seguinte formulação:

$$G(l,p) = G \times (g(l,p))^2 \text{ sendo } G = \frac{1}{255}$$

eq. 7.5

Nesse caso se propicia um realce maior nas áreas de intensidade média e clara da imagem. A inclinação da curva de transformação será mais acentuada no final do que no início do histograma, como mostra a Figura 7.14.

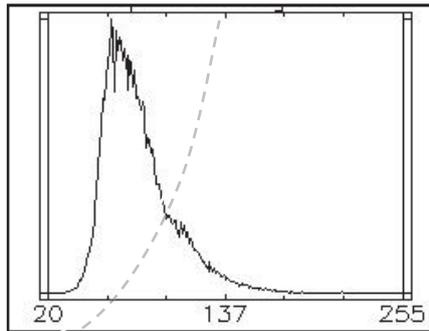


Fig. 7.14 Representação da função de transformação quadrática.

Equivalentes às funções raiz quadrada e quadrática são, respectivamente, as funções logaritmo e exponencial, com a diferença de que promovem o realce de um intervalo menor de níveis de brilho. Por isso as inclinações das curvas de transformações são mais inclinadas, como mostra a Figura 7.15.

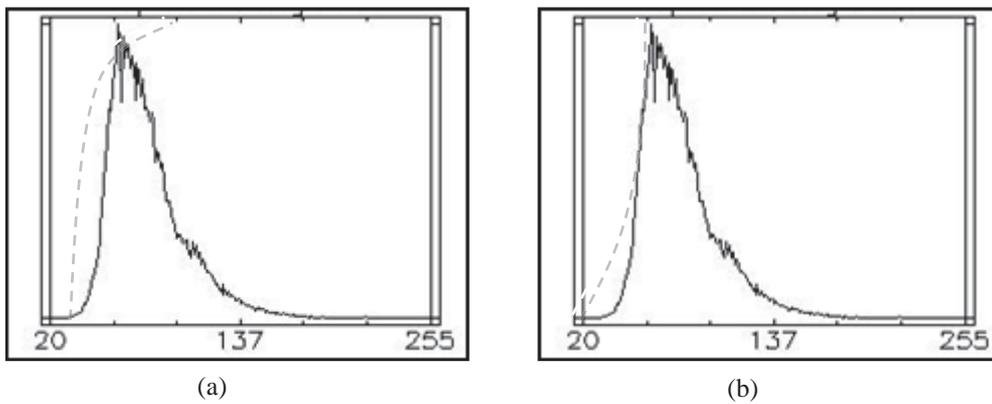
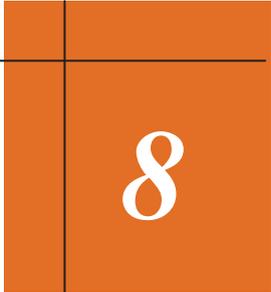


Fig. 7.15 Representações a) da função logaritmo e b) da função exponencial, com inclinações acentuadas das curvas.

MODELOS DE CORES APLICADOS ÀS IMAGENS

Paulo Roberto Meneses

8

8.1 Cor

Na interpretação de imagens de sensoriamento remoto, a extração de informações visando à identificação e discriminação dos objetos, depende, primordialmente, da forma de apresentação visual da imagem na tela do monitor. Uma das formas mais comum e eficiente é por meio de imagens coloridas, pela simples razão de que a visão humana é colorida.

O termo cor é usado para referir-se a um aspecto da experiência visual de percepção. Para descrevê-la usamos vários atributos, como a cor dominante, o brilho, ou se ela é clara, escura ou acinzentada. Há também fatores físicos que podem ser considerados e que afetam esses atributos, como a iluminação da cena, a natureza da superfície e até a atitude do observador. Isso torna muito difícil obter medidas quantitativas precisas da magnitude de percepção da cor. Matematicamente, para dimensionar uma cor seria preciso numerar os vetores que são necessários para caracterizar diretamente a percepção de cor. Essa formulação matemática tem que estar de acordo com as teorias que tentam explicar como o olho humano enxerga as cores, as quais usam de conceitos ópticos físicos e psicofísicos, para explicar a resposta interna aos estímulos externos de cores.

Experimentos realizados a partir de misturas de cores mostraram que a combinação de três independentes estímulos de diferentes composições espectrais é necessária para produzir a percepção visual de todas as cores. Isto é facilmente conseguido por meio da mistura espacial de três focos de luzes básicas, azul, verde e vermelha, com variações independentes de ajustes de suas intensidades. É possível representar graficamente, numericamente, ou em notação vetorial, essa mistura aditiva das três cores básicas, como é mostrado na Figura 8.1. Nesta figura, o espaço piramidal é definido pelos vetores divergentes. Uma seção transversal deste espaço define um plano triangular, onde quantidades proporcionais da energia de cada cor primária podem ser representadas ao longo dos lados do triângulo. Um gráfico desta espécie é chamado de triângulo de cor. No triângulo de cor a natureza de qualquer estímulo de cor, resultante da proporção de misturas das cores primárias, pode ser representada com um ponto dentro do triângulo. Nessa forma geométrica qualquer cor pode ser expressa por coordenadas, chamadas de coordenadas de tricromacidade. Em 1931 a *Commission Internationale de l'Eclairage* (CIE) adotou um sistema de especificações triestímulo como o padrão internacional para colorimetria. Foram estabelecidos os valores de comprimentos de onda 435,8 nm, 546,1 nm e 700 nm para representarem espectralmente as três cores básicas, azul, verde e vermelha, respectivamente.

Foi com base nessa teoria triestímulo que se modelou a percepção visual de cores e se criaram as formulações computacionais, para usar a cor como forma de exposição de imagens multispectrais de sensoriamento remoto e, através de técnicas de processamento, realçar a extração da informação da imagem.

Como será visto neste capítulo, é através dos algoritmos de processamento de cores, usualmente utilizados em processamento de imagens, que o espaço de coordenadas configurado para representar computacionalmente as cores, pode ser obtido por vetores que compõem os três eixos ortogonais de um cubo de cores tricromáticas RGB, ou como outra

opção, usar o espaço hexacone para representar a cor por atributos do brilho, matiz e saturação da cor (IHS). Isso significa a aceitação de dois modelos para explicar o que é a cor: modelo RGB e modelo IHS. A representação desses dois modelos, respectivamente, nos espaços do cubo e do hexacone, foi a forma encontrada para uma simplificação computacional confiável e ajustada aos instrumentos de reprodução da cor, os monitores.

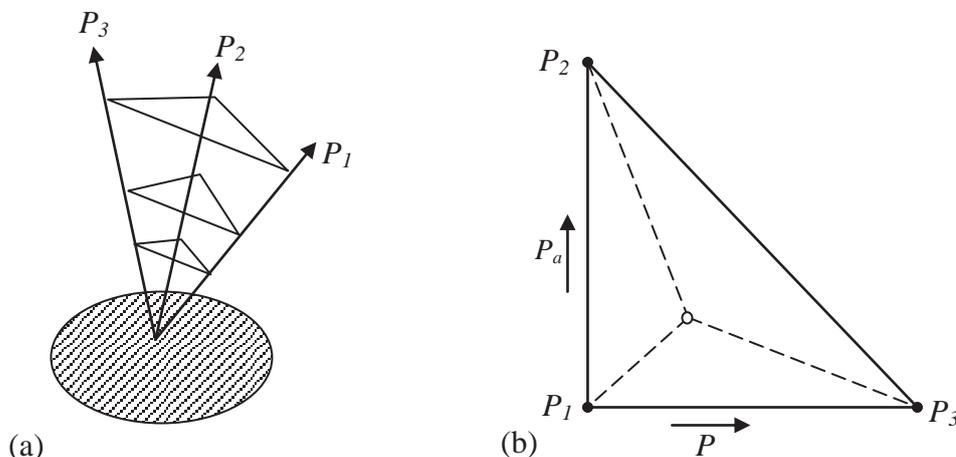


Fig. 8.1 **a)** As quantidades de energia de cada uma das três luzes básicas (P_1 , P_2 , P_3) são ilustradas como vetores e qualquer combinação dessas quantidades define um plano triangular. **b)** A projeção do plano triangular fornece o diagrama de vetores no qual as quantidades relativas das cores básicas podem ser expressas com posições de coordenadas. (Fonte: Bartleson, 1995).

Qual é a importância da cor para a visualização das imagens multiespectrais de sensoriamento remoto? Se considerarmos que fisiologicamente a visão humana tem uma baixa percepção para discriminar níveis de cinza, essa seria uma das respostas a esta questão. Apenas para exemplificar, deve-se lembrar que para interpretar fotografias aéreas preto e branco, recorre-se à visão estereoscópica para observar os detalhes espaciais das feições, e muito pouco se utiliza da análise dos tons cinza para identificar as suas propriedades. Por esse fato, torna-se óbvio que a visualização em preto e branco das bandas individuais de um sensor não é a forma mais ideal para se analisar o conteúdo de informação dos dados. Os métodos de ampliação de contraste vistos no capítulo anterior ajudam a melhorar essa deficiência, mas dificilmente conseguem garantir que todas as informações contidas nas bandas serão visualmente reconhecidas pelo fotointérprete. Por essa razão, quando se modifica o contraste das imagens os resultados poderão ser melhores avaliados quando as imagens são combinadas para formar composições coloridas. As composições coloridas procuram reproduzir padrões de cores, combinando as bandas de um sensor com as cores básicas azul, verde e vermelho.

A intenção de usar a cor pode ser apenas para expor visualmente as imagens para facilitar algumas operações simples, como escolha de pontos de controle para registro, ou seleção de amostras de áreas para uma classificação supervisionada, mas o uso mais importante é propiciar uma alta qualidade de extração de informações, para fins de mapeamentos temáticos. Não são apenas as imagens realçadas por modificação de histogramas que são usadas para compor uma imagem colorida. Há diversas outras técnicas que consideram as medidas de atributos da cor para configurar um algoritmo de processamento, como por decorrelação de bandas ou fusão de imagens com diferentes resoluções espaciais.

8.2

Fatiamento de histograma

O procedimento mais simples para associar cor a uma imagem é por meio do fatiamento dos valores de brilho, processo que alguns pesquisadores consideram ser uma forma de realce de contraste, muito embora, de fato não é realizada uma operação matemática ou estatística de transformação da imagem.

O fatiamento dos valores de brilho de uma imagem (*density slice*) consiste num processo de dividir o intervalo digital mínimo-máximo de uma banda selecionada, em subintervalos digitais especificados pelo analista. Os pixels que estiverem dentro de um intervalo digital são convertidos para um único valor e visualmente mapeados a uma cor escolhida. Se o analista decidir dividir o histograma em dez fatias, a imagem de saída terá dez variações de cores, selecionadas de uma paleta de cores. As cores dessa banda são denominadas de pseudocores, apenas para diferenciar esta imagem colorida de uma composição colorida padrão RGB. É uma forma simples de dar cor a uma imagem de tons de cinza. Porém, ao se agrupar pixels em um intervalo de brilho, o número total de valores discretos de brilho é reduzido, e alguns detalhes da imagem são perdidos.

O valor dessa técnica é transformar sutis variações de níveis de cinza que não foram visualmente percebidas pelo analista, e que poderiam estar representando pequenas diferenças de um alvo aparentemente homogêneo. O resultado é bastante parecido com uma classificação do tipo paralelepípedo, assunto este a ser visto bem mais adiante. A Figura 8.2 mostra a aplicação de fatiamento para um depósito salar nos Andes argentino, com exposições de sais de bórax e halita, em proporções variadas. Dificilmente, dois intérpretes chegariam a um mesmo resultado de mapeamento visual das variações dos níveis de cinza que esta imagem apresenta. Bons resultados também seriam obtidos para o mapeamento de plumas de dispersão de sedimentos em corpos d'água, propiciando mapeamentos mais detalhados do que por um processo visual.

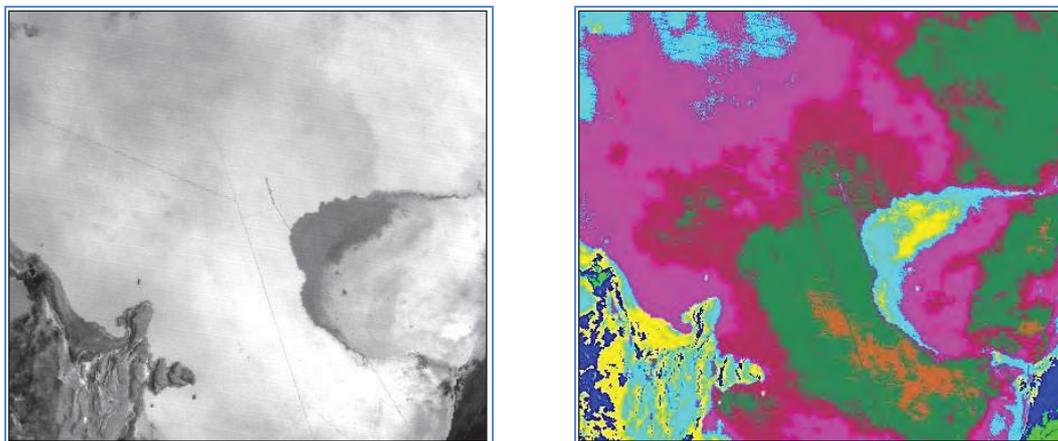


Fig. 8.2 Banda do infravermelho próximo de um salar andino e pseudocores obtidas pelo fatiamento dos níveis de cinza da imagem.

8.3

Espaço de cor RGB

O sistema de cor RGB é o mais usado entre os modelos de cores, especialmente para imagens de 8 bits. De acordo com a teoria de mistura de cores, a luz visível, quando passa

através da pupila é focada na retina pelas lentes oculares. Na retina há um grande número de células fotoreceptoras, altamente especializadas, conhecidas como cones e bastonetes, e que estão conectados por uma rede de fibras nervosas ao nervo óptico, ao longo das quais a energia luminosa detectada pelo olho vai ao cérebro, formando a imagem visual. Há cerca de 5 milhões de cones e 120 milhões de bastonetes. Os bastonetes respondem à luz de baixos níveis de iluminação (*Intensidade*) adaptando-se à subobscuridade. Os cones realizam a distinção de matiz (*Hue*) e a percepção de pureza (*Saturação*). A cor, ou mais apropriadamente *hue*, imagina-se ser associada com a visão diurna dos cones, porque há três tipos de cones, cada um sendo responsável pela criação de cada uma das três cores primárias, azul, verde e vermelho. Por isso, é chamada de teoria triestímulo da visão humana da cor. O mais interessante dessa teoria triestímulo, além de sua simplicidade, é porque ela dá a idéia de que as cores podem ser formadas pela soma de vermelho, azul e verde em várias combinações de intensidades. Dessa forma, se imaginarmos que cada cor possui uma intensidade bem definida, ao se tomar uma fração da intensidade da cor e somá-la à outra, cria-se uma nova cor (*C*), que pode ser expressa por meio da conhecida equação de adição de cores.

$$C = x_1B + x_2G + x_3R \quad \text{eq. 8.1}$$

No algoritmo do modelo do espaço de cor para as imagens de sensoriamento remoto, as intensidades x_1 , x_2 , x_3 , são determinadas pelos valores digitais de brilho das bandas. Em obediência à teoria triestímulo da percepção da cor, o modelo concebido baseia-se na adição de um triplete de bandas, às quais são associados livremente os canais das cores azul, verde e vermelho do monitor. Esse sistema é conhecido como sistema de cores RGB (*red, green, blue*).

Na Figura 8.3 está esquematizado o processo de display da imagem no computador, onde três bandas são processadas por três *Look-Up Tables* (LUTs) para converter os números inteiros de cada banda da imagem digital (*NDs*), para valores analógicos discretos de níveis de cinza (*NCs*), que são armazenados na memória de vídeo do monitor. Para cada banda de 8 bits de resolução radiométrica há 256 níveis de cinza possíveis, havendo, portanto 256^3 possíveis vetores RGB, muito embora, os monitores não tenham capacidade para expor todas essas cores. Isso não é um problema, porque esse número de cores não é atingido devido ao fato de cada banda ocupar apenas um pequeno intervalo de valores digitais do intervalo total.

O sistema de cores RGB tem como qualidade destacada a liberdade para o analista explorar as possíveis combinações de três cores com três bandas, para obter a imagem colorida de melhor contraste. Embora o apelo visual das cores seja dependente da qualidade de contraste de cada banda, ele é controlado pela escolha adequada das bandas em função do comportamento espectral dos alvos presentes na imagem. Isso requer do fotointérprete experiência e conhecimento sobre o comportamento espectral dos alvos. Não basta apenas habilidade do intérprete em processamento de imagem.

A cor é um recurso imperativo no uso de imagens multiespectrais da faixa óptica do espectro eletromagnético, mas composições coloridas podem ser obtidas com qualquer outro tipo de imagem, como de imagens termais multibandas do sensor ASTER ou de imagens de radar de modo multipolarimétrico do RadarSat.

A regra universal de adição das três cores primárias, azul, verde e vermelho, é mostrada na Figura 8.4. A combinação da projeção dos focos de luzes azul, verde e vermelho resulta no branco, e a combinação em par das cores azul + verde resulta na cor ciano, o par de cores azul + vermelho resulta na cor magenta, e o par de cores verde + vermelho na cor amarela. Milhões de cores poderão ser obtidas variando a intensidade de luz de qualquer uma das três cores primárias.

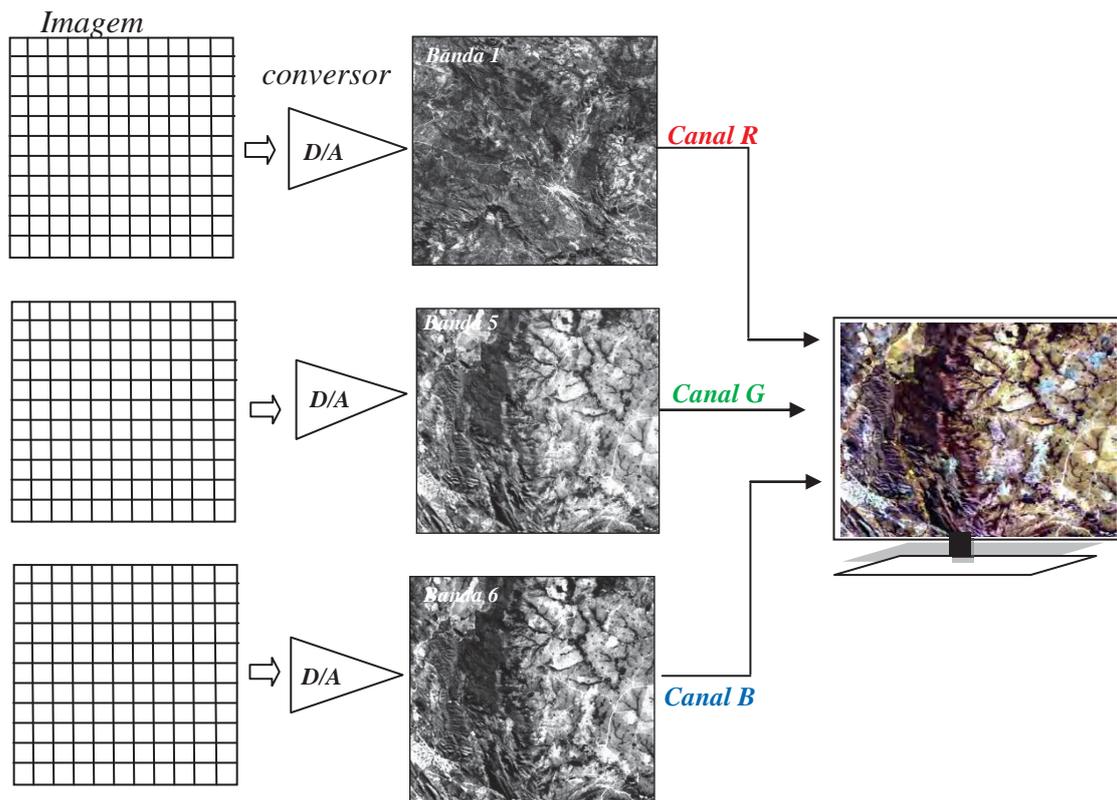


Fig. 8.3 Conversão de uma imagem digital para analógica no processo de formação de uma composição colorida padrão RGB.

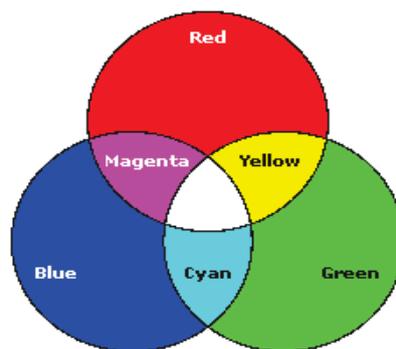
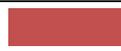


Fig. 8.4 Combinação aditiva das cores RGB, gerando as cores secundárias ciano, magenta e amarelo.

Em termos instrumentais, os monitores coloridos são constituídos de materiais fotossensíveis às três cores primárias, que se iluminam como um pequeno ponto de luz colorido. A iluminação da tela é produzida por correntes de elétrons, cujas intensidades são determinadas pelos valores de brilho dos pixels da imagem. Quando uma imagem é carregada na tela, um pixel da imagem ocupará um correspondente pixel do monitor. Dessa forma, cada pixel da tela registrará a combinação das três cores, com intensidades correspondentes aos

valores dos pixels das três bandas combinadas. Suponha uma imagem com os seguintes valores: na banda 1 o pixel tem um valor digital 255 e foi, opcionalmente, endereçado ao canal de vídeo R do monitor; na imagem da banda 2 o pixel tem também valor 255 e foi endereçado ao canal G; e na banda 3 pixel tem valor 0 e foi endereçado ao canal B. Os valores digitais 255 acenderão na tela do computador altos valores de brilho de cor vermelha e verde para as bandas 1 e 2, respectivamente, enquanto o valor digital mínimo 0 não acenderá nenhuma intensidade de azul no monitor. A soma das intensidades de brilho das cores, R intenso + G intenso + B nulo, resulta em um pixel na tela de cor amarela (Y). A Tabela 8.1 contém alguns exemplos de cores resultantes das combinações dos valores digitais com as cores básicas RGB.

Tabela 8.1- Notações de cores RGB correspondentes aos valores digitais de três bandas.

	192, 80, 77
	84, 141, 212
	0, 255, 0
	255, 0, 255
	102, 204, 255
	215, 246, 20
	255, 0, 102
	128, 128, 128
	11, 131, 62

De acordo com os exemplos da tabela acima vemos que a cor dominante é controlada pelo pixel ou pixels que possuem maior valor digital, ou seja, maior radiância. Como os *hardware* de monitores são padronizados pelo sistema RGB, qualquer outra representação de cor em imagem tem, obrigatoriamente, de ser transformada para o sistema RGB, para que possa ser exposta em monitores coloridos.

O espaço de cores desse modelo computacional de mistura das cores RGB é representado pelo cubo de cor, como mostra a Figura 8.5. O modelo do cubo é intuitivamente relacionado com o modelo triestímulo da visão humana e com o mecanismo de cores dos monitores. Os valores de níveis de cinza de cada banda irão constituir no sistema de coordenadas RGB os eixos ortogonais do cubo de cor. O intervalo de valor de brilho da imagem define o tamanho dos eixos do cubo de cores RGB, que para imagens quantizadas em 8 bits é 256. Portanto, cada pixel da imagem nesse sistema de cor é representado por um vetor que estará de algum modo dentro dos limites do cubo de cor. Note na figura que os vértices do cubo representam as cores aditivas primárias e secundárias, e o eixo diagonal com origem no centro do cubo e em direção ao vértice oposto às cores, contém os tons de cinza. Sobre as arestas do cubo localizam-se as cores saturadas neste espaço. Cor saturada não significa cor pura, como as cores definidas em 1931 pela *Commission Internationale de l'Eclairage*, onde cores puras são somente aquelas localizadas no contorno do diagrama de tricromaticidade. Dessa forma, o uso do cubo de cor não é capaz de reproduzir cores puras, apenas cores saturadas.

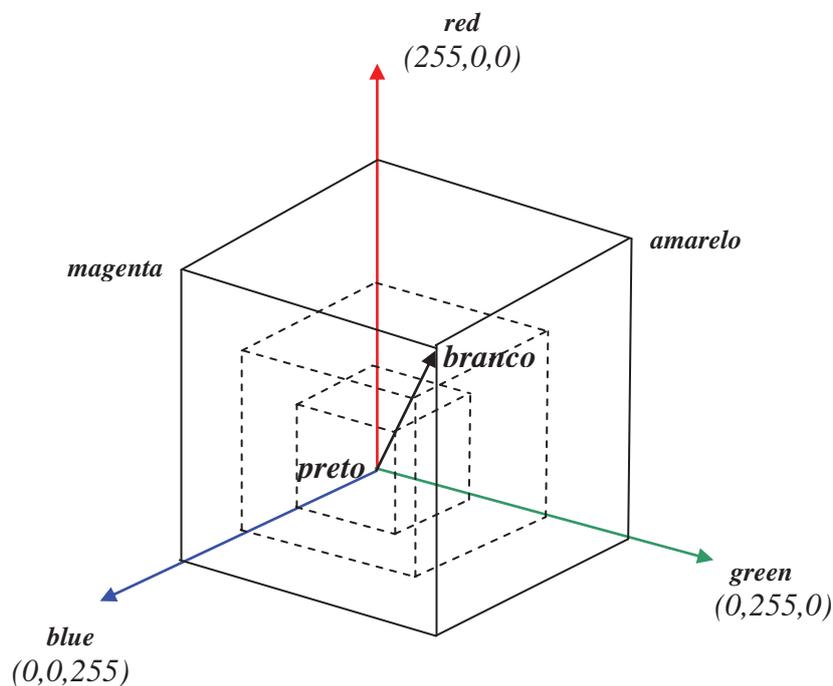


Fig. 8.5 Representação do espaço de cubo de cores RGB para construção de imagens coloridas.

A melhor combinação de cores para um tripleto de bandas é uma decisão a ser tomada pelo analista. Isso pode parecer simples, mas se considerarmos o número de possíveis combinações coloridas, como no cálculo abaixo, com seis bandas permutadas com três cores, a tarefa é quase impossível.

$$nPr = \frac{n!}{(n-r)!} \quad \text{com 6 bandas} \quad nPr = \frac{6!}{(6-3)!} = 120 \text{ combinações possíveis}$$

Para resolver o problema, o intérprete deve fazer a seleção de três bandas que possuam o máximo da informação desejada. Com imagens de um sensor óptico, um prático recurso para isso é plotar em um gráfico os padrões de reflectâncias dos alvos que se deseja discriminar na imagem, e nele indicar as posições das bandas. As melhores bandas são aquelas situadas nas regiões de maior diferença de reflectância entre os alvos, como exemplifica a Figura 8.6, com as bandas do sensor ETM. Nesse exemplo, a melhor composição colorida seria com as bandas 4, 5, e 7. Pelo fato de os comprimentos de onda destas bandas não serem do visível, a composição colorida por elas formada é chamada de falsa cor. Para se ter uma composição colorida que se aproxime da visão humana, deve ser usado um tripleto de bandas com comprimentos de onda situados exclusivamente no visível. No exemplo mostrado na Figura 8.6, essa composição seria com as bandas 1, 2 e 3.

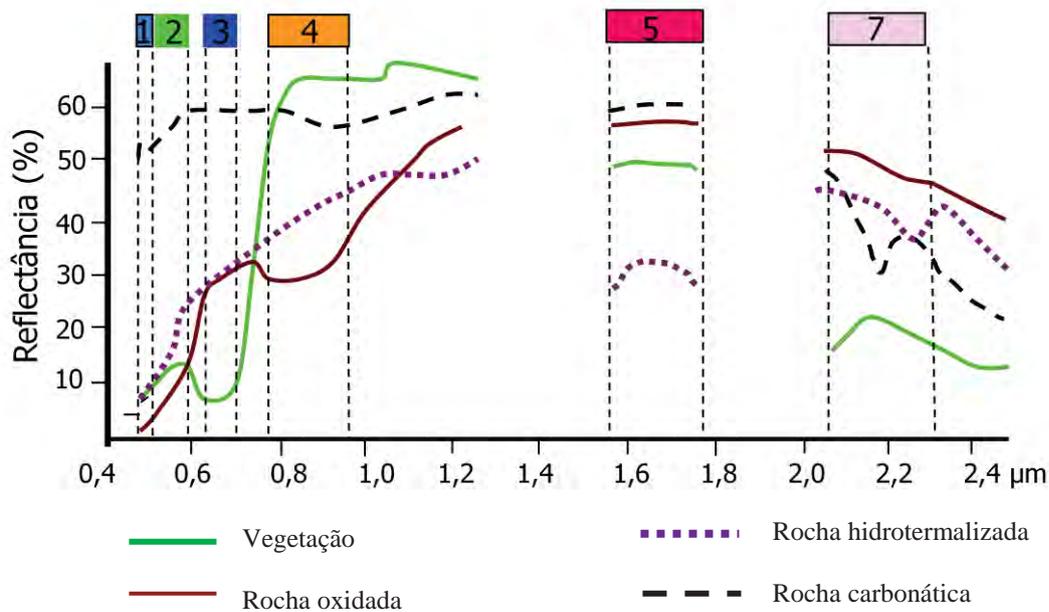


Fig. 8.6 Espectros de reflectância de quatro materiais e as posições das bandas do sensor ETM como meio prático para selecionar três bandas que melhor possam identificar esses materiais.

Uma vez selecionado o tripleto de bandas há um aspecto interessante que deve ser considerado na escolha de atribuir as cores às bandas. Experimentos mostram que o número de bastonetes sensíveis ao azul é muito menor do que para as cores vermelha e verde, e por isso, a sensibilidade da visão humana às cores azuis é mais baixa do que às cores verde e vermelha, como mostra a Figura 8.7. Em função disso, é aconselhável que ao se montar uma composição colorida deve-se associar a cor verde ou a cor vermelha à banda de maior variância, portanto, de maior contraste, destinando a cor azul à banda de menor variância. Pode-se constatar isso nas composições coloridas exibidas na Figura 8.8. São imagens obtidas pela combinação das bandas 3, 4 e 5 do sensor ETM do satélite Landsat 7. Dessas três bandas, a banda 5 é a que apresenta a maior variância. Observe, quando a ela é destinada a cor verde ou vermelha, a composição aparenta maior impacto visual do que quando se associa a ela a cor azul, muito embora todas as três composições contenham o mesmo nível de informação.

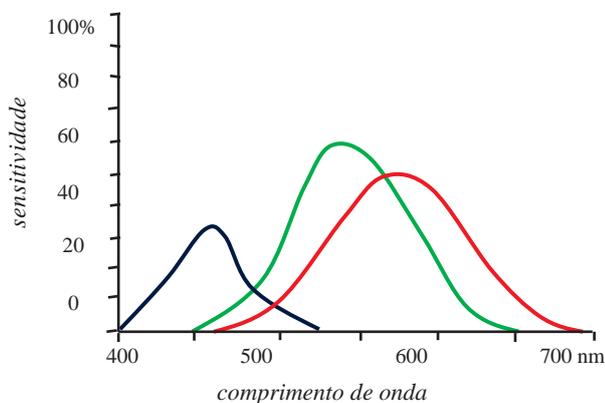


Fig. 8.7 Diferenças de sensibilidade do olho humano às cores azul, verde e vermelha

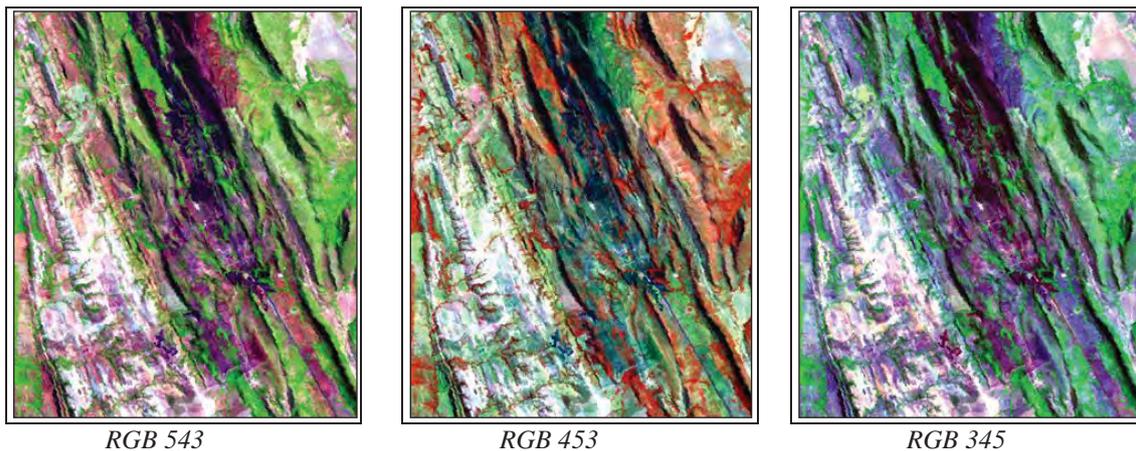


Fig. 8.8 Impacto das cores na composição colorida obtida com a associação das cores verde ou vermelha de maior percepção do olho humano, à banda de maior variância (banda 5).

8.4 Espaço de cor IHS

No espaço de cores RGB os eixos do cubo representam a quantização da radiância referente aos comprimentos de onda de um tripleto de bandas, resultando em imagens coloridas, que satisfazem a maioria das necessidades do intérprete. Contudo, ao se descrever a cor de um objeto, frequentemente nos referimos, por exemplo, se aquela cor vermelha é brilhante, clara ou escura, ou mesmo se é uma cor pura. Essa é uma forma de se descrever a cor por meio da percepção fisiológica humana, através de três atributos: intensidade, hue e saturação, que são grandezas quantitativamente especificáveis e independentes, sob o ponto de vista de percepção visual. Diz-se, então, que Intensidade (I), Hue (H) e Saturação(S) são atributos da cor, fortemente, percebidos pela visão. Dependendo dos valores dos dados das bandas, esses atributos possuirão valores bem diferentes de imagem para imagem.

O problema das imagens coloridas RGB é que os ajustes das cores que são feitos nos monitores, através de manipulações de ganho e brilho aplicados a cada cor básica alteram, simultaneamente, os valores de intensidade, matiz e saturação, prejudicando, assim, o processo de análise visual dos objetos presentes na imagem (Dutra e Meneses, 1986, 1987). No espaço IHS é possível manipular cada componente separadamente, obtendo dessa forma, maior controle sobre o realce de cor, através de deslocamento e operações lineares e não lineares sobre os componentes I, H e S.

O sistema IHS não é uma teoria de cor, mas outra forma de igualmente modelar uma representação espacial desses três atributos, para a mesma cor obtida pelo espaço de cubo de cor. Ou seja, é uma transformação numérica do espaço de cor RGB para o espaço IHS. Define-se intensidade (I) como a quantidade de brilho de uma cena, o que é uma medida do albedo refletido das partes iluminadas e sombreadas de todos os alvos presentes na imagem. É o equivalente a ver uma cena colorida, com uma visão em preto e branco. Assim, a intensidade é independente dos atributos saturação e hue, que são apropriadamente, os atributos da cor. Saturação (S) é o grau de diluição de uma cor pura por luz branca, e por isso é também chamada de pureza da cor. E hue (H) ou matiz define a cor espectral dominante. Na transformação IHS a imagem hue derivada de três bandas é livre de sombra, porque os valores dos pixels na imagem hue são independentes de iluminação e estão apenas relacionados às assinaturas de reflectância das três bandas.

Para se usar IHS como uma opção de processamento de cor deve-se seguir os passos indicados na Figura 8.9. Com três bandas selecionadas executa-se a transformação do espaço cúbico RGB para o espaço IHS, obtendo-se separadamente os componentes de intensidade (*I*), hue (*H*) e saturação (*S*). Nesse processo não há um deslocamento numérico da cor, uma característica que não é geralmente verdadeira, quando os componentes R, G, e B no cubo de cor são contrastados por um realce tipo linear. Mudanças de contrastes em H ou S devem ser feitas por transformações apropriadas, como forma de se ter maior controle sobre os realces das cores da imagem. Com a aplicação da transformação IHS inversa volta-se ao espaço de cores RGB, para que se possa observar a imagem nos monitores coloridos. Além disso, é possível aplicar filtros passa-altas nessas composições de maneira a ressaltar os detalhes espaciais.

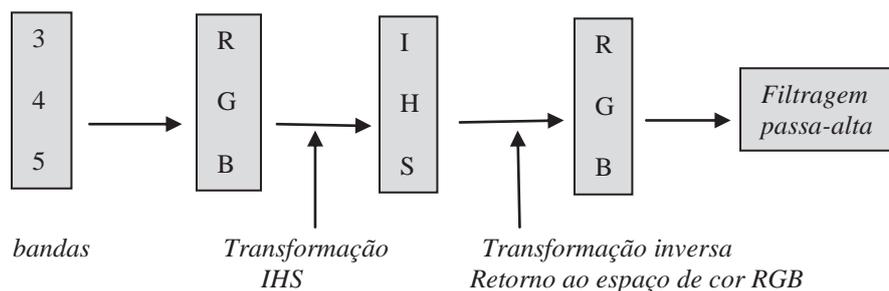


Fig. 8.9 Etapas do processo de transformação do espaço de cores RGB para o espaço IHS.

Um exemplo da transformação para o espaço de cores IHS é mostrado na Figura 8.10, a partir do tripleto de bandas 3, 4 e 5 do sensor ETM. Os histogramas são apresentados para demonstrar o primeiro passo do processo de transformação, que consiste em extrair do conjunto das três bandas os três componentes independentes que caracterizam a cor. Note que os intervalos digitais de 0 – 255 das bandas são convertidos para 0 -1 para os componentes I e S, e o componente hue é expressa em ângulos de 0° a 360°. Antes dos componentes serem revertidos para o espaço RGB, a fim de serem visualizados na tela, o analista pode ajustar cada componente por métodos de realce de contraste. A diferença desse ajuste com os ajustes feitos no espaço RGB, é que no espaço IHS a mudança de cores se apresentará uniforme. Nesta figura são mostradas para efeitos de comparação, a composição colorida no espaço de cor IHS e a composição colorida no espaço de cor RGB. Observe que a imagem IHS retrata de forma bem mais contrastante e com finos detalhes, as variações de cores, as quais na imagem RGB são mais difíceis de serem percebidas. Há uma pequena perda de textura do relevo, porque no processo de transformação as sombras são computadas como valores de brilho.

Para descrever o modelo geométrico do espaço de cor IHS usa-se normalmente um hexacone, que é representativo da maioria das versões de algoritmos usados em processamento de imagens equivalentes ao IHS, como o HSV (value), e o HLS (lightness). *Value* e *Lightness* são atributos com equivalência ao atributo intensidade I. Outra conhecida transformação é o HSV (Munsell) que se baseia na carta de cores de solos e rochas, mas que utiliza a geometria de um cilindro. Variações dessas representações são possíveis e, praticamente, não se nota diferenças significativas de resultados de processamento entre estes algoritmos. A base da transformação, descrita a seguir, é a mesma para todos.

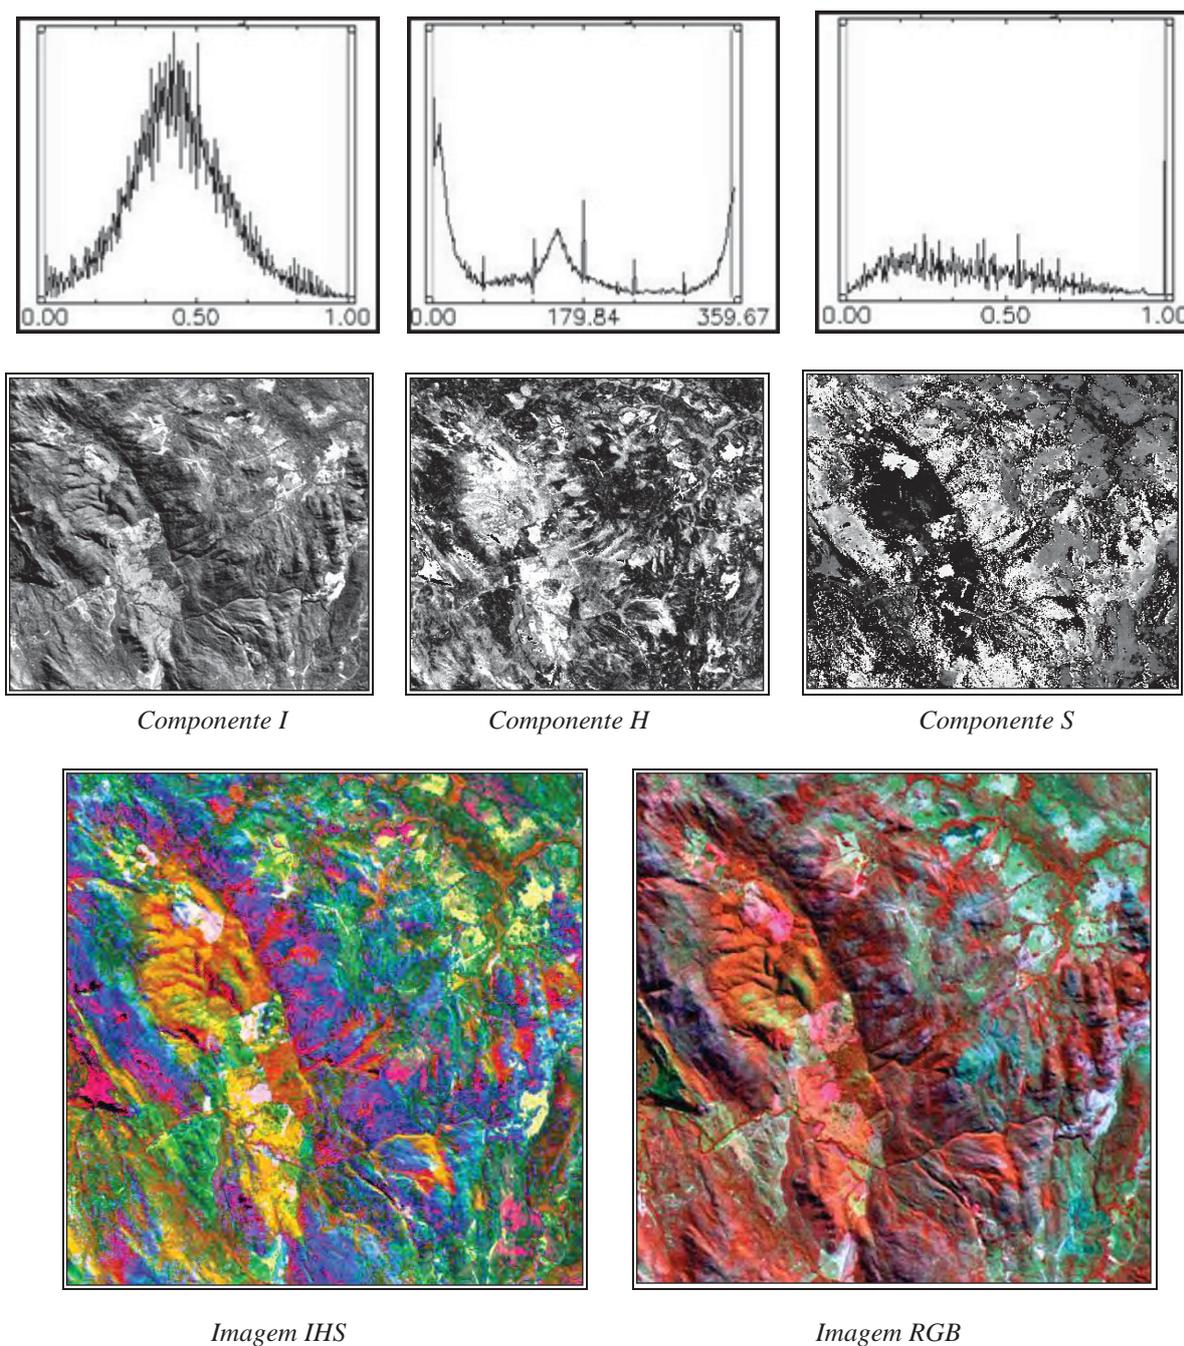


Fig. 8.10 Histogramas e as correspondentes imagens componentes IHS das bandas ETM 3,4,5 e abaixo a imagem colorida IHS ao lado da imagem colorida RGB.

Schowengert (2007), utilizando a geometria de um hexacone, descreve como se chega às medidas das coordenadas dos atributos IHS. Como IHS é uma transformação do sistema RGB, a concepção da geometria do hexacone deve ser subtraída da geometria do cubo de cor. Imagine a projeção de cada subhexágono de cor, em um plano perpendicular à linha do vetor preto ao branco, como visto na Figura 8.11. Movendo-se o vértice do vetor preto ao branco, a projeção do plano resulta em uma série de hexágonos de diferentes dimensões. Essa série de hexágonos define o hexacone. No hexacone, a linha de cinza do preto ao branco define a intensidade de cada hexágono, enquanto os componentes H e S se localizam, propriamente, no hexágono. O local onde o hexacone se reduz ao valor mínimo, a

intensidade I é zero, isso é, o hexacone é um ponto preto. À medida que aumenta a intensidade os tamanhos dos hexágonos vão aumentando, e o ponto preto caminha do cinza até atingir o seu máximo, o branco. A dimensão de cada seção transversal do hexacone determina a quantidade de matizes presentes (Hue). Para um ponto interno à projeção de um hexágono, com uma dada intensidade, os outros dois componentes da cor, Hue e Saturação, são definidos, geometricamente, na superfície do hexágono. O Hue é determinado pela posição do matiz em torno do hexágono, e que é calculado pela rotação do ângulo azimutal de 0° a 360° . O vermelho está em 0° graus, o amarelo em 60° graus, o verde 120° graus, o ciano em 180° , o azul em 240° graus e o magenta em 300° . A Saturação é determinada pela distância do ponto ao centro do hexágono, e por isso, define a quantidade de branco que está associada à cor. Pontos mais distantes do centro representam matizes mais puros do que aqueles mais próximos ao centro. Saturação e Intensidade têm valores no intervalo de 0 a 1. Para se efetuar o realce dos atributos IHS de uma forma independente, antes de voltar ao espaço RGB (transformação inversa), a componente I pode ser linearmente ampliada para realçar as áreas de baixo albedo, H é rotacionado pela escolha de um ângulo apropriado para destacar uma cor, e os valores de S podem ser linearmente reescalados, a fim de aumentar a saturação e tornar as cores mais vivas.

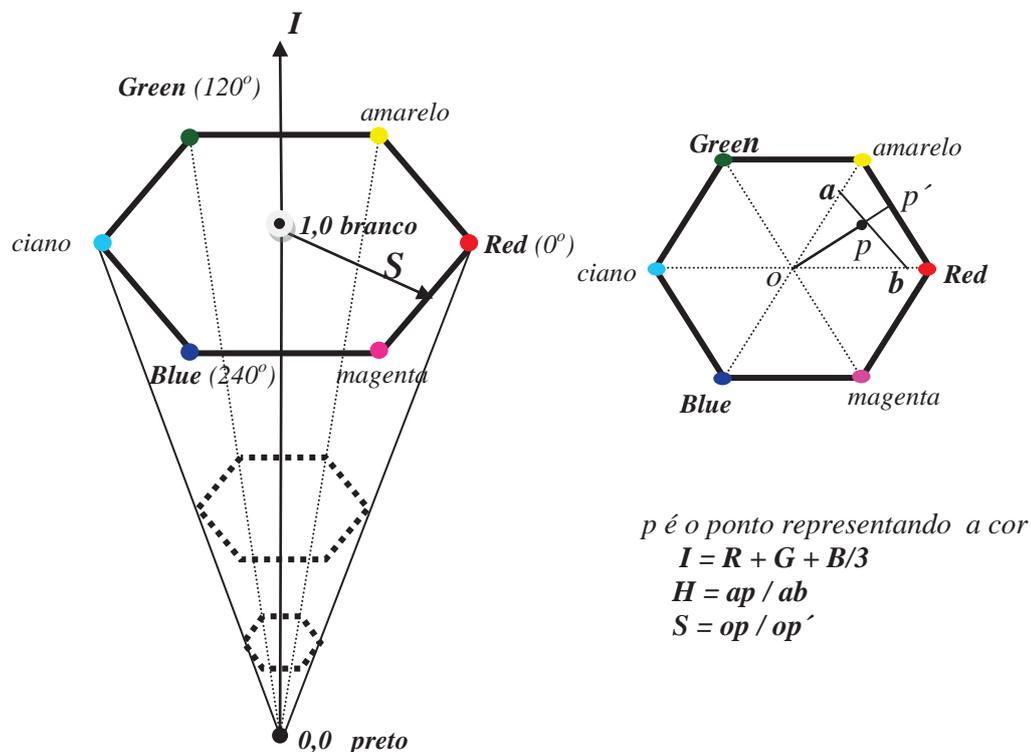


Fig. 8.11 Modelo de representação dos atributos IHS da cor por meio da geometria do hexacone. (Adaptado de Schowengert, 2007).

Como as imagens são armazenadas utilizando o espaço de cores RGB, torna-se necessário a utilização de equações para a transformação IHS. Transformações lineares podem ser usadas para definir os componentes, o que tornam os algoritmos de transformação de intensidade, matiz e saturação bastante simples e eficientes. Uma transformação bastante conhecida é a que foi proposta por Pratt (1991), que tem a seguinte formulação, também baseada na geometria do hexacone:

$$\begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/\sqrt{6} & 1/\sqrt{6} & 2/\sqrt{6} \\ 1/\sqrt{6} & 2/\sqrt{6} & 0 \end{bmatrix} = \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

Após essa primeira transformação, os valores de matiz (H), saturação (S) e intensidade (I = V) são obtidos por:

$$H = \tan^{-1} \frac{V_1}{V_2} \quad \text{eq. 8.2}$$

$$S = \sqrt{(V_1)^2 + (V_2)^2} \quad \text{eq. 8.3}$$

$$V = I \quad \text{eq. 8.4}$$

onde, $0 \leq S, V \leq 1$ e $0 \leq H \leq 2\pi$

A transformação inversa para o espaço RGB, para que a imagem possa ser visualizada nos monitores coloridos que são de padrão RGB, é dada por:

$$V_1 = S \cos(H) \quad \text{eq. 8.5}$$

$$V_2 = S \sin(H) \quad \text{eq. 8.6}$$

$$I = V \quad \text{eq. 8.7}$$

Outras variações de transformações existem, tais como, HLS (hue, lightness, saturação) ou HSV (hue, saturação, value). No modelo HLS o espaço de cor é definido por um hexacone duplo (Figura 8.12). Nesse modelo, diferentemente do que ocorre no HSV, os valores de L e S nos quais se obtém o mais forte nível de luminosidade e saturação são em $L=0,5$ e $S=1$, enquanto que no HSV, para se ter o mesmo efeito, teríamos $V=1$ e $S=1$ (Foley *et al.*, 1990).

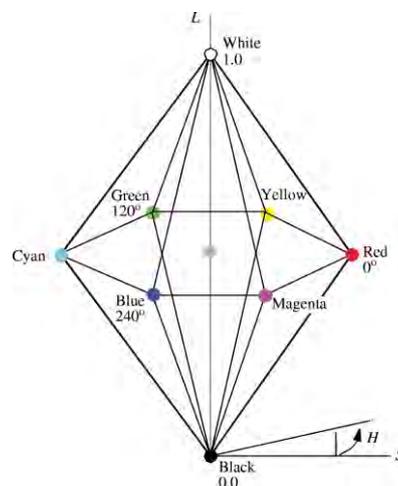


Fig. 8.12 Modelo de cor HSL por meio da geometria do hexacone duplo. (Adaptado de Foley *et al.*, 1991).

Independente de quais sejam as equações de transformação, Souto (2000) observou que um problema inerente aos componentes da cor é a instabilidade de hue sob condições variadas de saturação e/ou intensidade. O autor comprovou que é percebida uma acentuada instabilidade de matiz quando a cena exibe baixos valores de saturação. Na medida em que o valor de saturação aumenta, a instabilidade de matiz diminui, até chegar a uma situação de estabilidade. Para valores baixos de intensidade, o componente matiz é mais sensível (ou instável) às variações de valores dos componentes no espaço RGB.

8.5 Fusão de Imagens

A alternativa para descrever as cores de uma imagem decompondo-as nos componentes de Intensidade (I), Hue (matiz) e Saturação (S), estende-se além do seu uso para a obtenção de composições coloridas. Na realidade, a transformação IHS foi concebida como uma poderosa técnica para ser usada como um meio de combinar imagens de diferentes sensores, com diferentes resoluções espaciais. Essa técnica ficou conhecida como fusão de imagens e seu principal objetivo é aumentar a resolução espacial das imagens multiespectrais de baixa resolução espacial, utilizando-se de uma imagem de alta resolução espacial, tal como a banda pancromática que atualmente diversos sensores possuem, ou então usando uma imagem de radar.

A representação no espaço de cores IHS apresenta algumas propriedades, entre as quais se destaca o ordenamento das resoluções espaciais dos componentes I, H e S, na forma como o olho humano é capaz de percebê-las. A componente I é percebida por máxima resolução, seguida de H e S, devido ao fato de que a retina do olho humano compõe-se de maior número de bastonetes (responsáveis pela percepção de luminosidade ou brilho I) do que de cones (responsáveis pela percepção do matiz H). Para exemplificar isso imagine uma foto aérea tomada com um filme preto e branco do visível de uma área do terreno, portanto, colorida. As cores mais vivas da paisagem corresponderiam na foto preto e branco aos tons de cinza claros e as cores escuras corresponderiam aos tons de cinza escuros. A foto aérea em preto e branco seria, portanto, uma representação da intensidade I. Para compensar a falta dos outros dois atributos da cor, elas têm com principal característica a alta resolução espacial, de 1 m ou mais, que possibilita a identificação dos objetos pela análise de suas formas e não pelas propriedades de matiz e saturação. Elas possuem assim, uma baixa resolução espectral, mas uma alta resolução espacial. Então, o ideal seria ter um sensor que pudesse registrar com a máxima eficiência os três componentes das cores com alta resolução espacial. Mas o que vemos é uma maioria de sistemas sensores orbitais com um módulo multiespectral com baixa resolução espacial, adicionado com uma banda de ampla largura espectral, tal como das fotos aéreas e com uma alta resolução espacial. Essa banda tem sido denominada de banda pancromática. Utilizando a técnica IHS podemos processar conjuntamente as imagens multiespectrais e a banda pancromática, combinando as suas resoluções e obtendo como resultado uma imagem com alta resolução espectral e espacial.

O processo de fusão de imagens é feito em dois passos. O primeiro passo segue o mesmo processo para a construção de uma composição colorida no espaço IHS. O analista deve selecionar três bandas do módulo multiespectral que contenham as melhores informações espectrais de seu interesse, e realizar a transformação para o espaço IHS. Os componentes H e S que guardam a informação espectral das cores são preservados e o componente I é descartado e substituído pela imagem pancromática de alta resolução espacial. O segundo passo consiste em reamostrar os componentes H e S para a resolução espacial da banda pancromática, sintetizando uma imagem colorida com resolução espacial

da banda pancromática e com as cores do módulo multiespectral. Opera-se então a transformação inversa para o espaço de cor RGB. Apesar de ser uma técnica bastante utilizada, a fusão pelo método IHS possui a limitação de permitir apenas a fusão de três bandas com a imagem de alta resolução espacial.

Outras propostas de técnicas de fusão surgiram baseadas em três opções de modelos: modelo no domínio espacial, no domínio espectral e por operações algébricas. Os modelos no domínio espacial utilizam as transformadas de Wavelets e a técnica HPF (*High-Pass Filter*) para retirar a informação espacial de alta frequência da imagem de alta resolução espacial e combiná-la com imagem multiespectral. O modelo no domínio espectral é o da técnica IHS, e inclui outras duas novas técnicas: Principais Componentes e Gram-Schmidt. E o modelo algébrico das técnicas Brovey e Multiplicativa usam operações aritméticas pixel a pixel. Uma breve descrição dessas técnicas é apresentada (Welch & Ahlers, 1987; Vrabel, 1996).

Brovey (cor normalizada)

Utiliza uma combinação matemática de soma e multiplicação entre as imagens de diferentes resoluções espaciais. Cada banda da imagem multiespectral (MS_i) é multiplicada pela imagem de alta resolução (PAN) e dividida pelo somatório das bandas multiespectrais (equação 8.8). Isso normaliza a cor da imagem fusionada, contribuindo para diminuir a instabilidade de H sob condições de baixa saturação e/ou intensidade. Somente três bandas multiespectrais são usadas. A fusão *Brovey* possui as mesmas limitações da IHS, pois trabalha com o sistema de cores RGB (Pinto *et al.*, 2005). Mas mostra-se superior ao IHS quando as bandas multiespectrais são da região do infravermelho.

$$CN = \frac{(MS_i + 1) \times (PAN + 1) \times 3}{\sum_i MS_i \times 3} - 1$$

eq. 8.8

Principais Componentes (PC)

A fusão por Principais Componentes é a forma de não limitar o número de bandas que podem ser fusionadas, como ocorre com as técnicas Brovey e IHS. Inicia-se com a transformação das bandas multiespectrais em um mesmo número de componentes não-correlacionados. O primeiro principal componente (PC_1) é substituído pela banda pancromática, que antes passa por um processo de equalização de média e variância para que fique mais parecida possível com a PC_1 .

Gram-Schmidt (GS)

Este procedimento, assim como o de Principais Componentes, é uma operação sobre vetores, com o objetivo de torná-los ortogonais. A fusão inicia-se simulando a existência de uma banda pancromática a partir das bandas multiespectrais de baixa resolução espacial. A banda pancromática simulada deve estar dentro do intervalo espectral das bandas de baixa resolução. Na sequência, uma transformação de *Gram-Schmidt* é aplicada à banda pancromática simulada e às bandas multiespectrais, e a pancromática simulada é considerada como a primeira banda. Então, a primeira banda *Gram-Schmidt* é trocada pela banda pancromática de alta resolução e uma transformação inversa é aplicada para formar a imagem sintética de saída. O método *Gram-Schmidt* é mais preciso do que o método Principais

Componentes porque ele usa a função de resposta do sensor para estimar como a banda pancromática deve aparecer.

CN Spectral (normalização espectral de cores)

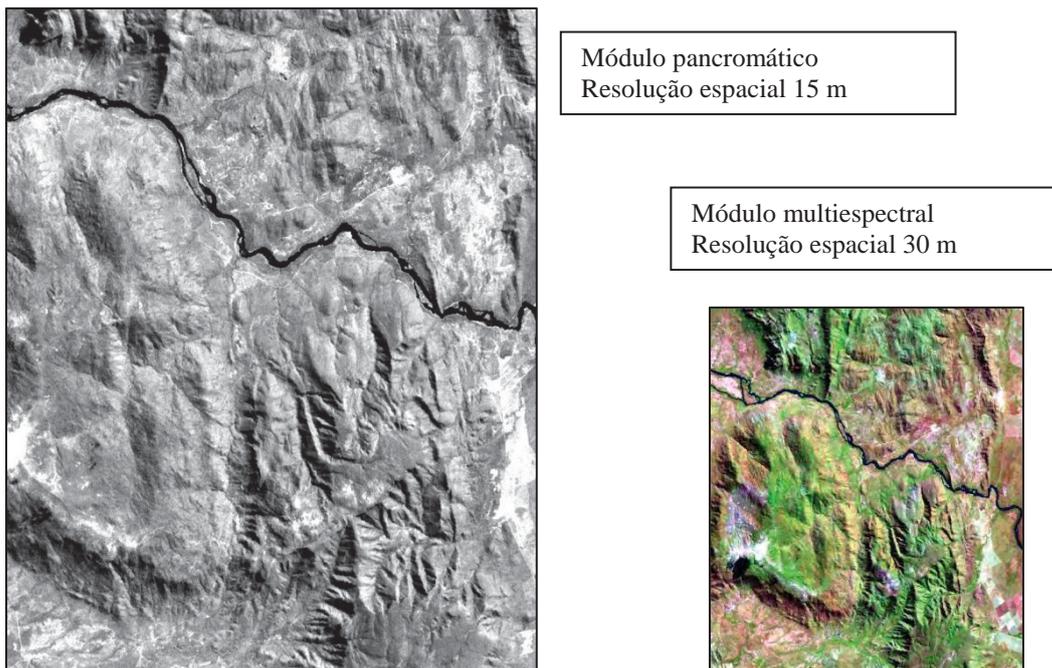
A técnica de fusão *CN Spectral (color normalization)* é uma extensão do algoritmo *Brovey*, mas sem restrição ao número de bandas e à resolução radiométrica da imagem sintética de saída. Entretanto, há uma única restrição para a execução dessa fusão: o intervalo espectral das bandas de entrada deve ser o mesmo da banda de alta resolução espacial. O processo de fusão começa com o agrupamento das bandas de entrada em segmentos espectrais cujos intervalos espectrais são definidos pelo valor central do comprimento de onda de cada banda, o que é obtido do arquivo cabeçalho (txt.) da imagem. Em seguida é realizada uma operação aritmética semelhante à da fusão *Brovey*. Cada banda de entrada é multiplicada pela banda de alta resolução espacial e normalizada pela divisão da soma de bandas multiespectrais, na forma da equação 8.9.

$$CN = \frac{MSi \times PAN \text{ (número banda segmento)}}{(\sum \text{bandas entrada segmento} + \text{número banda segmento})}$$

eq. 8.9

Podemos considerar que o método de fusão mais eficiente é aquele que preserva as cores da imagem original e que consegue transferir a informação espacial de alta frequência da imagem de alta resolução espacial.

Exemplos desses métodos são apresentados na Figura 8.13. As imagens são do sensor ETM do Landsat 7, com seis bandas no módulo multiespectral (0,45 μm – 2,35 μm) de resolução espacial de 30 metros e uma banda pancromática (0,55 μm - 0,95 μm) com resolução espacial de 15 metros.



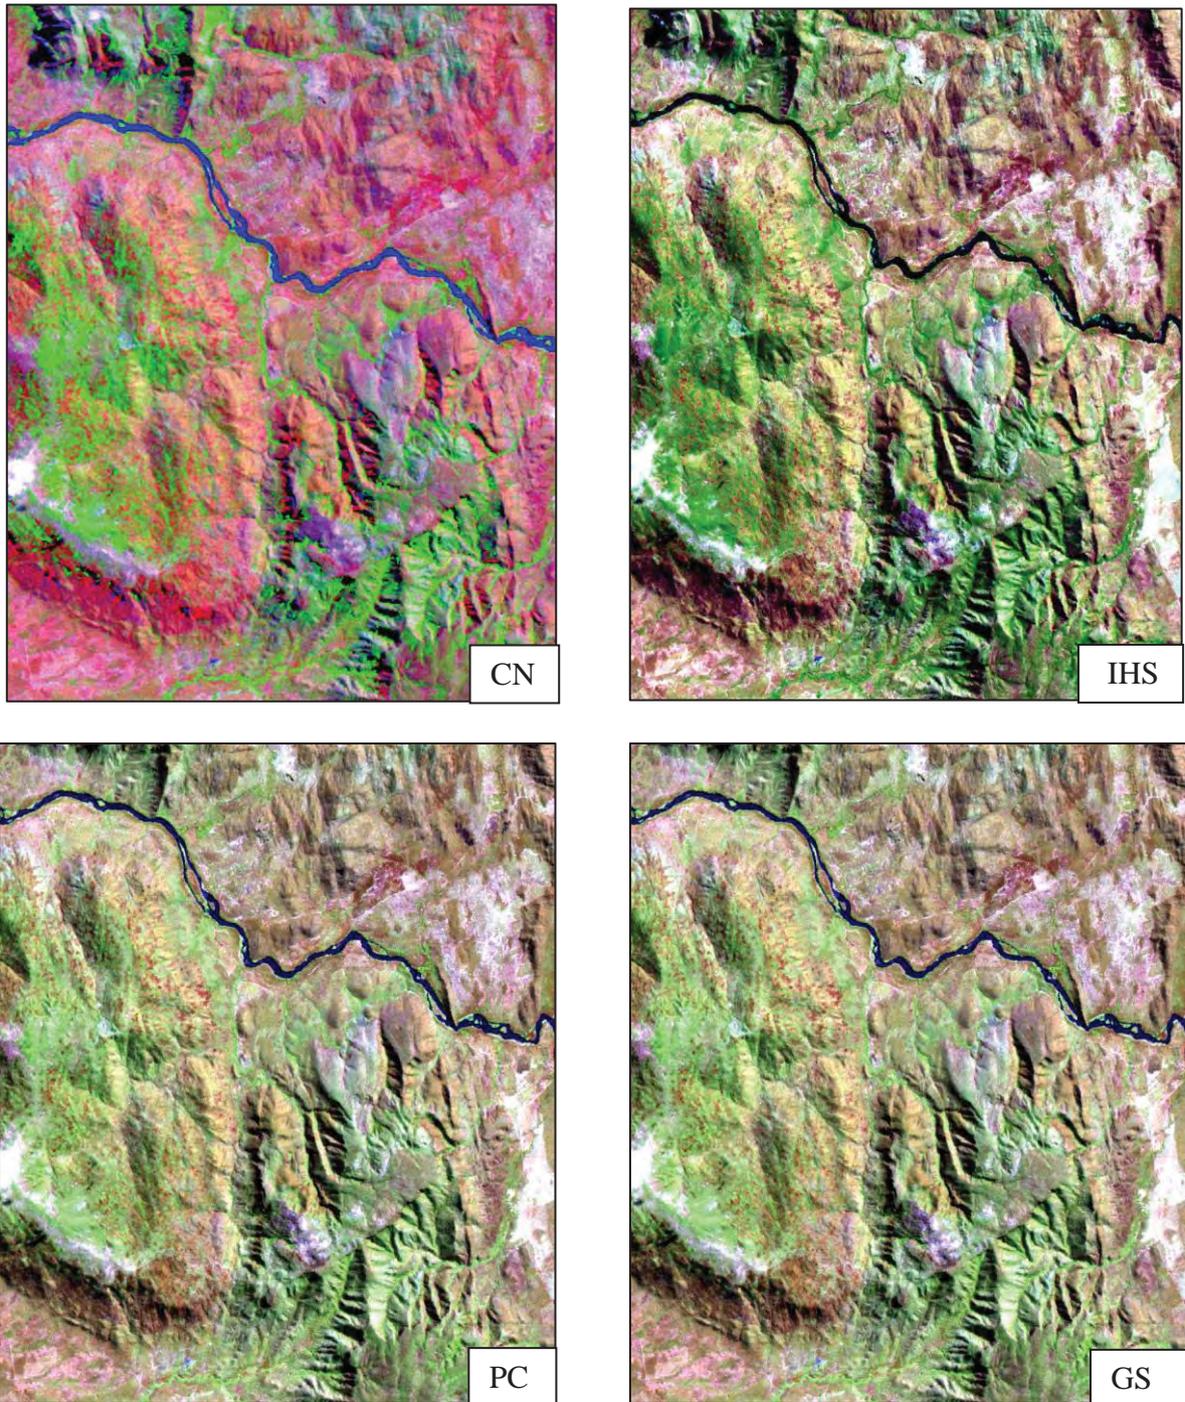


Fig. 8.13 Resultados da fusão da imagem multiespectral ETM de resolução de 30m com a imagem pancromática de resolução de 15m, pelos métodos no modelo algébrico (CN) e no domínio espectral (IHS), Principal Componente (PC) e Gram-Schmidt (GS).

ARITMÉTICA DE BANDAS

Paulo Roberto Meneses
Tati de Almeida

9

9.1 As operações aritméticas

Aritmética de bandas é uma das mais simples formulações algorítmicas de processamento de imagens e que pode ter resultados expressivos. A facilidade para executar as operações aritméticas de soma, subtração, multiplicação e divisão é uma notável demonstração das vantagens do uso de processamento de imagens multiespectrais. É um processo bastante rápido para ajustar e suavizar imagens muito ruidosas ou para se obter realces de toda a área de uma imagem ou de alvos específicos de interesse do analista. As operações aritméticas realizam um processamento de transformação dos dados a partir da combinação de imagens, gerando como resultado uma nova imagem completamente distinta das imagens de entrada. Uma nova matriz de dados é gerada. O processo de transformação é executado pixel a pixel por meio de uma regra matemática pré-definida envolvendo, normalmente, no mínimo duas bandas do mesmo sensor ou bandas de datas de aquisição diferentes (Figura 9.1). Nesse último caso, as imagens devem ser co-registradas.

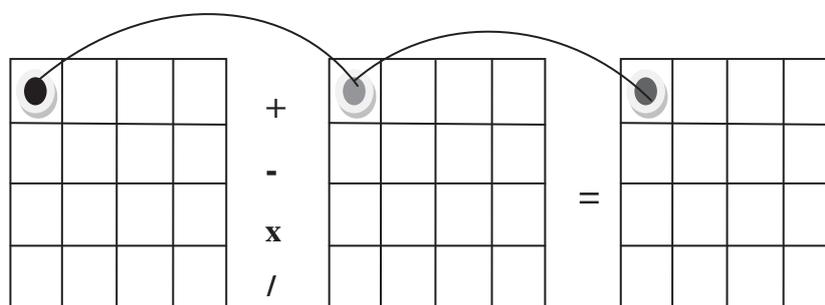


Fig. 9.1 Operações aritméticas são executadas pixel a pixel entre duas bandas.

As operações de uso mais comuns são a divisão e a subtração, com reduzida aplicação para as operações de soma e multiplicação. Como o resultado é uma única imagem, as operações aritméticas são uma forma de recurso para reduzir o número de imagens, o que é uma vantagem em termos de armazenamento em disco. Conforme seja a operação pode ocorrer perda de informação quando os novos valores ultrapassarem o intervalo de números digitais ou resultar em números fracionários. Por exemplo, para uma imagem de 8 bits os valores que ficarem abaixo de 0 serão saturados em 0 e os valores acima de 255 serão saturados em 255, para manter a imagem em 8 bits. E nos casos de os novos valores digitais ficarem reduzidos a valores muito pequenos, como numa divisão de uma banda por outra, é requerido um fator de ganho (multiplicativo) e um *off-set* (aditivo), para que seja ampliado o contraste visual da imagem transformada.

Em termos gerais, a soma e a multiplicação servem para realçar similaridades espectrais entre imagens de diferentes bandas ou datas, enquanto a subtração e a divisão são utilizadas para realçar diferenças espectrais dos alvos.

9.2 Soma

Com um par de imagens ou n imagens, a operação soma é definida como uma soma normalizada de diferentes bandas espectrais ou de várias imagens semelhantes tiradas em datas distintas. Pode também ser aplicada para somar uma banda de um sensor com imagens processadas de outro sensor. A expressão genérica para a soma é:

$$g_{soma}(l, p) = int \frac{(g_1(l, p) \dots + \dots g_n(l, p))}{n} \quad eq. 9.1$$

sendo, $n = \text{número de bandas}$

De onde se pode perceber que a nova imagem (g_{soma}) é uma média aritmética dos pixels de todas as bandas somadas (g_i). Como são somados pixels bons com pixels ruidosos, a soma tende a minimizar os ruídos que podem estar presentes nas imagens originais. Deve-se dividir a soma pelo número de bandas somadas, porque sempre o resultado ultrapassa a faixa de valores digitais da imagem. Por exemplo, a soma entre os pixels de duas imagens de 8 bits (faixa 0 a 255) poderá ficar entre 0 a 510, o que obviamente excede a capacidade de memória da imagem. Se simplesmente dividir o resultado por dois, a nova imagem é reescalada para o intervalo 0 – 255.

A soma é utilizada para realçar similaridades entre imagens de diferentes bandas ou datas, resultando no realce de alvos com respostas espectrais diferentes daquelas presentes nas imagens originais. Segundo Florenzano *et al.* (2002) a adição de imagens pode também ser aplicada para a obtenção de uma banda pancromática a partir, por exemplo, da adição das imagens de bandas da região do visível (ex. bandas 1+2+3 ETM). Outra aplicação sugerida por Crósta (1993) é somar uma imagem original à sua versão submetida a um filtro de convolução de realce direcional, o que permite combinar a informação tonal da imagem original com a informação textural da imagem filtrada, obtendo-se um resultado de melhor qualidade visual para fins de interpretação. Um exemplo numérico da soma é mostrado na Figura 9.2.

O exemplo mostrado na Figura 9.3 é a soma das três bandas do visível do sensor ETM, simulando o exemplo proposto por Florenzano *et al.* (2002) para se criar uma imagem pancromática. Nos *software* que permitem este processamento, a expressão computacional é do tipo:

$$\frac{(float(b1) + float(b2) + float(b3))}{3} \quad eq. 9.2$$

onde, *float* é usado para evitar erros de *byte overflow* durante os cálculos.

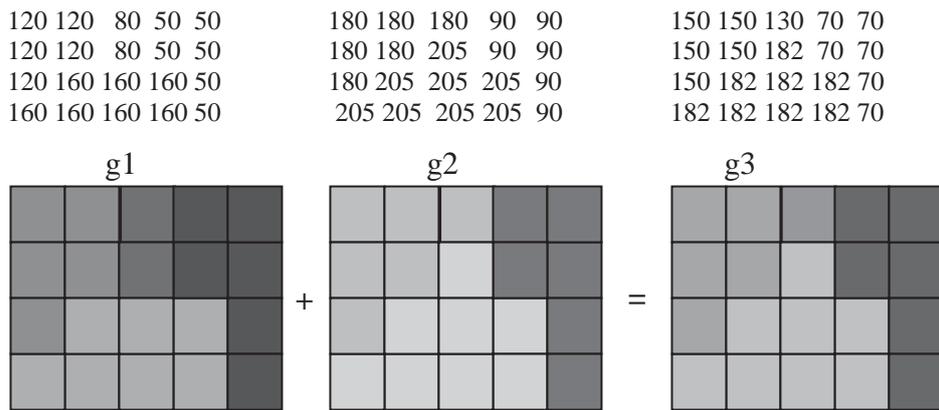


Fig. 9.2 Soma de duas bandas com similaridades, resultando numa imagem realçada que é a média aritmética.

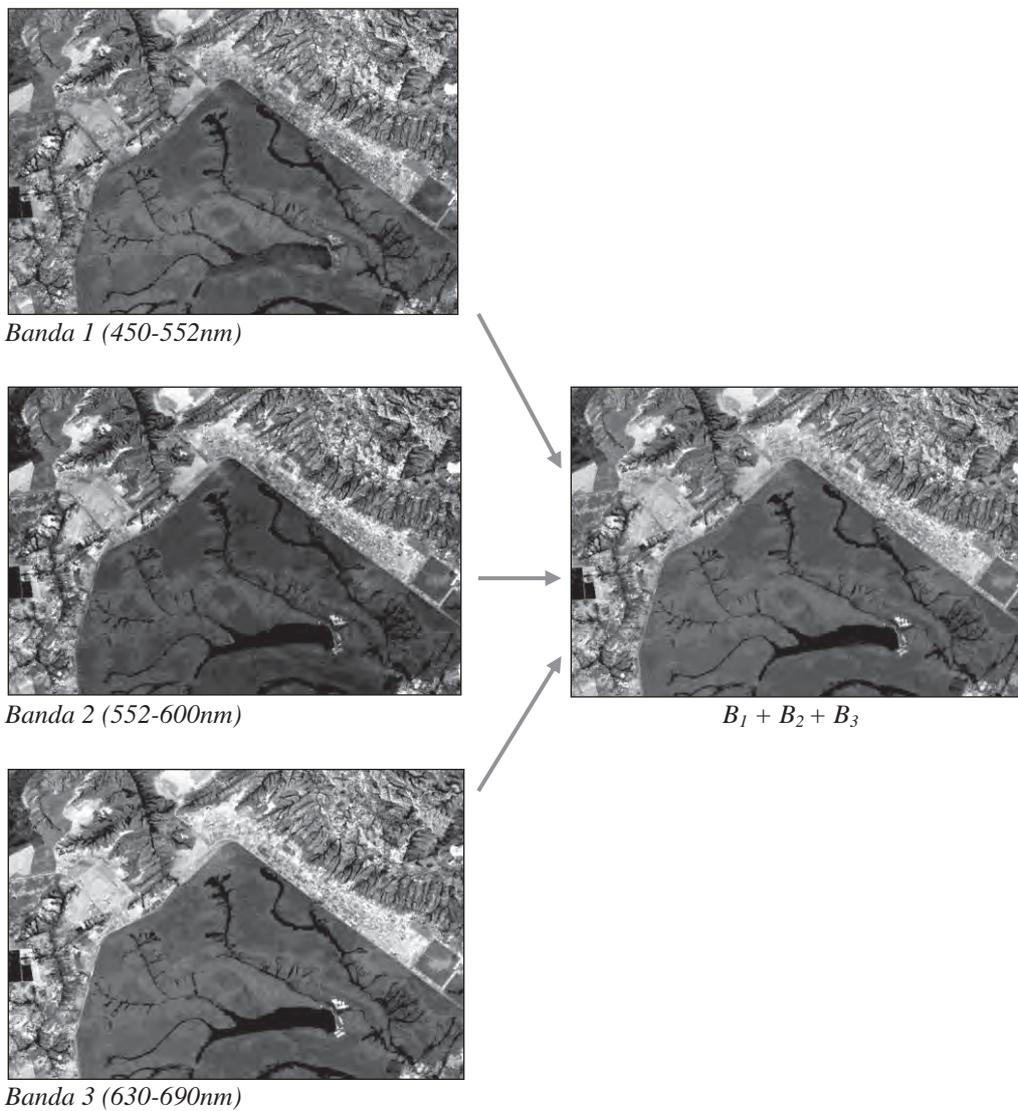


Fig. 9.3 Operação aritmética de soma de três bandas do visível para simular a criação de uma imagem pancromática.

9.3 Multiplicação

A multiplicação é talvez a menos usada das operações. Em sensoriamento remoto pode-se ver alguma utilidade prática da multiplicação, quando se multiplica uma banda por outra. Uma das principais dificuldades com a multiplicação é a faixa extrema de valores que pode ser gerada. Uma imagem com 8 bits produzirá valores de 0 a mais de 65000. Isso é um produto de 16 bits, condizentes com imagens de altíssima resolução, muito usadas na área industrial para controle de qualidade de produtos. Para as imagens de sensoriamento remoto, o produto da multiplicação é automaticamente reescalado para o intervalo 0 a 255, o que acarreta uma perda significativa de dados. A expressão abaixo é normalmente usada na multiplicação de duas bandas, e tem a finalidade de realçar os dados que são semelhantes em ambas.

$$g_{prod}(l, p) = int \frac{(g_1(l, p) \times g_n(l, p))}{k - l} \quad eq. 9.3$$

onde, $k - 1$ representa o valor máximo de quantização. Numa imagem de 8 bits, $k - 1 = 255$.

Florenzano *et al.* (2002) encontrou uma forma de usar a multiplicação de imagens como recurso para obter uma imagem que agrega o realce da informação textural do relevo com a informação espectral. Para isso, multiplicaram a banda 4 ETM do infravermelho próximo, que em áreas com cobertura vegetal consegue ter uma boa informação de relevo, pelas bandas 2, 5 e 7, combinando os resultados dessa multiplicação em uma composição colorida. Comparada com uma composição colorida simples RGB das bandas 2, 5 e 7, dá para perceber que é uma imagem com maior valor para interpretação visual das formas de relevo, enquanto se vê uma leve suavização das cores que ajuda a retirar, em benefício do intérprete, o efeito distrativo de cores saturadas de outros alvos (Figura 9.4).

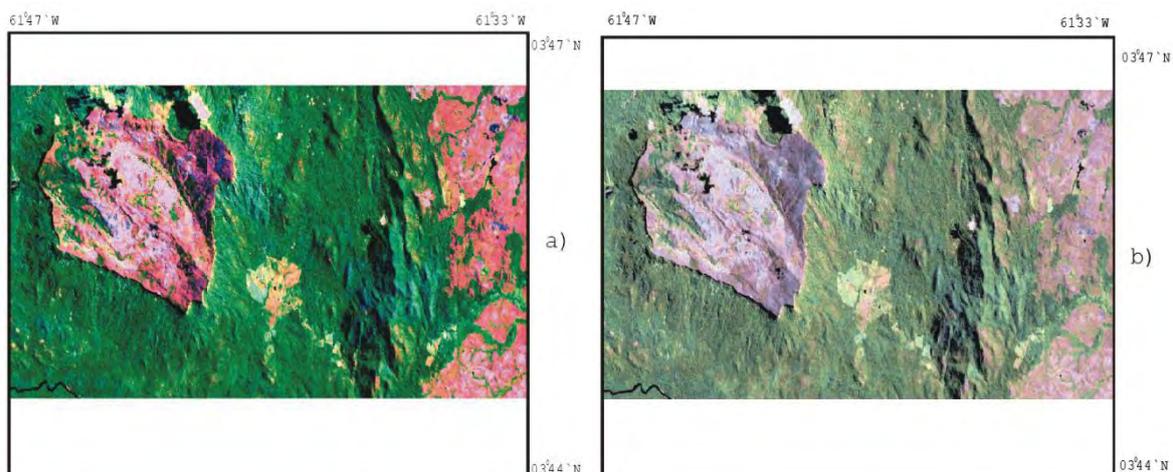


Fig. 9.4 Imagens Landsat 5 – TM da região da serra do Tepequém (Roraima). Em a) composição 542/RGB e em b) composição da multiplicação 4x5(R) 4x2(G) 4x7(B). (Copiado de Florenzano *et al.* 2002).

9.4 Subtração

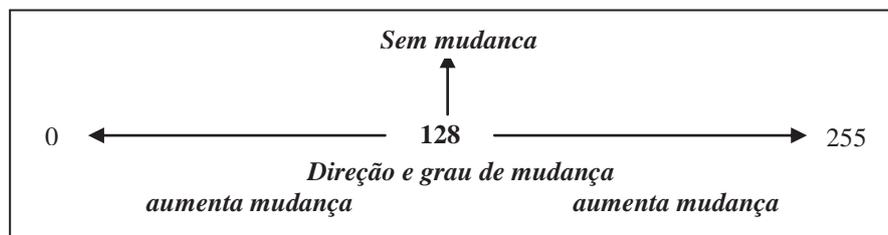
A subtração de bandas é uma operação de grande recurso prático para detectar mudanças temporais dos alvos presentes em uma área, aplicação conhecida como *change detection*. Tem amplo uso na detecção de impactos ambientais e na avaliação de desmatamentos florestais. São necessárias duas imagens de datas diferentes da mesma banda, o que é mais fácil de realizar com imagens do mesmo sensor, do que com sensores diferentes. Deve-se também dar preferência para imagens tomadas com iguais ângulos de iluminação (inclinação e azimutal solar), pois se sabe que as áreas contendo alvos com forte controle de organização estrutural mostram reflectância dependente da geometria de iluminação.

Nesse tipo de aplicação com frequência ocorre das imagens tomadas em datas diferentes apresentarem histogramas com médias e desvio padrão não coincidentes, caracterizando uma mudança de radiância global da cena. É então preciso, antes de efetuar a subtração, equalizar a radiância das duas imagens para evitar a detecção de mudanças não reais.

A subtração entre os pixels das imagens pode resultar numa diferença máxima negativa de -255 e numa diferença máxima positiva de $+255$, contando que sempre haverá nas imagens alguns pixels com valores digitais mínimos zero e máximos 255. Para compensar os valores negativos de pixels, porque não existe radiância de energia negativa, ao resultado da subtração são adicionados 255 e assim o intervalo digital é deslocado para 0 a 511. A seguir divide-se este intervalo por dois para ter a imagem reescalada entre 0 – 255. O esquema abaixo exemplifica a operação de subtração de imagens.

$$g_{dif} = \frac{(g_1 - g_2) + 255}{2}$$

eq. 9.4



De acordo com essa formulação matemática de detecção de mudanças, os pixels com valores de 128 são de áreas sem mudanças, enquanto as áreas que sofreram mudanças ao longo das duas datas terão pixels com valores na direção de 0 ou de 255. Portanto, pode-se dizer que é diagnosticado uma direção de mudança. Vemos isso no exemplo da Figura 9.5 de duas imagens tomadas em 2001 e 2006. Subtraindo a banda 3 ETM da imagem de 2006 da imagem de 2001, os pixels na direção ao zero representam mudanças das classes de alvos que eram mais claras (maior reflectância) em 2001 do que eram em 2006, e os pixels na direção a 255 são das classes de alvos que eram mais escuros em 2001 do que eram em 2006. Os valores extremos 0 e 255 indicam mudanças extremas, e os valores de cinza intermediários indicam mudanças graduais. O histograma da imagem subtração tem um pico centrado em 128, e rapidamente caindo para ambos os lados.

Caso o objetivo seja fixar uma magnitude de mudança, o algoritmo de subtração torna-se, simplesmente, em uma subtração de valores absolutos dos pixels das duas imagens, independente do sinal da subtração ser negativo ou positivo.

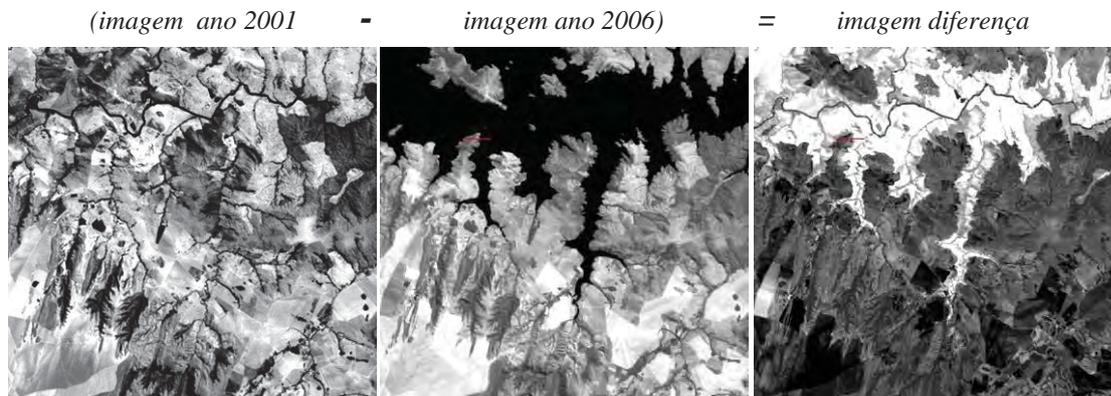


Fig. 9.5 Detecção de mudanças por meio de subtração de imagens tomadas em diferentes datas. Na imagem diferença os tons de cinza mais escuros indicam as áreas que sofreram maiores mudanças.

9.5 Divisão de Bandas

No processo de extração de informações de imagens de sensores multiespectrais, em muitas situações há o interesse específico de se discriminar na cena sutis variações de reflectância de alvos específicos, como um tipo de litologia, solo, ou tipos de vegetação. Nesse caso, deve-se buscar por meios que possam destacar exclusivamente as propriedades daquele tipo de alvo, em detrimento a todos os outros presentes na cena, sem interesse. A divisão ou razão de bandas é a operação aritmética usada para esse fim e, por isso, se tornou em uma das mais úteis e abrangentes técnicas de transformação de imagem. Ela se baseia em parâmetros dos aspectos físicos do sensor e no comportamento da reflectância dos alvos, como veremos logo adiante. Matematicamente, a divisão de bandas é na sua forma mais simples do tipo,

$$g_{div}(l, p) = a \frac{g_1(l, p)}{g_2(l, p)} + b$$

eq. 9.5

onde, a = ganho; b = offset

Como mostra a equação 9.5, a divisão de imagens consiste na divisão do pixel de uma banda pelo pixel de posição correspondente de outra banda, tal como representado na Figura 9.6. Como os valores da divisão resultam em números pequenos e fracionários, para fins de exposição da imagem no monitor de vídeo eles devem ser multiplicados por um valor escalar (*a*) para recolocá-los ou expandi-los para o intervalo 0 a 255 de uma imagem de 8 bits. Uma constante (*b*) é somada aos valores reescalados para apenas obter um deslocamento (*offset*) do histograma para uma posição mais central entre 0 a 255, a fim de possibilitar um equilíbrio no realce da imagem. Nesse tipo de algoritmo os valores de *a* e *b* são auto calculados.

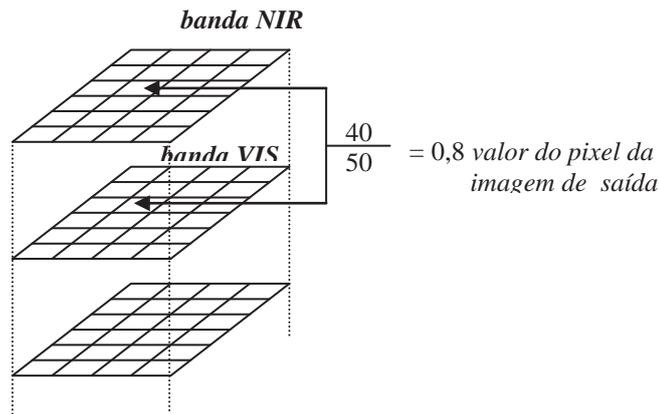


Fig. 9.6 Processo de divisão de duas bandas.

A divisão trabalha no realce das assinaturas espectrais dos alvos e, para isso, é necessário que o intérprete selecione corretamente as bandas do sensor. A seleção das bandas é decidida com base no conhecimento que o intérprete tem acerca do padrão de reflectância do alvo de interesse. Daí decorre ser uma técnica controlada pelo intérprete, com resultados que se têm mostrado importantes para o mapeamento litológico, de solos ou de vegetação.

Por princípio, para se realçar uma determinada litologia ou um tipo de solo específico por divisão de bandas, as áreas destes alvos precisam expor na imagem padrões homogêneos e bem definidos de reflectância. Porém, em áreas de relevos não planos, os sombreamentos alteram os valores de reflectância dos alvos, e o pressuposto de um padrão de reflectância diagnóstico daquele alvo é perdido. Nesse caso, a recuperação da reflectância do alvo sombreado, implica na supressão da sombra. Há dessa forma, um compromisso mútuo entre a possibilidade de se realçar alvos específicos e a supressão de sombras em imagens multiespectrais. A situação é demonstrada na Figura 9.7, para uma hipotética forma de relevo. Nesta figura vemos pela geometria de iluminação do relevo, que o ângulo θ formado pela direção do raio solar incidente com a normal à superfície, é diferente entre a face frontal da encosta que é fortemente iluminada, e a face oposta da encosta que é sombreada. Isto tem uma implicação matemática. Como o valor do coseno do ângulo θ é parte da equação que mede os valores quantitativos da reflectância de uma superfície (eq. 9.6 a 9.8), mesmo que as duas encostas fossem constituídas da mesma litologia, a reflectância da face oposta seria diferente da face frontal devido ao sombreamento, e não poderia ser interpretada como uma variação da reflectância do alvo.

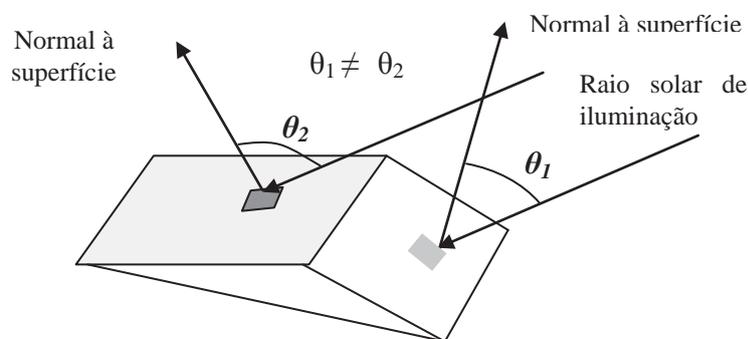


Fig. 9.7 Influência da variação do ângulo solar de iluminação (θ) na reflectância da superfície do terreno em virtude das inclinações das vertentes frontal e oposta.

A demonstração matemática da divisão de bandas para supressão do sombreamento é mostrada a seguir. A equação matemática que descreve a radiância medida pelo sensor para cada banda, integra, além do coseno do ângulo de incidência (θ), as variáveis relacionadas à irradiância da fonte (E), trajetória atmosférica (T), reflectância do alvo (ρ), e parâmetros físicos do sensor (R), que podem ser expressos na forma da eq. 9.6.

$$L_{\lambda} = \frac{1}{\pi} \int E_{\lambda} R_{\lambda} \{T_{\beta(\lambda)} T_{z(\lambda)} \rho(\lambda) \cos \theta + \rho'_{\theta}\}$$

eq. 9.6

onde, E_{λ} = irradiância solar
 R_{λ} = função da resposta espectral do sensor
 $T_{\beta\lambda}$ = transmitância da atmosfera na trajetória descendente
 $T_{z\lambda}$ = transmitância da atmosfera na direção zênite refletida da superfície
 ρ_{λ} = reflectância da superfície
 ρ'_{θ} = reflectância da atmosfera, θ indicando a dependência da elevação solar

Reescrevendo a equação 9.5 de uma forma mais simples, tem-se:

$$L = E_{\lambda} G_{\lambda} T_{\lambda} \rho_{\lambda} \theta + N_{\lambda}$$

Eq. 9.7

onde, E_{λ} = irradiância solar
 G_{λ} = fator instrumental
 T_{λ} = transmitância atmosfera
 ρ_{λ} = reflectância da superfície
 θ = ângulos de iluminação solar do terreno
 N_{λ} = radiância aditiva da atmosfera

Assim, a divisão de bandas equivale à divisão das radiâncias de duas bandas selecionadas.

$$\frac{L_{\lambda 1}}{L_{\lambda 2}} = \frac{E_{\lambda} G_{\lambda 1} T_{\lambda 1} \rho_{\lambda 1} \theta + N_{\lambda 1}}{E_{\lambda} G_{\lambda 2} T_{\lambda 2} \rho_{\lambda 2} \theta + N_{\lambda 2}}$$

eq. 9.8

Dos parâmetros envolvidos na divisão, o único termo que possui o mesmo valor nas duas bandas é o ângulo θ de iluminação solar. A divisão anula o termo θ e desta forma a reflectância das duas faces deixa de ter a influência das variações de iluminações. O efeito na imagem é a eliminação (na realidade uma redução) das variações de relevo, deixando a superfície topográfica plana, sem sombreamento. Sem o efeito de sombreamento a reflectância da superfície do alvo torna-se uniforme e configura representar sua assinatura espectral. Segundo Drury (1987), o efeito do sombreamento não é completamente eliminado por duas razões. Primeiro, os terrenos naturais não são uma superfície Lambertiana, ou seja, as reflectâncias das superfícies variam em função do ângulo entre as superfícies e a iluminação incidente e também em função das formas das estruturas, tal como o dossel de uma vegetação. Segundo, os efeitos atmosféricos modificam os valores de razões de diferentes encostas, de uma maneira imprevisível. Devido a isso, é aconselhável corrigir a atmosfera, transformando a imagem digital para imagem de reflectância antes de se realizar a divisão.

Suprimido o sombreamento quando a divisão de bandas é executada, automaticamente, o realce do alvo desejado se apresenta, razão pela qual a divisão de bandas é uma técnica de realce de imagens de grande poder. Um exemplo prático da aplicação da divisão de bandas para realçar alvos de interesse do interprete é ilustrado pela Figura 9.8.

Imagine quatro diferentes tipos de alvos que tenham padrões de reflectância como no esquema desta figura. Esses alvos, quando vistos na banda 1 ou na banda 2 não mostram diferenças significativas de reflectância entre si, à exceção do alvo D. Sendo assim, os alvos A, B e C dificilmente podem ser discriminados entre si, seja na banda 1 ou na banda 2, como mostram na Tabela 9.1 os valores digitais dos pixels equivalentes aos valores de reflectância dos alvos A, B C e D, valores estes muito próximos entre si. Mas, com base na equação 9.5, quando a banda 2 é dividida pela banda 1, os valores digitais da imagem de saída se transformam numa significativa diferença digital, e os quatro alvos passam a ser facilmente discriminados.

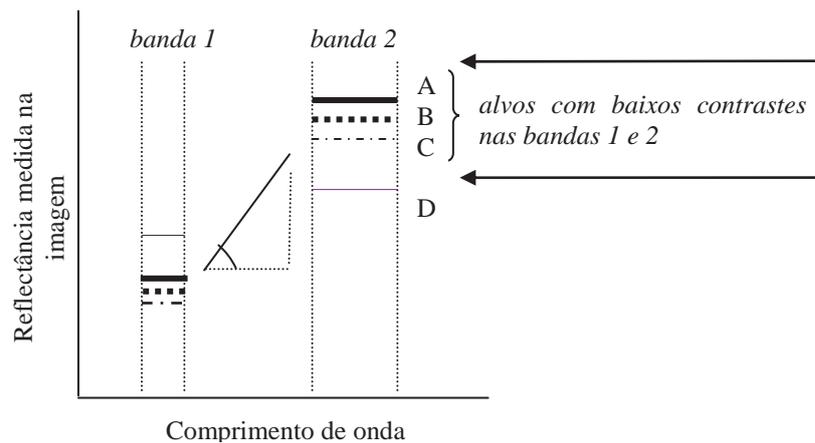


Fig. 9.8 Gradiente de diferença de reflectância dos alvos como condição imposta para a divisão da banda 2 pela banda 1.

Tabela 9.1 Valores digitais dos pixels referentes aos alvos da Figura 9.8

alvos \ bandas	bandas			
	1	2	2/1	$a=15$ $b=7$
A	8	43	5,4	88
B	6	40	6,6	106
C	5	38	7,6	121
D	13	24	1,8	34

Para se chegar aos valores finais da Tabela 9.1 há uma condição estabelecida, e que é a regra básica para se obter o realce de alvos pela operação de divisão de bandas. Essa regra tem como princípio que o alvo deve ter uma boa diferença de reflectância entre as duas bandas, que na Figura 9.8 é avaliada pela reta que mede o declive entre os valores de reflectância da banda 2 com a banda 1. Observe que os quatros alvos obedecem a esta regra. E quanto maior for a diferença, maior é o resultado da razão e maior realce o alvo apresentará na imagem de saída. Ou seja, a razão é diretamente proporcional à razão de reflectâncias das duas bandas. Na prática, para encontrarmos as bandas que satisfaçam essa condição, o intérprete deve primeiro identificar qual banda do sensor situa-se na região da feição espectral de maior absorção, e a seguir a banda situada no comprimento de onda em que o alvo apresente a mais alta reflectância. Assim, encontrará as duas bandas com a maior declividade entre os valores de reflectância. Embora a divisão seja definida em termos de reflectâncias dos alvos, ela é largamente aplicada em imagens com valores de números digitais não calibrados.

É bastante vantajoso o uso das imagens razão, para se obter composições coloridas a partir da combinação de três distintas imagens razão monocromáticas. Essas composições têm a vantagem de combinar informações destacadas de várias bandas, facilitando a interpretação das sutis variações espectrais dos alvos, além de ser uma forma de reduzir a dimensão de dados para análise. Três razões envolvem seis bandas.

9.5.1 Índice de Vegetação

O mais conhecido e didático exemplo que claramente ilustra os princípios da divisão de bandas que foram apresentados, é a criação de índices, sendo o índice mais conhecido a divisão de bandas visando o realce das variações de densidade da cobertura vegetal, ao qual se denomina de índice de vegetação. Na Figura 9.9 está plotada a curva de reflectância da vegetação para demonstrar na prática como um índice deve ser criado. Os dois outros espectros de reflectância são de dois alvos sem cobertura vegetal, água e rocha quartzítica, colocados na figura para demonstrar as diferenças da divisão, comparativamente com a da vegetação. Na vegetação, a principal banda de absorção está centrada em 650 nm, região visível da luz vermelha, e que nas imagens do sensor ETM do Landsat equivale à banda 3, situada em 630 nm a 690 nm. E a região de maior reflectância é no infravermelho próximo, onde se situa a banda 4, nos comprimentos de onda de 760 nm a 900 nm. Fazendo a divisão da banda 4 pela banda 3 os pixels situados nas áreas com vegetação resultarão em valores bem maiores do que 1. Entretanto, os pixels da água e da rocha quartzítica resultarão em valores próximos a 1, porque para ambos não há praticamente nenhuma diferença de declividade de suas reflectâncias entre as duas bandas. Essa é outra regra das imagens razão, que sempre mostra que alvos com diferentes radiâncias absolutas, mas com similares declividades de curvas espectrais de reflectância, aparecerão com valores de pixels aproximadamente iguais e baixos. Aplicando-se o escalonamento, os pixels da vegetação se transformam para altos valores digitais, aparecendo nas imagens em tons muito claros, e os outros dois alvos se transformam em valores digitais comparativamente bem mais baixos do que os da vegetação, e surgem na imagem como alvos escuros, indicando serem áreas sem vegetação. Com isso foi criado um índice para destacar as áreas de vegetação das áreas sem cobertura de vegetação.

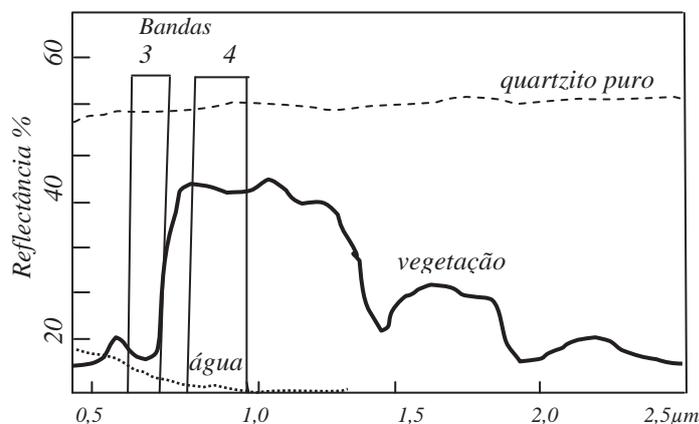


Fig. 9.9 A reflectância dos alvos mostra alto gradiente de reflectância entre as bandas 4 e 3 para a vegetação e gradientes quase nulos para a água e o quartzito puro.

O índice de vegetação "Ratio Vegetation Index – RVI" é universalmente o mais conhecido. Como visto no exemplo anterior da Figura 9.8, esse índice de vegetação consiste na divisão da banda situada no infravermelho próximo (NIR), região que a vegetação mostra a mais intensa reflectância, pela banda situada no vermelho (R), onde a vegetação possui a mais alta absorção da luz solar visível devido à presença em sua constituição do pigmento verde clorofila, indicativo de uma vegetação sadia. É regra dividir a banda de maior reflectância pela banda de menor reflectância. A forma matemática é bem simples, como mostra a equação abaixo.

$$RVI = \frac{NIR}{RED}$$

eq. 9.9

Os valores absolutos de RVI computados são sempre maiores que zero e assumem valores positivos altos em áreas de densa cobertura vegetal. O escalonamento, como se comentou, é necessário para converter os valores da divisão para números inteiros dentro do intervalo numérico da imagem (por ex. 0 – 255), a fim de expor visualmente a imagem ao intérprete. O resultado é uma imagem monocromática, com a gradação de tons de cinza indicando a variação da biomassa ou o índice de área foliar. Quanto mais claro o tom de cinza, maior a densidade de vegetação. Tons de cinzas médios indicam pouca vegetação e tons de cinza totalmente escuros indicam ausência de vegetação, o que só pode ocorrer nas áreas de corpos de água, de solos expostos, áreas cobertas por neve, ou nuvens.

Um índice similar, um pouco mais complexo, *Normalize Difference Vegetation Index – NDVI* envolve a diferença e a soma entre estas duas bandas do infravermelho próximo e do vermelho, segundo a razão:

$$RVI = \frac{NIR - RED}{NIR + RED}$$

eq. 9.10

Os valores de NDVI computados variam de -1 a +1. A vantagem do NDVI sobre o RVI é que ele tende a ser linearmente mais proporcional à biomassa. Também é mais apropriado quando se pretende fazer comparações ao longo do tempo de uma mesma área, pois é esperado de ser menos influenciado pelas variações das condições atmosféricas. É um índice preferido ao RVI, e amplamente utilizado numa escala continental ou global, de forma comercial, com sensores como o SPOT. Inúmeros trabalhos fizeram relação do NDVI com diversos aspectos da vegetação, tais como: medida de índice de área foliar, determinação da porcentagem de cobertura do solo, e estimativas da radiação fotossinteticamente ativa, que foram usados em vários modelos para estudos de fotossíntese e sequestro de carbono.

Um exemplo numérico de valores dos índices RVI e NDVI obtidos com a divisão das bandas 4 e 3 do sensor ETM do Landsat, para dados com correção atmosférica e transformados para reflectância, de uma área agricultada com pivôs de irrigação plantados, solos expostos preparados para cultivos e água represada, é mostrado na Tabela 9.2. A Figura 9.10 mostra os gráficos de reflectância desses alvos, obtidos diretamente da imagem. Na razão simples 4/3, por ser uma razão absoluta, não se pode ter uma previsibilidade de resultado dos valores, e o que se observa é uma significativa diferença de valores de razão. Valores maiores são obtidos para a área de pivô de irrigação com vegetação de cultivo plantado, valores baixos para solos expostos e valores menores que 1 para a água. Os valores obtidos para o NDVI, que se pode dizer que são valores modulados do RVI, são mais indicativos para quantificar o valor numérico de índice para vegetação, que se aproxima de 1 em áreas de densa vegetação, valores negativos para áreas com total ausência de vegetação (água), e solos expostos ficando com valores que se aproximam de zero.

Tabela 9.2 Valores de razão dos índices RVI e NDVI de dados amostrados de uma matriz 3x3 em imagem ETM-Landsat transformada para reflectância.

	<i>Banda 4</i>			<i>Banda 3</i>			<i>4/3</i>			<i>4-3/4+3</i>		
<i>vegetação</i>	95	106	85	8	9	10	11,8	11,7	8,5	0,84	0,84	0,79
	84	76	114	8	8	11	10,5	9,5	10,4	0,78	0,81	0,82
	74	77	80	6	8	11	12,3	7,0	10,0	0,85	0,75	0,82
<i>solo exposto</i>	56	62	58	28	30	29	2,07	2,06	2,0	0,34	0,35	0,33
	61	63	60	28	31	28	2,18	2,03	2,14	0,37	0,34	0,36
	57	69	57	28	29	28	2,03	2,38	2,03	0,34	0,41	0,34
<i>Água</i>	4	3	3	6	6	2	0,6	0,5	0,6	-0,2	-0,33	-0,25
	4	2	3	5	5	4	0,8	0,4	0,75	-0,11	-0,42	-0,14
	3	2	3	3	3	4	1,0	0,66	1,0	-0,16	-0,2	-0,14

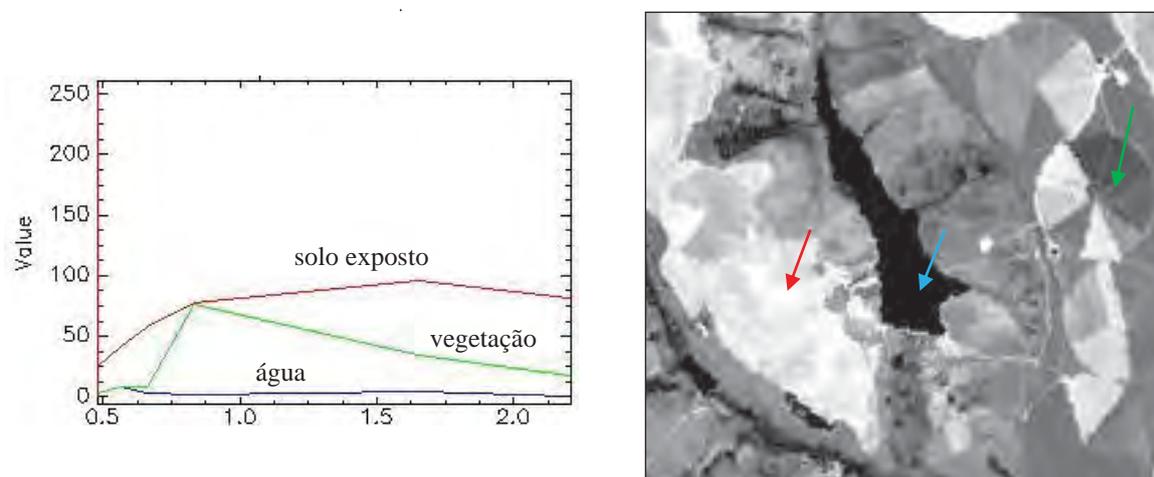


Fig. 9.10 Imagem e espectros de reflectância das bandas do sensor ETM para os alvos amostrados na Tabela 9.2.

A Figura 9.11 mostra, comparativamente, os resultados dos dois índices de vegetação – RVI e NDVI. A imagem colorida é uma composição das bandas do infravermelho próximo e do visível do sensor SPOT, com resolução espacial de 20 m. As cores verdes são de áreas com cobertura vegetal de cultivo, havendo duas linhas de matas galerias, com tons de verde mais carregado. As variações da cor verde das áreas de cultivo correspondem a variações de biomassa e de densidade de clorofila. As cores magenta são de solos expostos preparados para cultivo, muitos com cobertura de palhada seca. Parcelas de solos nus compactados aparecem em tons brancos. As imagens RVI e NDVI mostram um mapeamento detalhado de tons de cinza, em que os tons de cinzas mais claros são das áreas com mais densa cobertura vegetal, gradando para tons de cinza intermediários conforme a cobertura vegetal diminui, até os tons de cinza escuros das áreas sem qualquer cobertura vegetal. Ambas as imagens são bem semelhantes, mas se observa na imagem NDVI uma melhor definição ou nitidez das classes de alvos.

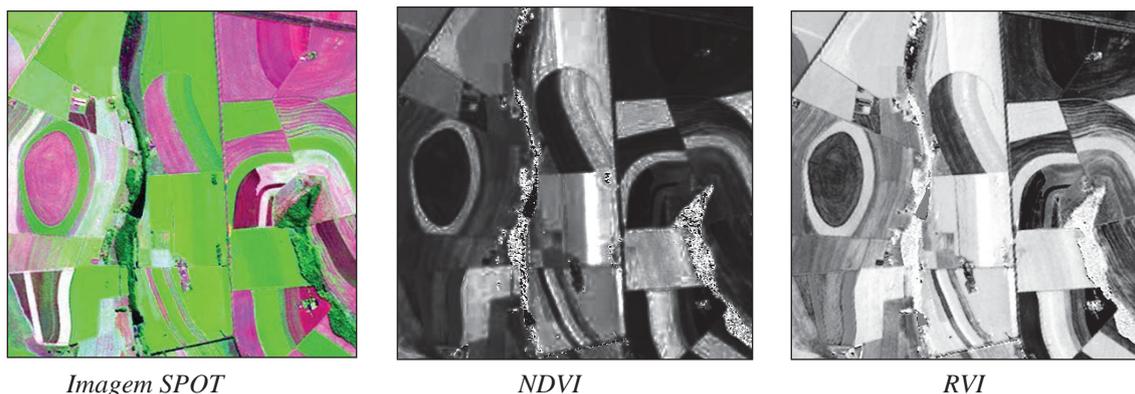


Fig. 9.11 Índice de vegetação obtido pela divisão das bandas do infravermelho próximo com a banda do vermelho da imagem SPOT.

Apesar de grande aceitação do NDVI, Huete e Jackson (1987) constataram que esse índice não confirma ser um bom indicador de biomassa de vegetação se o terreno tiver uma pobre cobertura de vegetação, como em áreas semi-áridas, ou áridas. Propuseram um novo índice, *Soil Adjusted Vegetation Index* (SAVI) que tem um melhor desempenho para as áreas com baixa cobertura vegetal, ou seja, com a presença natural de exposições de solos, e que se mostra sensível à variação dos tipos de solos. Sua formulação é a seguinte:

$$SAVI = \left\{ \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \right\} (1 + L)$$

eq. 9.11

Onde L é uma constante empiricamente determinada para minimizar a sensibilidade do índice de vegetação às variações de reflectância dos tipos de solo. Como a primeira parte da equação SAVI é idêntica ao índice NDVI, se L for igual a zero o SAVI é igual ao NDVI. Para áreas de cobertura vegetal intermediária, L é tipicamente em torno de 0,5. O fator $(1 + L)$ assegura que o intervalo de valores de SAVI é o mesmo que o do NDVI, isso é, entre -1 +1.

Com essa mesma concepção do índice de vegetação é possível modelar índices para água, minerais ou solos. A dificuldade com os minerais e os solos, é que eles apresentam uma grande diversidade de composição e, assim, uma grande variedade de padrões de reflectância. Para cada tipo de mineral ou de solo um índice deve ser idealizado. Consequentemente é maior a exigência de o sensor possuir muitas bandas para se ter uma possibilidade efetiva de criar estes índices. Uma rápida apresentação sobre índices desses materiais é mostrada nos itens a seguir.

9.5.2 Índice de Água

Seguindo os mesmos preceitos estipulados para o índice de vegetação, é também possível, com base na curva de reflectância da água, criar um índice de diferença normalizada da água (NDWI). Esse índice requer o uso de uma banda situada na região do comprimento de onda próxima da cor verde ($\pm 490 - 580$ nm) e de uma banda situada no comprimento de onda do infravermelho próximo ($\pm 760 - 1000$ nm), conforme a equação 9.12.

$$NDWI = \frac{G - NIR}{G + NIR}$$

eq. 9.12

Na Figura 9.12 são mostradas as curvas de reflectância de corpos d'água com diferentes concentrações de partículas de sedimentos em suspensão. Segundo Novo (2001), medidas em campo e experimentos em laboratório comprovam que com o aumento da concentração de sólidos totais em suspensão na água, o material particulado tem como principal efeito o aumento do coeficiente de espalhamento da reflectância da água. A análise do gráfico da Figura 9.12 mostra um patamar de alta de reflectância entre 500 nm a 700 nm, que é mais alto quanto maior é a concentração de sedimentos, e uma queda de reflectância em direção ao infravermelho próximo que se acentua com a diminuição da concentração de sedimentos. Essa condição configura valores de declividades diferentes para cada nível de concentração de sedimentos, possibilitando com a aplicação do índice de água em um mapeamento das plumas de sedimentos, distinguindo níveis de água turva e de água limpa.

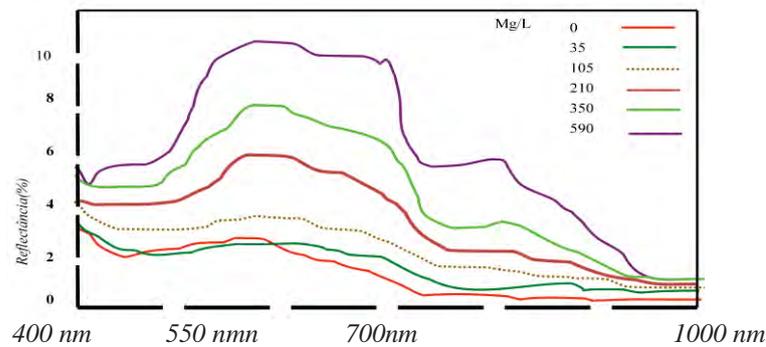


Fig. 9.12 Variação da reflectância da água devido às diferenças de concentrações de partículas sólidas em suspensão (Fonte: Novo, 2008).

Tomando-se imagens do sensor ETM, a aplicação do índice da água pela equação consiste na divisão das bandas 2 (520 – 600 nm) pela banda 4 (760 – 900 nm). A Figura 9.12 de rios amazônicos, com efeito, confirma a validade desse índice para diferenciar plumas de sedimentos em suspensão.

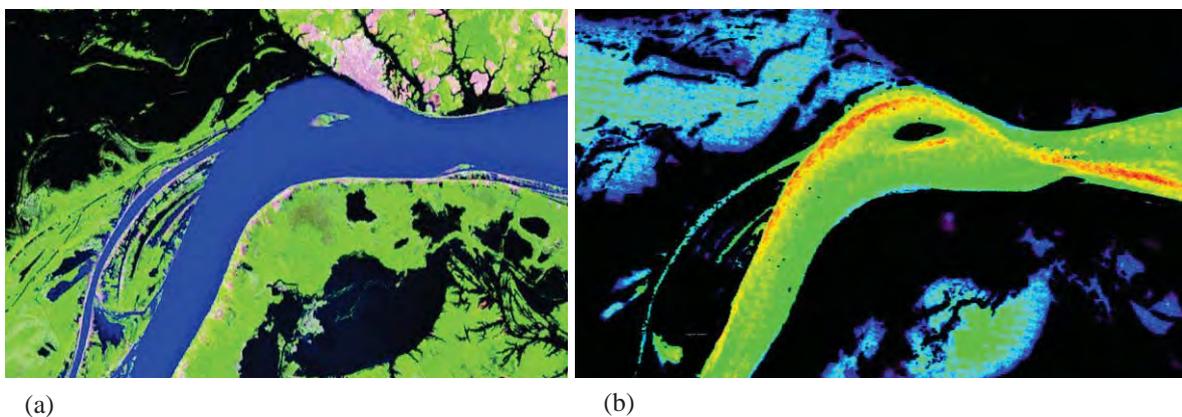


Fig. 9.12 Composição colorida ETM+ 543 (a) e a imagem índice de diferença normalizada da água (b) com destaque para a linha em vermelho do fluxo de sedimentos em suspensão.

9.5.3 Índices Minerais

Nas aplicações geológicas o uso da técnica divisão de bandas também pode se constituir numa excelente opção para a prospecção de alvos geológicos com interesses de pesquisa mineral. Devido ao fato de os minerais e as rochas serem os materiais que apresentam a maior diversidade de bandas de absorção por causa de sua enorme variedade composicional, teoricamente, seria possível criar índices para vários tipos de rochas ou de minerais, tal como o índice de vegetação. Entretanto, para isso o sensor precisaria satisfazer pelo menos dois requisitos. Primeiro, possuir bandas espectrais posicionadas em torno das principais feições de absorção que caracterizam a composição dos materiais geológicos, o que implicaria em um sensor com muitas bandas espectrais. Infelizmente os atuais sensores multiespectrais em operação, além de terem poucas bandas que não estão situadas nos comprimentos de onda favoráveis à geologia, restringem, atualmente, o uso de razão de bandas para fins geológicos. Segundo, como as feições de absorção de rochas ou minerais normalmente tem uma largura muito estreita, as bandas desse sensor precisariam ter larguras espectrais em torno de 10 a 30 nm, o que é bem mais estreito que a largura das bandas dos atuais sensores. O sensor multiespectral ETM do Landsat serve para ilustrar este problema. A banda sete, no infravermelho de ondas curtas (2,08 – 2,35 μm), foi incluída para ser uma banda geológica para a identificação de áreas com alteração hidrotermal, porque esses minerais tipicamente apresentam as suas feições de absorção na região espectral do infravermelho de ondas curtas. Porém, os resultados não se mostraram muito eficientes para esse propósito porque a largura da banda 7 é muito ampla, com 270 nm, e também porque é nesse intervalo espectral que os argilos minerais de intemperismo possuem bandas de absorção de 10 a 30 nm de largura, e isso torna difícil o uso dessa banda para identificar com segurança se há ou não em uma área a presença de alteração hidrotermal.

Atualmente, as seis bandas que o sensor ASTER possui em torno da região espectral da banda 7 do Landsat é a melhor opção geológica. Razões de bandas para identificação de halos de alteração hidrotermal podem ser feitas com a banda 4 deste sensor (1,7 – 1,8 μm), tipicamente onde os materiais geológicos não alterados exibem altas reflectâncias, e com uma das cinco bandas existentes para a identificação de minerais de alteração hidrotermal: bandas 5 (2,145 – 2,185 μm), 6 (2,185 – 2,225 μm), 7 (2,235 – 2,285 μm), 8 (2,295 – 2,3659 μm) e 9 (2,360 – 2,430 μm). Na Figura 9.13 são apresentados os espectros de reflectância de alguns minerais de hidrotermalismo.

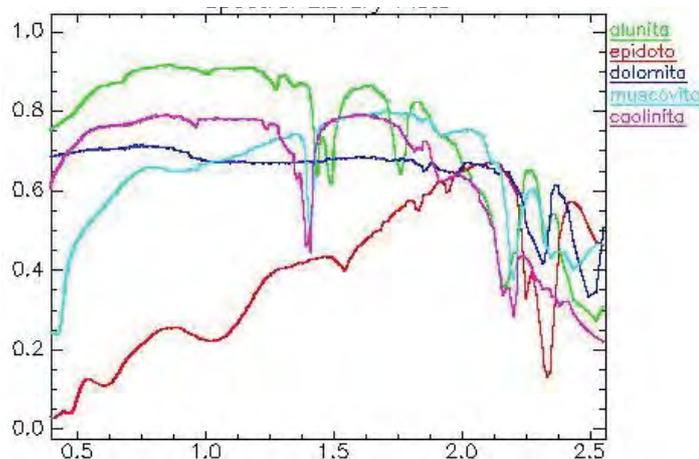


Fig. 9.13 Exemplos de espectros de minerais de alteração hidrotermal que têm intensas bandas de absorção posicionadas na região espectral do infravermelho.

Se as imagens ASTER fossem utilizadas para se fazer uma discriminação de um halo hidrotermal que contivessem os minerais da Figura 9.13 e outros, as seguintes razões de bandas poderiam ser propostas (incluem as bandas 10 a 14 do módulo termal).

Tabela 9.3 Índices minerais para o sensor ASTER usando razões de bandas (Fonte Cudahy & Souza Filho, (2006).

Feições	Bandas ou razões	Referências
Ferro		
Ferro férrico	2/1	Rowan; CSIRO
Ferro ferroso	5/3+1/2	Rowan
Laterita	4/5	Bierwith
<i>Gossan</i>	4/2	Volesky
Silicatos férricos (biotita, clorita e anfibólio)	5/4	CSIRO
Óxidos de ferro	4/3	CSIRO
Carbonatos/Minerais Máficos		
Carbonato/ clorita/ epidoto	(7+9)/8	Rowan
Epidoto/ clorita/ anfibólio	(6+9)/(7+8)	CSIRO
Anfibólio/ MgOH	(6+9)/8	Hewson
Anfibólio	6/8	Bierwith
Dolomita	(6+8)/7	Rowan; USGS
Carbonato	13/14	Bierwith, Nimoyima, CSIRO
Silicatos		
Sericita/ muscovita/ illita/ esmectita	(5+7)/6	Rowan (USGS); Hewson (CSIRO)
Alunita/ caolinita/ pirofilita	(4+6)/5	Rowan (USGS)
Fengita	5/6	Hewson
Muscovita	7/6	Hewson
Caolinita	7/5	Hewson
Argila	(5x7)/6 ²	Bierwith
Alteração	4/5	Volesky
Rocha hospedeira	5/6	Volesky
Sílica		
Rochas ricas em quartzo	14/12	Rowan
Sílica	(11x11)/(10x12)	Bierwith
Minerais de baixo grau (garnierita, clinopiroxênio, epidoto e clorita)	12/13	Bierwith, CSIRO
SiO ₂	13/12	Palomera
SiO ₂	12/13	Nimoyima
Rochas silicáticas	(11x11)/(10x12)	Nimoyima
Sílica	11/10	CSIRO
Sílica	11/12	CSIRO
Sílica	13/10	CSIRO
Outras		
Vegetação	3/2	
NDVI	(3-2)/(3+2)	

10.1 Correlações de Bandas

A maioria das aplicações de sensoriamento remoto, principalmente as que estão voltadas para a exploração e monitoração dos recursos naturais, exige o uso de sensores com um razoável número de bandas, visto que parece ser mais importante discriminar a natureza de um objeto do que, simplesmente, detectar a sua presença. Isso quer dizer, que para se distinguir uma rocha granítica de uma vulcânica, uma água turva de uma água límpida ou uma vegetação sadia de uma vegetação seca, o sensor deve possuir bandas posicionadas em comprimentos de onda que permitam diferenciar as variações de reflectância referentes às diferenças de composição dos materiais. Contudo, essa exigência de um maior número de bandas tem um compromisso crítico. Ao se comparar, visualmente ou numericamente, as múltiplas bandas de um sensor, normalmente se observa alta semelhança entre algumas delas, principalmente, entre as bandas contíguas da mesma região espectral. Diz-se que essas bandas têm alta correlação, indicando que há redundância de informações de dados, ou seja, repetição.

A alta correlação tem como causa a semelhança da reflectância entre os alvos presentes numa área, como vemos na Figura 10.1. Destacam-se a combinação de dois fatores para a alta correlação entre as imagens: i) muitos alvos, como é exemplo a vegetação, possuem uma reflectância muito próxima nos comprimentos de onda do visível ou do infravermelho de ondas curtas, resultando em valores de radiância pouco diferenciados e, portanto, as imagens desses comprimentos de onda são muito semelhantes entre si; ii) o sombreamento topográfico é, espectralmente, o mesmo em todas as bandas ópticas de um sensor, aparecendo dominante em áreas de relevo acidentado com baixo ângulo de iluminação solar, e com isso, aumenta o grau de correlação entre as bandas. Uma alta correlação também é encontrada em áreas com pouca variação de tipos de alvos.

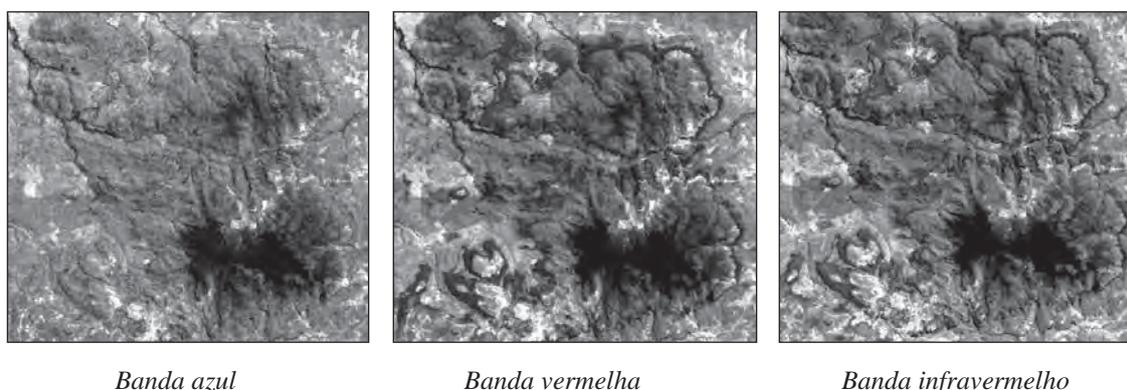


Fig.10.1 A similaridade entre as três bandas indica a quantidade de correlação espectral dos dados.

A correlação tem um efeito muito mais significativo nas imagens de sensores hiperespectrais, em razão das centenas de bandas que esses sensores adquirem, do que nas poucas bandas dos sensores multiespectrais. Mas, o tratamento para solucionar o problema de correlação das imagens é encarado da mesma maneira, independente do número de bandas que têm os sensores multiespectral e hiperespectral. No capítulo 14, sobre processamento de imagens hiperespectrais, este assunto será abordado mais detalhadamente.

Como se tem visto nas discussões dos capítulos precedentes, pode-se generalizar que a base do processamento de imagens multiespectrais é a manipulação numérica dos dados para a obtenção de novas imagens com alto contraste, a fim de apresentá-las em cores no monitor de vídeo, para o analista executar as interpretações. Entretanto, quando a correlação entre algumas bandas é alta, as possíveis combinações das bandas para se obter composições coloridas, deixam de exibir diferenças de contrastes para uma boa interpretação. Sendo assim, é lógico pensar que por causa desta redundância a análise de todas as bandas não parece ser necessária. Mas, de fato, a redundância ou correlação não é 100%, havendo sempre um mínimo de informação não redundante que é interessante de ser preservado.

Uma poderosa técnica de processamento de imagens foi desenvolvida para eliminar a alta correlação entre as bandas de um sensor, com o mínimo de perda de informação. Essa técnica é conhecida como principais componentes. A técnica principais componentes tem seus princípios na estatística para análise de um grande número de variáveis, e por isso, é largamente usada na biologia e geologia como um processo de redução da dimensão dos dados a serem analisados. A grande vantagem dessa técnica é a remoção de qualquer correlação presente no conjunto de bandas originais, com uma simultânea compressão da maioria da informação total presente em todas as bandas, isso é, concentra a variância total para poucas dimensões. É o mesmo de dizer, que de um conjunto de dez bandas, cerca de 90% a 95% de toda a informação das bandas fosse redistribuída e concentrada em apenas três novas imagens (principais componentes), sem que houvesse correlação entre elas. Os outros 10% ou 5% de informações remanescentes se distribuem nos outros sete componentes, que igualmente não mais se correlacionam.

Os novos componentes são relacionados aos valores de brilho do conjunto das imagens originais, via uma transformação linear, que tem dois efeitos práticos: (i) tornar evidentes feições que não eram anteriormente discerníveis; e (ii) devido à compressão de dados que é obtida, combinando-se os três primeiros principais componentes, as informações de todas as bandas podem ser vista numa única composição colorida. Porém, as imagens componentes perdem as relações físicas da reflectância dos alvos, o que torna o processo interpretativo um tanto trabalhoso.

Neste capítulo serão abordados os princípios da transformação de imagens multiespectrais para o novo conjunto de componentes, primeiramente, com a técnica conhecida como Transformação por Principais Componentes (TPC), que permite operações com qualquer número de bandas. Uma derivação dessa técnica é apresentada, a seguir, para um conjunto de apenas três bandas, visando nesse caso, a obtenção de composições coloridas RGB com imagens componentes descorrelacionadas, mas com a diferença de que não há perda das relações físicas da reflectância das bandas envolvidas. Como será visto a seguir, ambos os processos envolvem uma rotação dos eixos dos dados originais, razão pela qual essas técnicas serem denominadas de rotação espectral.

10.2

Transformação por Principais Componentes

A natureza do formato das imagens multiespectrais possibilita representar os valores de brilho dos pixels por suas posições dentro de um espaço vetorial, com quantos eixos ou

dimensões forem as bandas espectrais. Isso foi visto na representação de cor das composições coloridas, por meio do espaço cúbico das três cores RGB, e que consistia, simplesmente, plotar os valores de brilho dos pixels de cada uma das três bandas, em um sistema ortogonal de coordenadas, no espaço tridimensional. O mesmo pode ser realizado para o espaço n -dimensional, com qualquer número de bandas que um sensor possua. No contexto da transformação por principais componentes, o objetivo da representação do espaço vetorial n -dimensional é determinar o nível de correlação que pode haver entre n bandas e calcular o grau de informação ou variância que os dados apresentam, a fim de determinar os coeficientes que transformam as imagens em novos componentes. Para facilitar o entendimento matemático e geométrico, a discussão que segue se limitará ao espaço de duas dimensões, pelo fato de que dimensões maiores só podem ser algebricamente representadas.

Considere um espaço de duas variáveis x e y com um grande número de pixels plotados neste espaço, como na Figura 10.2a. Cada pixel pode ser descrito por seu vetor x_i , enquanto, o vetor média m define a média das posições dos pixels neste espaço. Se os valores dos pixels são bastante correlacionáveis, medidas simultâneas de x e y traçam uma linha reta definida pelo eixo AB na Figura 10.2b. Se x e y não são perfeitamente correlacionáveis, os pixels são delimitados pelo espaço de uma elipse, com seus dois eixos com dimensões, significativamente, diferentes (Figura 10.2c). Haverá uma direção predominante (AB) de variabilidade que tem um eixo maior em relação a um segundo pequeno eixo traçado ortogonalmente (CD), que mostra ter baixa variabilidade. Se este eixo CD contém uma pequena proporção do total da variabilidade dos dados, ele pode ser ignorado sem acarretar muita perda da informação. Isso significa uma diminuição na dimensão dos dados de dois para um. Dessa maneira, ao se representar a distribuição dos pixels na forma de uma elipse, percebe-se que os eixos AB e CD revelam, mais apropriadamente, a estrutura interna que está presente nos dados das imagens, do que os eixos x e y separados. Para confirmar essa afirmativa, observe na Figura 10.2a, que as variâncias das variáveis x e y , que são medidas pelo espalhamento dos pontos na direção paralela aos eixos x e y , são aproximadamente iguais.

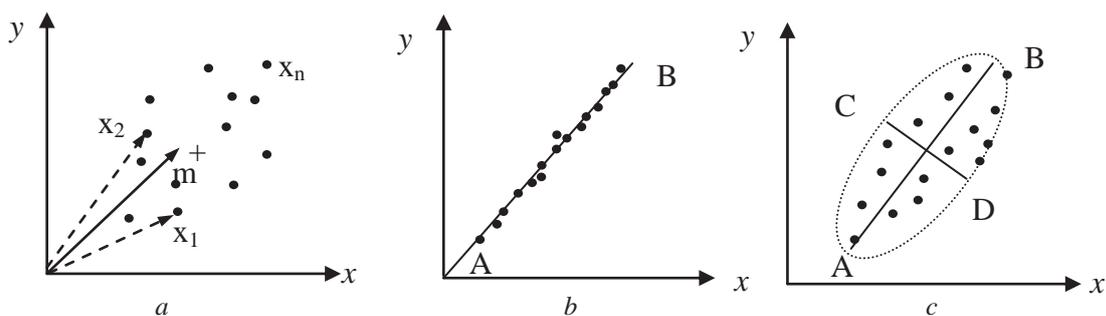


Fig. 10.2 Espaço bidimensional da representação dos dados mostrando: a) o vetor x_i dos pixels e o vetor média m ; b) a alta correlação dos dados com a variabilidade em um único eixo AB ; c) a correlação positiva com os eixos AB e CD medindo a variabilidade dos dados.

Segundo Mather (1987), o exemplo da Figura 10.2 mostra que há uma distinção importante a ser vista entre o número de variáveis (bandas) e a dimensionalidade do conjunto de dados. Na Figura 10.2b, o número de variáveis é dois, mas a dimensionalidade é um. Na Figura 10.2c, a dimensionalidade dos dados é efetivamente um, embora o número de variáveis observadas seja de fato dois. O uso de um único eixo AB substitui os eixos separados x e y , com a vantagem de reduzir a dimensionalidade dos dados e, adicionalmente,

a informação transmitida pelo eixo AB é maior do que a informação transmitida pelos dois eixos separados. Normalmente, imagens multiespectrais têm uma dimensionalidade que é menor do que o número de bandas espectrais. A transformação por principais componentes atua neste sentido, de reduzir o conjunto de dados, preservando a informação existente e, com isso, minimizar o esforço de análise de um grande número de variáveis, no caso de sensoriamento remoto, de um grande número de bandas.

A forma da elipse, como meio para descrever o espalhamento dos pixels no espaço n -dimensional, é definida pela matriz de covariância calculada para as n bandas espectrais. Por definição, matriz de covariância é uma matriz simétrica, que mede como duas ou n variáveis variam conjuntamente, e seus valores são sempre positivos. A covariância é por vezes chamada de medida de dependência linear entre duas ou n variáveis aleatórias. Calculando-se o vetor média e a matriz de covariância, determinam-se a localização e a forma do espalhamento dos pontos no espaço n -dimensional e se conhece os valores numéricos da correlação existente entre o conjunto de bandas analisadas.

A matriz de covariância é um dos mais importantes recursos matemáticos usados no processamento de imagens multiespectrais e os valores da matriz enfatizam propriedades do conjunto das bandas analisadas. Mas, há uma controvérsia em se usar a matriz de covariância ao invés da matriz de coeficientes de correlação para transformações de bandas. Se a matriz de covariância for usada para definir a forma da elipse que encerra os pontos numa direção particular, as medidas de cada variável devem ser comparáveis. E isso não é o que de fato acontece quando se compara os valores digitais entre bandas diferentes. Um número digital de valor 52 numa dada banda representa um valor de radiância que não é, fisicamente, o mesmo valor de radiância para o número 52 em outra banda. Simplesmente, porque os detectores de cada banda possuem valores específicos de ganhos e *offset* para efeitos de calibração. Sendo assim, são variáveis não totalmente comparáveis. Pode-se verificar isso na Figura 10.3, que é um extrato de pixels de duas bandas em diferentes comprimentos de onda, da mesma área. Na imagem à esquerda o pixel situado na coluna 1, linha 2, tem ND=52. Esse mesmo valor digital é encontrado na imagem à direita na posição coluna 1, linha 4. Observe a diferença dos tons de cinza nas duas imagens para o mesmo valor digital 52. Nessa situação é que a matriz de coeficientes de correlação é melhor para medir o grau de correlação entre bandas espectrais. Os coeficientes de correlação são, simplesmente, a covariância medida para variáveis padronizadas (Mather, 1987), e são encontrados na matriz, nos elementos fora da diagonal.

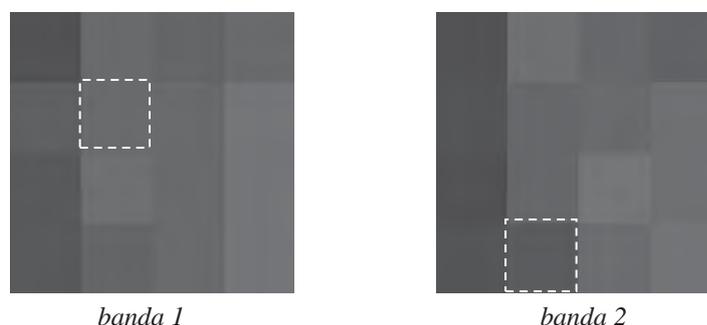


Fig. 10.3 Imagens de duas diferentes bandas contendo pixels de igual valor digital, mas que exibem valores de brilho diferentes. O pixel com contorno tracejado tem valor 52 nas duas bandas.

Como vem sendo destacado, a experiência nos mostra que qualquer sensor multiespectral possui algumas bandas com alta correlação, de modo que os eixos de suas

funções de densidade de probabilidade (*FDP*), não são estatisticamente ortogonais, isso é, as variáveis nos eixos não são independentes. A técnica principais componentes envolve uma rotação (e uma translação) num hipotético espaço de atributos do sistema de coordenadas da função de densidade de probabilidade, produzindo novas variáveis conhecidas como principais componentes, ou eixos, que são combinações lineares das variáveis originais (bandas originais). A rotação das coordenadas dos eixos originais é um esforço para ortogonalizar os novos eixos PC, fazendo-os coincidirem ao máximo com as direções de distribuição dos dados, ou suas variâncias.

Numa representação hipotética, considere a distribuição no espaço bidimensional dos valores de brilho dos pixels de duas bandas (Figura 10.4). Os pontos representam o espaço de distribuição dos pixels, que nas duas bandas originais ostentam quase que as mesmas características espectrais (alta correlação). Na transformação por principais componentes, isso é, no novo sistema de eixos ou componentes ortogonais rotacionados, os pixels apresentam no primeiro componente (PC_1) ou primeiro eixo principal, maior variância, enquanto, que no segundo componente (PC_2) a variância é menor. Desde que se assume que a variância é uma medida do conteúdo de informação da imagem, o primeiro componente ou primeiro eixo agrega uma maior quantidade de informação espectral, produzindo uma imagem com maior detalhe de informação. Nesse novo espaço de eixos rotacionados o primeiro componente não tem correlação com o segundo componente. Situações similares podem ser imaginadas em espaços de n dimensões, ou n bandas, sabendo-se, contudo, que todo o processo de transformação da imagem é realizado numa concepção puramente matemática.

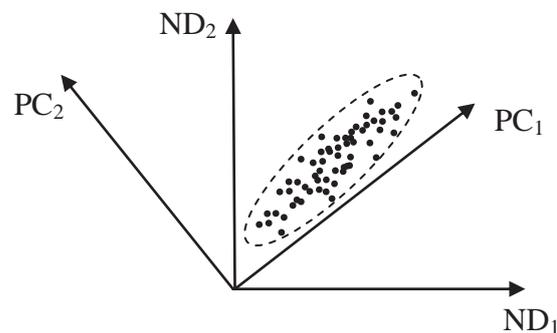


Fig. 10.4 Rotação espectral dos eixos originais com alta correlação, para novos eixos PC descorrelacionados.

Em síntese, no processamento das imagens por principais componentes, o objetivo principal é definir o número de dimensões que estão presentes no conjunto de dados e fixar os coeficientes que especificam as posições dos eixos que apontem nas direções das mais altas variabilidades dos dados. Portanto, eliminar a alta correlação das imagens tem a vantagem de reduzir o volume de dados a ser analisado e de redistribuir a informação espectral entre os novos principais componentes.

O cálculo da transformação por principais componentes é extenso e de relativa complexidade. No livro *Statistic and Data Analysis in Geology*, de Davis (2002), o leitor encontrará a base do desenvolvimento estatístico, com exemplos de aplicações a variáveis geológicas. Um exemplo prático é mostrado a seguir, com as seis bandas ETM da faixa óptica do espectro. Primeiro, foram computadas as matrizes de correlação das seis bandas, mas, cabe ao usuário decidir se todas as bandas ou apenas uma parte delas será utilizada para

os cálculos dos componentes. Ambas as matrizes são simétricas, e por isso é desnecessário repetir os mesmos valores acima da diagonal. A Tabela 10.1 é a matriz dos coeficientes de correlação computada para as seis bandas. Os coeficientes variam de -1 a +1. Os altos valores positivos indicam que se tem uma correlação positiva alta entre as bandas e a correlação diminui quando o coeficiente se aproxima de zero. O sinal negativo indica que há correlação inversa entre as bandas, ou seja, quando um pixel tem um alto valor digital numa banda, na outra banda ele tem um baixo valor. Coeficientes negativos ocorrem devido à presença de vegetação, que na banda 4 do infravermelho próximo têm altos valores de brilho, enquanto, nas outras cinco bandas, os valores são baixos. A Tabela 10.2 é a matriz de covariância cujos valores medem quanto as bandas variam conjuntamente. É também, chamada de matriz de variância-covariância porque a diagonal é a medida da variância de cada banda. Note neste exemplo que a banda 5 é a banda que tem a maior variância, ou seja, a banda que contém maior informação e maior contraste espectral.

Tabela 10.1 Matriz de coeficientes de correlação computada de seis bandas do sensor ETM

Correlação	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
Banda 1	1,0					
Banda 2	0,918	1,0				
Banda 3	0,935	0,953	1,0			
Banda 4	-0,430	-0,558	-0,418	1,0		
Banda 5	0,876	0,861	0,893	0,457	1,0	
Banda 7	0,881	0,851	0,906	0,332	0,965	1,0

Tabela 10.2 Matriz de covariância das mesmas bandas da Tabela 10.1

Covariância	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
Banda 1	20,408					
Banda 2	15,747	14,411				
Banda 3	32,681	27,963	59,751			
Banda 4	17,661	19,231	29,357	82,474		
Banda 5	78,381	64,667	136,773	82,191	392,147	
Banda 7	37,743	30,633	66,452	28,639	181,325	90,045

O primeiro passo na transformação principais componentes consiste num cálculo algébrico linear que altera a matriz de coeficientes, determinando um conjunto de quantidades denominado de autovalores (*eigenvalues*). Os autovalores são medidos em termos de unidade de variância, na diagonal da matriz da Tabela 10.3. Por convenção, eles são arranjados em ordem decrescente de variância. A variância total das imagens componentes mantém a mesma das imagens originais, só que a maior variância agora está localizada no primeiro componente, com valores sucessivamente menores para os componentes de ordem maior. Como a variância é uma das medidas da quantidade de informação presente numa imagem, os autovalores representam o tamanho dos eixos principais do elipsóide de seis eixos. Fora da diagonal os valores zero indicam não haver qualquer correlação entre os componentes. O número de principais componentes sempre será igual ao número de bandas originais.

Tabela 10.3 Matriz de autovalores (*eigenvalues*) calculados pela transformação dos coeficientes de correlação.

Componentes	PC1	PC2	PC3	PC4	PC5	PC6
PC1	572,816					
PC2	0	65,961				
PC3	0	0	14,670			
PC4	0	0	0	3,174		
PC5	0	0	0	0	1,916	
PC6	0	0	0	0	0	0,699

Para facilitar a percepção do impacto dessa transformação, pode-se apresentar os autovalores, isso é, as variâncias, em porcentagens. Para se calcular a porcentagem de variância de cada imagem principal componente, basta dividir a variância total dos seis componentes pela variância de cada componente. Seus valores estão mostrados na Tabela 10.4.

Tabela 10.4 Autovalores em porcentagens

Componentes	PC1	PC2	PC3	PC4	PC5	PC6
% variância	86,891	10,005	2,225	0,481	0,291	1,107
% variância acumulada	86,891	96,896	99,121	99,602	99,893	100

Observe que os três primeiros componentes somam 99,121%, o que se pode dizer que é praticamente a variância total do conjunto das seis bandas originais. O restante da variância, que é menor que 1%, seria muito pouco significativo em termos de conteúdo de informação. Normalmente, considera-se que a partir do quarto componente as imagens contêm apenas ruídos e podem ser desprezadas. Em outras palavras, separa-se a variância não aleatória (conteúdo de informação), da variância aleatória (ruído), enquanto, simultaneamente, qualquer redundância entre as bandas é eliminada. Como resultado prático os três primeiros componentes, que contêm 99,121% da variância total original, podem ser combinados em uma única composição colorida RGB. Por essa razão, a transformação por principais componentes é uma forma de reduzir a dimensão dos dados originais, diminuindo a obrigação de se analisar um grande número de variáveis. Mas, antes que esse processo possa ser concluído, uma segunda operação é processada. Associados à cada autovalor existe um conjunto de coordenadas que define as direções dos eixos dos principais componentes. São chamados de autovetores (*eigenvectors*). A Tabela 10.5 apresenta os autovetores computados.

Tabela 10.5 Matriz de autovetores derivados da matriz de coeficientes de correlação.

Componentes	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
PC1	0,171	0,143	0,299	0,190	0,823	0,384
PC2	-0,012	0,061	-0,045	0,967	-0,116	-0,213
PC3	0,377	0,359	0,736	-0,023	-0,429	0,056
PC4	0,135	0,072	0,167	-0,150	0,351	-0,896
PC5	0,892	-0,064	-0,445	-0,001	-0,028	0,035
PC6	0,121	-0,915	0,376	0,073	-0,018	-0,005

Os coeficientes da matriz de autovetores são interpretados como as direções cosenos dos novos eixos em relação aos eixos originais, apontando na direção de qual é a contribuição ou peso das bandas originais na formação de cada principal componente. De uma maneira bem simples, pode-se dizer que a banda original que mais contribui para a formação de um principal componente é a que tem na matriz de autovetores o valor absoluto maior. Na Tabela 10.5 o primeiro componente tem uma contribuição muito maior da banda 5. Como consequência, a imagem da PC1 será muito semelhante, na aparência, com a banda 5 original. A diferença com a imagem original da banda 5 é que a PC1 é interpretada como sendo, aproximadamente, uma imagem albedo, a qual descreve o brilho médio da cena. A PC1 é quase uma soma das médias das imagens, enquanto os componentes restantes de algum modo parecem diferenças entre pares das imagens originais.

Em termos numéricos pode-se entender que os autovetores são definidos como uma combinação aditiva e linear computada para cada pixel de uma banda original, para criar o novo valor de pixel dos principais componentes. Tomando-se como exemplo os autovetores do primeiro componente da matriz da Tabela 10.5, a seguinte operação é feita para se calcular o novo valor de cada pixel da imagem principal componente. A mesma operação é repetida com os demais componentes.

$$PC_1 = 0,171x_{ij1} + 0,143x_{ij2} + 0,299x_{ij3} + 0,190x_{ij4} + 0,823x_{ij5} + 0,384x_{ij6}$$

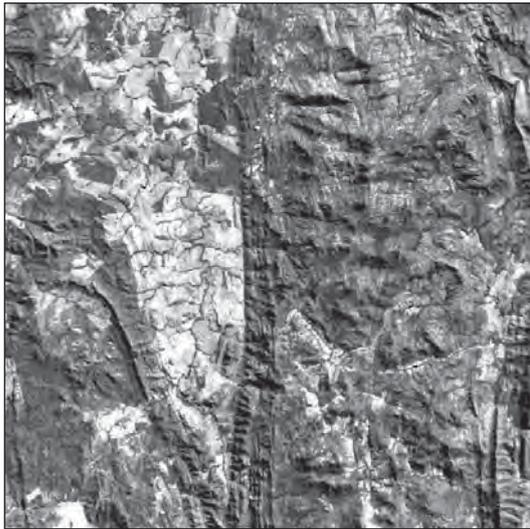
onde, PC_{1ij} = valor do pixel na linha i coluna j do primeiro principal componente
 $x_{ij1...6}$ = valor do pixel na linha i coluna j de cada uma das bandas originais 1 a 6

A Figura 10.5 mostra as imagens resultantes da transformação por principais componentes, cujos dados são os das matrizes apresentadas. Como as imagens principais componentes têm correlação zero, qualquer pixel lido em um componente tem um diferente valor digital nos outros componentes.

Os três primeiros principais componentes, que reúnem 99,121% da informação total, podem ser combinados em uma composição colorida RGB, obtendo-se uma imagem de alto contraste de cores. As cores são mais contrastantes do que as que são obtidas com as bandas originais, e isso é devido à ausência de correlação entre os componentes. Porém, há uma grande dificuldade para se identificar as naturezas das classes dos alvos, porque sendo cada uma das imagens componentes formadas pela soma das contribuições de informações de todas as bandas originais, são perdidas as relações espectrais dos alvos com as imagens.

Crósta e Moore (1989) desenvolveram uma solução para essa dificuldade de identificação da natureza das classes nas imagens componentes principais, por meio da aplicação de uma técnica de análise denominada *Feature Oriented Principal Component* (FPSC), também denominada Técnica Crósta. Essa técnica possibilita identificar as classes de alvos através da análise da matriz de autovetores, reconhecendo qual componente contém a informação diretamente relacionada à assinatura espectral do alvo.

A primeira etapa da FPSC é a avaliação do espectro do alvo a ser pesquisado, com o objetivo de identificar duas bandas que contenham respostas de feições espectrais marcantes, uma com alta absorção e outra com alta reflectância. Após selecionadas essas duas bandas, são escolhidas outras duas bandas que contenham reflectâncias médias do alvo. Nessas quatro bandas é aplicada a transformação por principais componentes. A seguir são analisados os valores e sinais da matriz de autovetores, considerando-se que a imagem principal componente que contém a informação individualizada do alvo, é aquela que apresenta os maiores e menores valores absolutos nas bandas que têm as feições espectrais do alvo. Esse componente conterá a informação individualizada do alvo.



PC1



PC2



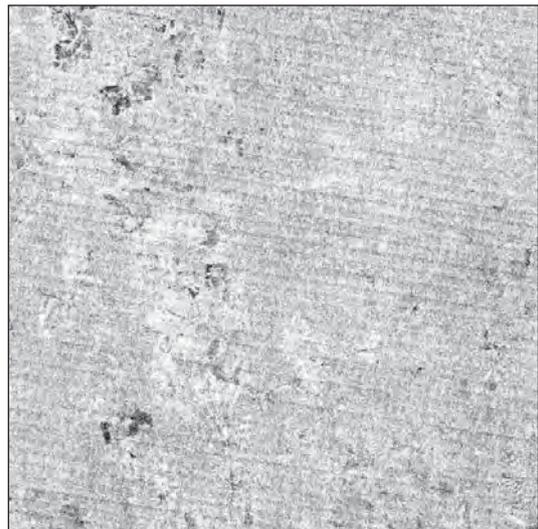
PC3



PC4



PC5



PC6

Fig. 10.5 Imagens principais componentes das seis bandas TM com os três primeiros componentes acumulando 99,126% da variância total das imagens originais.

Por exemplo, os espectros de reflectância dos minerais hidroxilados caolinita, montmorilonita e muscovita, apresentam uma forte feição de absorção na banda 7 e uma alta reflectância na banda 5 dos sensores TM e ETM⁺. Na Figura 10.6 é mostrado o espectro para o mineral muscovita e as posições espectrais das bandas do sensor ETM⁺. A aplicação da técnica crosta para mapeamento deste grupo mineral, e no caso deste exemplo da muscovita, utiliza a rotação por principais componentes entre as bandas 1, 4, 5 e 7.

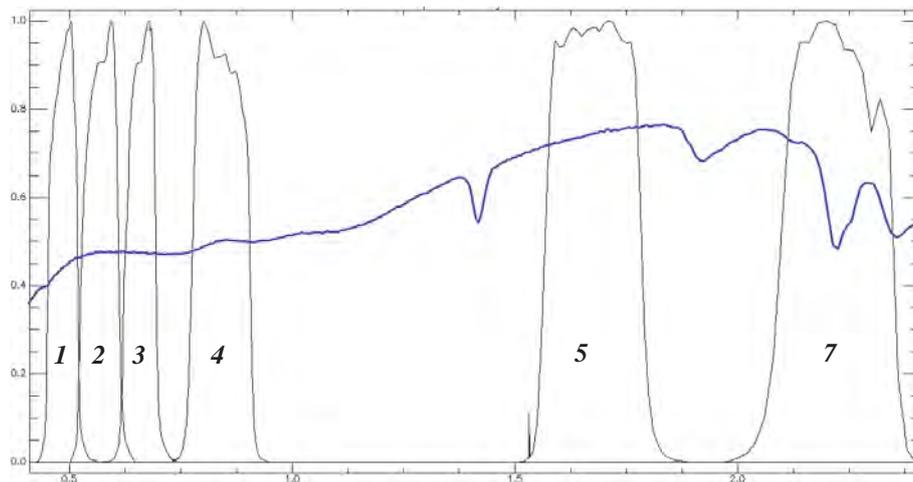


Fig. 10.6: Espectro da muscovita sobreposto ao intervalo das bandas 1, 2, 3, 4, 5 e 7 do sensor ETM⁺.

Na análise da matriz de autovetores deve-se identificar o principal componente que tenha sinais opostos e variações de moderado a alto para as bandas 5 e 7, sendo esse o principal componente que identifica as áreas que concentram a presença de muscovita nas rochas.

Um exemplo é demonstrado com as imagens ETM⁺ do Granito Pedra Branca da Província Estaniífera de Goiás, município de Nova Roma (Figura 10.7a). Na matriz de autovetores da Tabela 10.6 observa-se que os valores que apresentam a informação relativa à muscovita é o PC4 (maiores sinais de valores opostos). A imagem do componente PC4 é mostrada na Figura 10.7b, onde se destaca uma área de forma oval, a qual coincide com a faixa de greissen muscovítico mineralizado em estanho no granito Pedra Branca.

Tabela 10.6 Autovetores obtidos por principais componentes para as bandas 1, 4, 5 e 7 do sensor ETM⁺ do satélite Landsat 7.

	B1	B4	B5	B7
PC1	0,199966	0,250449	0,780750	0,536394
PC2	-0,191043	0,887538	0,050195	-0,416244
PC3	-0,875854	-0,264005	0,387476	-0,114209
PC4	-0,395470	0,282583	-0,487619	0,725244

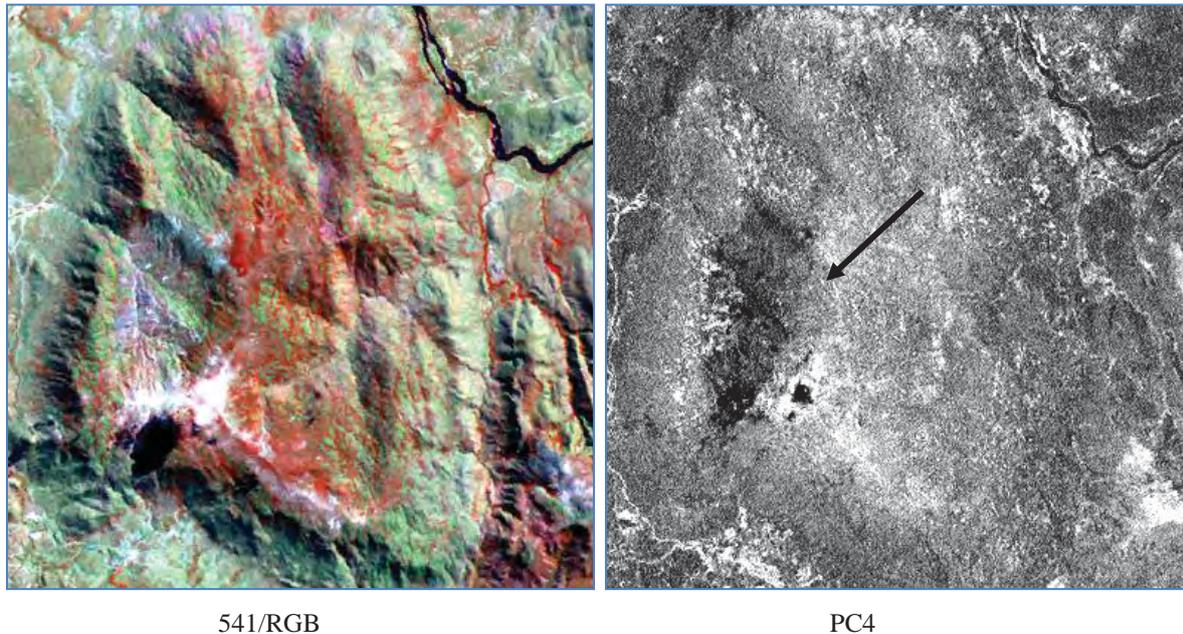


Fig. 10.7 Na imagem à esquerda composição colorida da área do granito Pedra Branca e na imagem à direita exemplo da aplicação da técnica Crósta (*Feature Oriented Principal Component*) com as bandas 1, 4, 5, 7 ETM, destacando a área de graissen no granito Serra Branca (GO).

10.3 Descorrelação de bandas

Outra técnica que também zera a correlação entre as bandas de um sensor, com princípios semelhantes à técnica principais componentes, é muito usada para a obtenção de composições coloridas a partir da seleção de um conjunto de apenas três bandas. Essa técnica, denominada de descorrelação de bandas, objetiva aumentar o contraste das cores, tendo em vista que as composições coloridas obtidas com as bandas originais modificadas por técnicas de ajustes histográficos, somente exibem um alto contraste de cores se possuem baixas correlações espectrais. Quando são altamente correlacionadas, produz-se uma imagem na qual algumas cores altamente saturadas não aparecem. Cores saturadas primárias ou secundárias são cores com alto brilho e com alto contraste. A ausência de cores saturadas na imagem comprova que as modificações de contraste por ampliações histográficas falham no sentido de não promover uma redistribuição equilibrada das cores, entre bandas que tenham alto grau de correlação. Gráficamente, esse efeito pode ser mostrado no espaço cúbico de cores RGB (Figura 10.8a), onde a representação histográfica tridimensional de três bandas é uma distribuição de forma elíptica, alongada segundo o eixo acromático. O tamanho da elipse é dimensionado pelos seus três eixos, ao longo dos quais são representados os espalhamentos dos pixels de cada uma das três bandas originais. O eixo maior da elipse e a sua direção representam a variação de intensidade de brilho dentro da imagem, a qual é a maior fonte de correlação interbanda. Depois de ser aplicada uma modificação de contraste, individualmente a cada uma das três bandas, a elipse torna-se mais alongada e ocupa uma porção maior do espaço cúbico de cores (Figura 10.8b). Mas, ainda é mantida a mesma proporção básica dos eixos da elipse, indicando que a correlação entre as bandas realçadas permanece. A consequência da manutenção dessa correlação é que grande parte do espaço volumétrico tridimensional do espaço de cores do cubo não é utilizado.

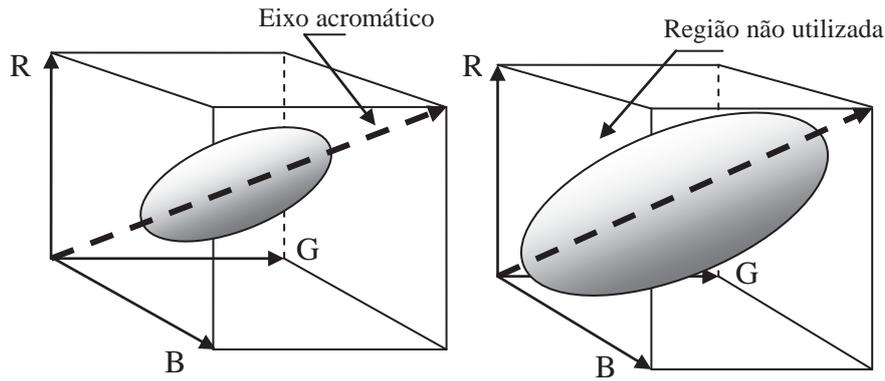


Fig. 10.8. (a) No espaço de cores RGB três bandas geram um histograma em três dimensões que assume a forma de uma elipse alongada. (b) Um realce linear amplia a elipse mas, a correlação existente entre as bandas permanece.

Para ocupar todo o espaço de cores do cubo e, assim, se ter uma contribuição total ou saturada de todas as cores representadas pelos três eixos RGB do cubo, a elipse deveria tornar-se uma esfera. Por definição, estatisticamente, a esfera ou o círculo representa o espaço da distribuição entre variáveis não correlacionadas, ou seja, correlação zero, como pode ser visto na Figura 10.9. Para obter isso, é necessário realizar uma transformação das bandas originais, na qual cada um dos valores da imagem de saída, ou novos componentes, depende dos valores conjuntos dos três componentes de entrada e não dos valores individuais de cada banda, como ocorre com a ampliação de contraste por manipulação histográfica. Esse tipo de transformação tem o pressuposto de obter uma distribuição esfericamente simétrica, que resulta em três novas imagens descorrelacionadas. Recordando o que se viu na sessão anterior, tal transformação baseia-se no uso da transformação por principais componentes.

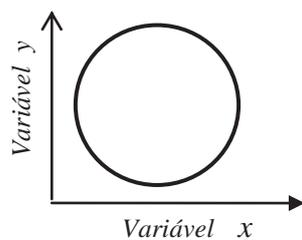


Fig. 10.9 O círculo representa o espaço de uma distribuição entre duas variáveis não correlacionadas.

Os novos componentes descorrelacionados passam a ter uma distribuição que ocupa quase todo o espaço cúbico de cores. Dessa forma, são maximizadas as feições de cores sem que sejam alteradas, consideravelmente, as cores originais da imagem. Isso porque os componentes não perdem a relação dos valores digitais transformados, com as propriedades físicas originais da radiância. O resultado é a obtenção de uma composição colorida com uma intensidade de contraste de cores muito maior do que a da composição colorida primária. A vantagem é que a interpretação da imagem é bem menos complexa do que a de principais componentes e pode ser feita com base nas propriedades do comportamento de reflectância dos alvos, como se faz em uma composição RGB normal. A limitação dessa transformação é que a sua aplicação é reduzida a três bandas.

Os procedimentos de realce por decorrelação, optando-se pela apresentação da transformação proposta por Soha e Scharwtz (1978), denominada de *Whitening*, consistem numa transformação por principais componentes, cuja matriz é uma matriz diagonal de autovalores que tem a forma:

$$|W| \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix}$$

Segue um realce individual dos componentes por uma equalização de variância, a qual assegura que os dados de cada componente tenham a mesma variância e que ocupem em cada eixo o volume máximo esférico no espaço de cores. O modelo de transformação desenvolvido por Soha e Scharwtz (1978), tem a formulação segundo a equação 10.1. Nesta equação, x são os vetores de valores de brilho da imagem original e y é o correspondente vetor de intensidade depois da transformação por principais componentes.

$$y = W^{-1/2\phi} x$$

eq. 10.1

A nova matriz *whitening* tem a forma:

$$W^{-1/2} = \begin{vmatrix} 1/\sqrt{\lambda_1} & 0 & 0 \\ 0 & 1/\sqrt{\lambda_2} & 0 \\ 0 & 0 & 1/\sqrt{\lambda_3} \end{vmatrix}$$

onde, $\lambda_1... \lambda_n$ da matriz $W^{1/2}$ são os autovalores e ϕ é a matriz de autovetores da matriz de covariância de x que promove a rotação dos eixos, eliminando a correlação original. W simboliza *Whitening*.

A representação gráfica em duas dimensões vista na Figura 10.10, mostra a rotação ϕ dos eixos originais para novos eixos ortogonais DEC_1 e DEC_2 , que consistem nas novas imagens decorrelacionadas.

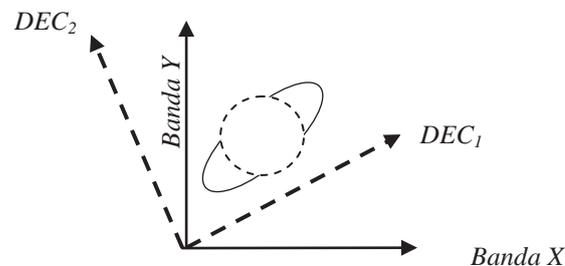


Fig. 10.10. Transformação da distribuição elíptica dos dados originais com correlação positiva para uma distribuição circular com correlação zero.

Como se procurou ressaltar inicialmente, o mais interessante do processo de decorrelação de bandas é fazer com que os dados das imagens transformadas retornem ao espaço original de cores. Nesse caso, o retorno com rotação ϕ é mais vantajoso do que no método de principais componentes, porque ele permite que as relações de cores básicas das bandas da imagem original sejam preservadas. Isso facilita ao intérprete para mapear as cores das imagens componentes, em concordância com as radiâncias dos alvos. Como se vê na equação 10.1, para se retornar ao espaço de cores originais efetua-se o inverso da transformação por principais componentes, o que é, simplesmente, a sua transposição. Lembrar que uma matriz transposta é uma matriz em que os elementos $a(i,j)$ são trocados pelos elementos $a(j,i)$, isso é, a matriz é rotacionada ao redor da diagonal principal.

A eficiência desse processo de realce de cores das imagens pode ser visto no exemplo da Figura 10.11, que compara uma composição colorida RGB das bandas ETM 5, 4, e 3 realçadas, independentemente, por expansão linear de contraste, com a composição colorida das bandas decorrelacionadas. Nota-se que as cores na imagem decorrelacionada são mais claras (saturadas), daí o nome da transformação se denominar *Whitening*. O lago na imagem da composição colorida normal é de um azul marinho escuro, mas que se confunde com um tom preto, induzindo o intérprete a imaginar que o nível de reflectância da água é zero. Na imagem por decorrelação a cor é realçada para um azul mais claro, mostrando de forma mais correta que a água não tem reflectância zero nos comprimentos de onda das três bandas.

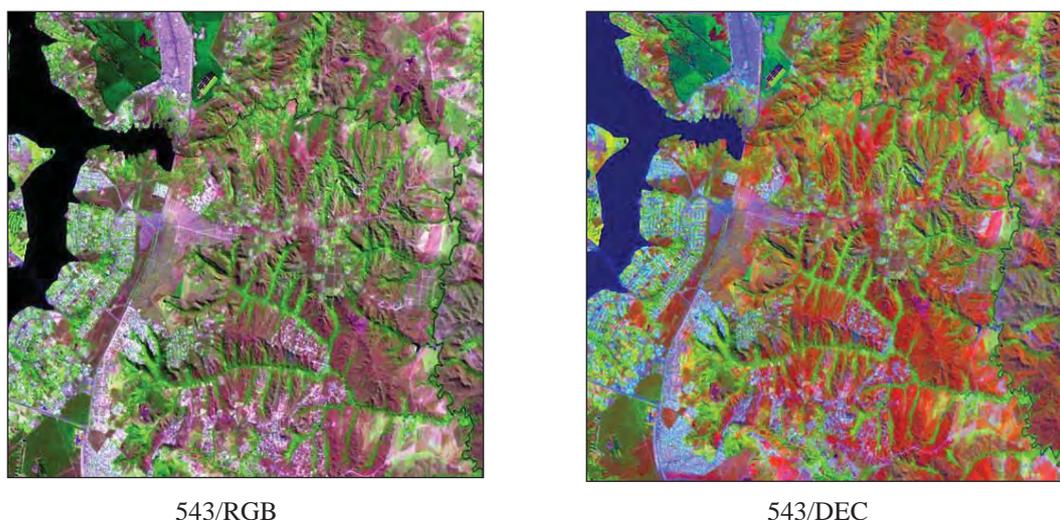


Fig. 10.11 Comparação do realce das cores de uma composição colorida com contraste linear, com a composição por decorrelação de bandas.

FILTRAGEM

Paulo Roberto Meneses
Antonio Nuno de Castro Santa Rosa



11

11.1 **Introdução**

Nos capítulos anteriores abordamos sobre as técnicas de processamento que visam realçar as imagens a partir de procedimentos que transformam os dados em função do valor individual de cada pixel, sendo por isso consideradas como técnicas de transformações radiométricas no domínio espectral da imagem. Outra alternativa de transformação é enfatizar ou reduzir as informações contidas numa imagem por meio de operações que envolvam os pixels de uma vizinhança, portanto, considerando um certo espaço geométrico da imagem. São as técnicas que atuam no domínio espacial da imagem.

Em qualquer imagem sempre é observado uma forte interdependência da vizinhança espacial dos valores dos pixels, porque os alvos na natureza tendem a mostrar uma homogeneidade dentro de certos espaços. Essa interdependência pode ser utilizada para realçar de forma seletiva detalhes geométricos da imagem, como as bruscas mudanças ou bordas entre áreas aparentemente homogêneas, que na realidade se configuram como limites. Mas também observamos nas imagens a presença de feições que marcam, por assim dizer, o rompimento desta interdependência, e que não parecem estar associadas a limites ou bordas de áreas, e que neste caso são identificadas como ruídos. As técnicas de processamento que atuam no sentido de realçar as bordas ou limites e de reduzir a presença dos ruídos, são denominadas de filtragens. Os filtros são os métodos de transformação da imagem no domínio espacial.

Transformar o valor de um pixel significa determinar um novo valor para o mesmo. Veremos neste capítulo as configurações de vários tipos de filtros no domínio do espaço ou do tempo, mas introduziremos também o conceito da filtragem no domínio da frequência, conhecida como Transformada de Fourier. A necessidade de se transformar o valor de um pixel de uma imagem é o fato de ter seu valor contaminado por diversos tipos de ruídos, ou seja, o valor do pixel é constituído de parcelas que chamamos de sinal e de ruído. O sinal é a parcela do valor do pixel que queremos determinar e realçar e o ruído a parcela que queremos minimizar, uma vez que o ruído não pode ser completamente eliminado do valor do pixel, pelo simples fato de desconhecermos seu percentual no valor do pixel.

Por ora vamos discutir a filtragem no domínio espacial, deixando para o final a discussão da filtragem no domínio da frequência, onde o operador, transformada de Fourier, usa o conteúdo do espaço global da imagem. A transformação no domínio do espaço se caracteriza por definir operações de filtragem a partir da informação local da imagem, dentro de um pequeno espaço em torno de um pixel.

Para filtrar uma imagem é importante conhecer a natureza do filtro que deve servir ao resultado que se deseja obter do processo de filtragem da imagem. A natureza de um filtro é determinada pela sua configuração que, de maneira geral, são classificados nos seguintes tipos:

Filtro passa-baixa: filtro que ressalta as estruturas maiores na imagem;

Filtro passa-alta: filtro que ressalta as estruturas de detalhe na imagem;
Filtro banda-passante: ressalta parte das maiores e menores estruturas da imagem.

A filtragem no domínio espacial é uma transformação que é realizada pixel a pixel, tal como é feito com as técnicas de transformações no domínio espectral (domínio da cor), com a diferença, como mencionado a pouco, de que a transformação do pixel é dependente dos valores de brilho dos pixels vizinhos e, portanto, da distribuição espacial local. Como brevemente comentado, essa dependência da vizinhança dos pixels é uma condição natural existente nas diferentes classes de alvos que podem ser identificadas numa imagem. Por exemplo, uma mata, um corpo de água ou uma parcela de solo agricultado compõem áreas que englobam muitos pixels em cada classe, e cada uma com valores de reflectância muito próximos, que somente mudam significativamente seus valores quando há a passagem para outra classe de alvo. Sob esse ponto de vista a imagem pode ser considerada como uma distribuição de padrões de valores de pixels que se repetem com uma determinada taxa. Essa taxa de repetição de pixels pode ocorrer em qualquer direção e representa as variações espaciais de brilho ou de níveis de cinza da imagem. Podemos ver isso na Figura 11.1 onde é mostrado o perfil de variação de brilho dos pixels medidos ao longo de uma linha na imagem, que atravessa áreas urbanas, lagos e reflorestamento. Note no perfil da figura à direita que há regiões com alta variação de brilho (áreas urbanas), e outras regiões, semelhantes como a marcada pela linha azul vertical, com baixa variação de brilho (lago e reflorestamento).

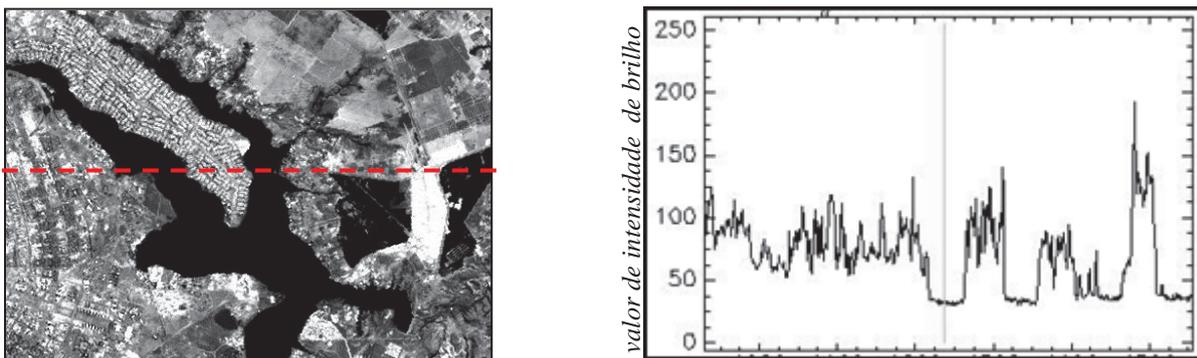


Fig. 11.1 À direita perfil mostrando a variação da intensidade de brilho ao longo de uma linha de pixels amostrada da imagem à esquerda (linha vermelha).

Esse conceito de variação espacial é aplicado aos métodos de filtragem espacial, que vê a imagem como sendo formada de componentes espaciais a diferentes escalas. Quando falamos em taxa de repetição de valores em uma imagem, estatisticamente estamos falando de moda, o que é bem entendido pela variação de brilho com mesma intensidade em locais espacialmente diferentes. Mas também, quando falamos em taxa, intuitivamente não deixamos de pensar em frequência. Por isso, taxa de variação espacial de brilho e frequência espacial são muitas vezes empregadas como sinônimos. Lillesand e Kiefer (1994) referem-se à "frequência" no domínio espacial como sendo a rugosidade das variações tonais que ocorrem em uma imagem. Áreas com alta frequência espacial são "tonalmente rugosas" e mostram as partes da imagem em que ocorrem rápidas mudanças dos valores de brilho, como se vê na Figura 11.1 das áreas urbanas. Elas expressam os detalhes da imagem numa escala local. As partes da imagem com baixa frequência espacial mostram pouca variação tonal na extensão de muitos pixels e, portanto, na escala de grandes áreas. Elas expressam, mais

apropriadamente, o comportamento espectral dos objetos. Nesse sentido, a filtragem espacial é uma técnica para realçar ou suavizar localmente parte destas repetições de padrão de brilho, principalmente, quando os padrões de variações de brilho são sutis. Quando o desejo é enfatizar as altas frequências de variações de brilho, o filtro espacial é genericamente chamado de passa-alta, e quando o desejo é enfatizar as baixas frequências o filtro espacial é chamado de passa-baixa. Considerando que qualquer imagem é composta de uma estrutura espacial aleatória de regiões com baixas e altas frequências espaciais, matematicamente, pode-se escrever esta relação como:

$$f(x, y) = PB(x, y) + PA(x, y)$$

eq. 11.1

onde, PB = passa-baixa
PA = passa-alta

A decomposição da imagem em uma soma de componentes de baixas e altas frequências de brilho é a base para a filtragem espacial. Para a maioria dos tipos de filtros se utiliza um operador de convolução discreta. Convolução é um operador matemático que vai operar dois elementos distintos, a imagem e o filtro. A operação de convolução discreta para filtrar a imagem, usa uma máscara móvel sobre a imagem, fixando pesos para a máscara, e tem a vantagem de ser um procedimento bastante rápido.

A função de processamento de convolução discreta entre a imagem de entrada e a máscara móvel do filtro pode ser escrita na forma:

$$g(i, j) = T[f(x, y)]$$

eq. 11.2

onde, $g(i, j)$ é a imagem processada, $f(x, y)$ é a imagem de entrada e T é um operador de transformação que atua sobre um conjunto de pixels vizinhos a (x, y) da imagem de entrada. Matematicamente, a equação 11.2 para a imagem $g(i, j)$ de saída (Schowengerdt, 1994) é:

$$g(i, j) = \sum_{m=0}^{N_x-1} \cdot \sum_{n=0}^{N_y-1} f_{mn} W_{i-m, j-n}$$

eq. 11.3

onde, f = a imagem de entrada
 w = função de resposta da janela, ambas com tamanho N_x, N_y

A maioria dos filtros é programada dentro de uma janela móvel. Dois procedimentos são realizados para filtrar a imagem:

- (i) Primeiro define-se uma máscara de arranjo de uma pequena matriz que contém coeficientes ou pesos. A matriz de pesos é denominada de kernel de convolução e, normalmente, se usa tamanhos com números ímpares de pixels, para que seja mantida uma simetria em relação ao pixel central.
- (ii) A máscara é movida sobre a imagem, linha por linha, coluna por coluna, e os valores dos pixels da área da imagem sob o filtro são multiplicados pelos correspondentes pesos dos pixels do filtro. A média da soma deste produto será o novo valor de brilho do pixel situado na posição central da área da imagem sob o filtro. Este valor é salvo e o processo continua.

O processo é repetido varrendo-se toda a imagem pixel a pixel como no esquema da Figura 11.2, e isso é um processo que opera a cada momento num espaço local da imagem. Quando o último pixel da imagem é processado a imagem original é modificada, radiometricamente, resultando em realces ou suavizações de feições de acordo com os valores dos pesos que foram estabelecidos. A flexibilidade de se usar praticamente qualquer peso na configuração de um filtro espacial faz da convolução um instrumento de processamento de imagem de muitas aplicabilidades.

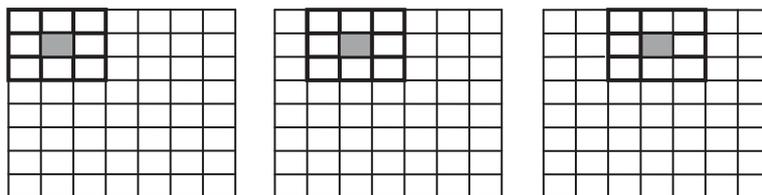


Fig. 11.2- Movimento da máscara de tamanho 3 x 3 para filtrar a imagem. O pixel cinza é o pixel central que terá o seu valor modificado conforme sejam os pesos dos pixels do filtro.

Os filtros mais utilizados que usam o processo de convolução, comumente se baseiam em três alternativas: na soma dos pesos, numa estatística específica, ou na noção de derivada. Há outras classes de filtros que transformam a imagem dentro dos mesmos conceitos de filtragem no domínio espacial, mas que não utilizam um operador de convolução. E, por fim, tem-se a filtragem no domínio da frequência. A filtragem é aplicada individualmente a cada banda original e é comum e útil aplicar um filtro em imagens que foram antecipadamente processadas por outras técnicas. A Tabela 11.1 lista as principais classes e tipos de filtros.

Tabela 11.1 Filtros de uso mais comum em sensoriamento remoto

Classe	Tipo	Aplicação
Domínio do Espaço (operador de convolução)	Passa alta	Realce da imagem
	Passa baixa de média de mediana	Supressão de ruído
	Direcional linear	Realce de bordas nas direções horizontal, vertical e diagonal
	Primeira derivada gradientes de: Roberts Sobel Prewit	Realce de bordas por operador não linear
	Laplaciano	Realce de bordas sem especificar direção
Domínio do Espaço (operador não convolução)	Morfológicos	Dilatação ou erosão da imagem
	Texturais	Realce das variações espaciais dos tons da imagem
	Adaptativos	Supressão de ruído com preservação do detalhe local
Domínio da Frequência	Fourier	Realce em relação à proporção da informação associada com as frequências

11.2 Filtro Passa-Alta

Os filtros passa-alta tendem a realçar os detalhes da imagem, o que implica em realçar os componentes de alta frequência espacial. Para isso, o filtro remove os componentes de baixa frequência de uma imagem enquanto retém os de alta frequência (variações locais). Isso pode realçar bordas entre diferentes áreas, como também aguçar as variações de brilho da imagem. Utiliza-se um kernel com alto valor central e com valores negativos circundantes. Filtros passa-alta somente podem ter dimensões ímpares (3 x 3, 5 x 5, e maiores). Quanto maior for o tamanho da janela ou da máscara mais se enfatizam as altas frequências espaciais, ou seja, os detalhes geométricos da imagem. Às vezes, filtros maiores que 100 x 100 pixels são usados para seletivamente eliminar alguns tipos de baixa frequência, como sombreamentos.

Na Figura 11.3 são mostrados duas máscaras de tamanhos 3 x 3 e 5 x 5. A soma dos pesos é igual a zero, o que remove a média local e produz uma imagem a qual mede o desvio do sinal de entrada em relação à média local. Quando a máscara é aplicada em regiões homogêneas de uma imagem o resultado será zero ou um valor digital muito baixo, enquanto que nas regiões não homogêneas o resultado é um realçamento, o que é consistente com o princípio da filtragem passa-alta. A aplicação de um filtro passa-alta com esses valores de peso pode resultar em números digitais negativos. Isso é automaticamente corrigido pelos algoritmos, que aplicam após a convolução uma normalização dos valores digitais para o intervalo de quantização da imagem.

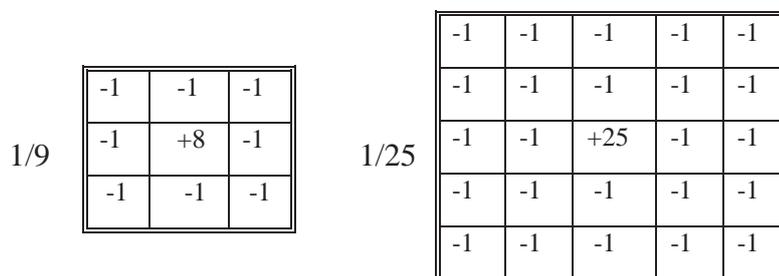


Fig. 11.3 Configuração de máscara de filtro passa-alta cujos pesos têm valores uniformes.

Na Figura 11.4 é mostrado o efeito do filtro passa-alta 3 x 3 em uma imagem do visível, com o objetivo de destacar o limite ou efeito de borda entre a área de vegetação de mata de galeria e o cerrado. Observe na grade de pixels da área indicada pela seta branca na imagem original, a transformação dos valores dos níveis de cinza que foi obtida com a filtragem na área limite das duas vegetações.

Entretanto, quando o objetivo é fazer uma interpretação visual temática da imagem, é desejável reforçar os componentes de alta frequência que representam os detalhes da imagem, sem eliminar totalmente os componentes de baixa frequência. Nesse caso, utiliza-se um filtro passa-alta multiplicado por um fator de amplificação, que é escrito na forma:

$$PA(x, y, K) = f(x, y) + K \times PA(X_{x,y})$$

eq. 11.4

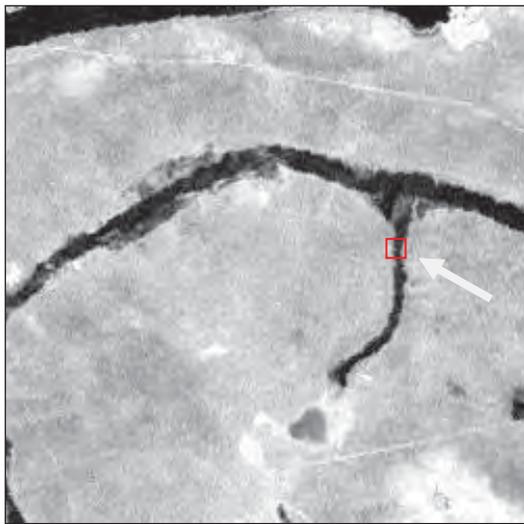


imagem original

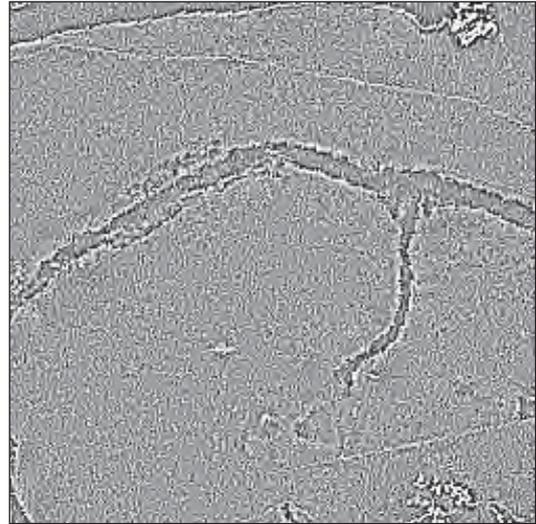
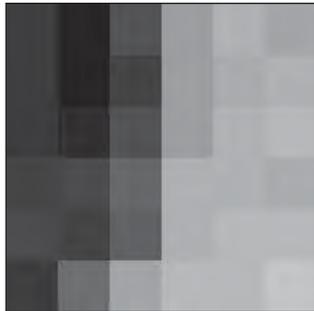
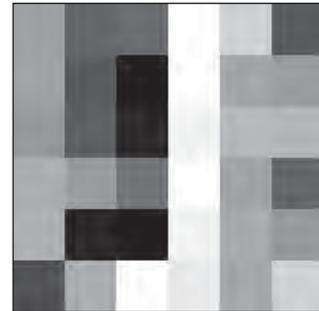


imagem filtrada



grade de pixel imagem original



grade pixel imagem filtrada

Fig. 11.4 Efeito de borda por um filtro passa-alta com dimensão de 3 x 3 em imagem do visível e o detalhe dos valores dos pixels da imagem original e da imagem filtrada da pequena área indicada pela seta branca na imagem à esquerda.

Exemplos desses filtros passa alta amplificados são mostrados na Tabela 11.2. A soma de seus pesos é igual a 1 o que significa que a imagem de saída tem a mesma média ND da imagem de entrada (preserva a baixa frequência), enquanto a quantidade de realce obtido é proporcional a K. A escolha do valor K depende do grau de realçamento que é desejado. No exemplo da Figura 11.5 foi aplicado um fator de amplificação K=2.

Tabela 11.2 Exemplos de filtro passa-alta amplificado, com diferentes valores de K.

K=1	K=2	K=3
$\frac{1}{9} \begin{vmatrix} -1 & -1 & -1 \\ -1 & +17 & -1 \\ -1 & -1 & -1 \end{vmatrix}$	$\frac{1}{9} \begin{vmatrix} -2 & -2 & -2 \\ -2 & +25 & -2 \\ -2 & -2 & -2 \end{vmatrix}$	$\frac{1}{9} \begin{vmatrix} -3 & -3 & -3 \\ -3 & +33 & -3 \\ -3 & -3 & -3 \end{vmatrix}$

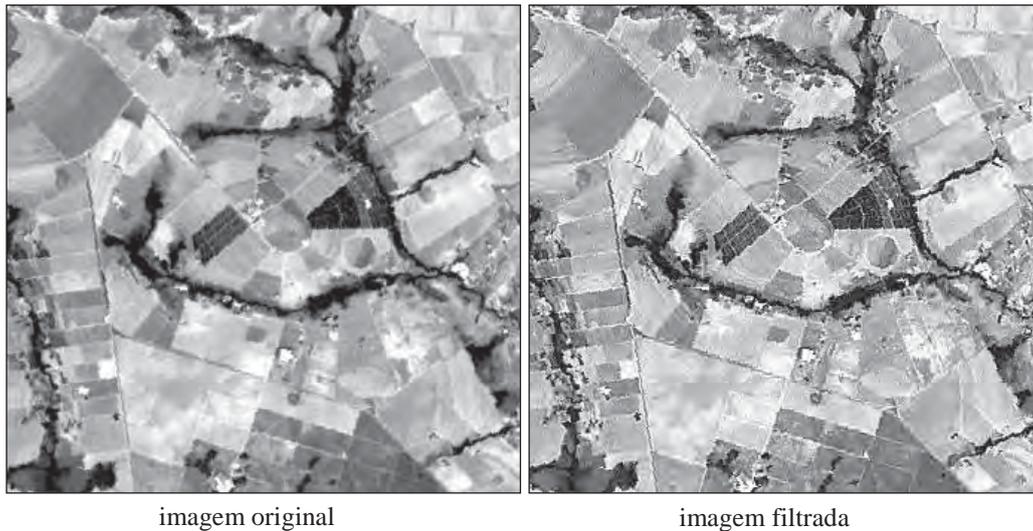


Fig. 11.5 Resultado da aplicação de um filtro passa-alta com fator de amplificação $K=2$ que realça os detalhes da imagem e preserva as baixas frequências, a fim de se ter uma imagem possível de interpretação visual temática.

11.3 Filtro Passa-Baixa

Os filtros passa-baixa preservam os componentes de baixa frequência da imagem à custa de reduzir os de alta frequência. São filtros de suavização porque atenuam as regiões de bordas e detalhes finos da imagem, como ruídos, que correspondem aos componentes de alta frequência. Dentre as técnicas mais conhecidas de suavização estão os filtros de média e da mediana.

11.3.1 Filtro Passa-Baixa de Média

Os filtros passa-baixa de média devem conter os mesmos pesos, com valores positivos 1 para cada elemento kernel. Multiplicando-se os pesos da máscara pelos pixels da imagem e dividindo o resultado pelo total do número dos pixels da máscara, o valor do pixel central da imagem é substituído pela média dos valores dos pixels vizinhos sob a janela. Por isso é um filtro de média. O efeito de se usar um filtro passa-baixa de média é reduzir a variabilidade dos níveis de cinza da imagem e suavizar o seu contraste. Os pixels de valores maiores que os seus vizinhos são reduzidos, de modo que os detalhes locais são perdidos. O produto é uma imagem de aparência um pouco desfocada. Matematicamente, o filtro passa-baixa de média é escrito na forma:

$$g(i,j) = \frac{1}{MN} \sum_{m=1}^M \sum_{n=1}^N f(m,n)$$

eq. 11.5

Pela razão dos filtros passa-baixa reduzirem as altas frequências de brilho de uma imagem, eles são usados para remover ruídos, e consequentemente, uniformizam os valores

de brilho da imagem. Isso porque, se geralmente os componentes de baixa frequência representam as características da reflectância dos objetos ou materiais, os ruídos aleatórios, por serem pixels com valores espúrios, representam as altas frequências. Nesse caso, os filtros passa-baixa têm como importante aplicabilidade ser um filtro para supressão de ruídos presentes na imagem. Em contrapartida é uma técnica que facilita a interpretação da imagem, quando o interesse do intérprete é identificar os padrões gerais dos níveis de cinza e não os seus detalhes, sem se incomodar com a perda de contraste de bordas.

Aumentando-se o tamanho da janela o filtro passa-baixa de média aumenta ainda mais o efeito de suavização da imagem, tornando-a com aparência mais desfocada. Como o tamanho do filtro está positivamente relacionado à suavização e à resolução espacial da imagem, filtros maiores do que 9 x 9 não são usados com frequência. As Figuras 11.6 e 11.7 mostram, respectivamente, exemplos de máscaras de filtro passa-baixa e o efeito de sua aplicação nas imagens. Observe que o resultado obtido é de uma imagem com aparência desfocada, porque os detalhes (altas frequências) são atenuados.

1/9	<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td></tr> </table>	+1	+1	+1	+1	+1	+1	+1	+1	+1
+1	+1	+1								
+1	+1	+1								
+1	+1	+1								

1/25	<table border="1" style="border-collapse: collapse; text-align: center;"> <tr><td>+1</td><td>+1</td><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td><td>+1</td><td>+1</td></tr> <tr><td>+1</td><td>+1</td><td>+1</td><td>+1</td><td>+1</td></tr> </table>	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1
+1	+1	+1	+1	+1																						
+1	+1	+1	+1	+1																						
+1	+1	+1	+1	+1																						
+1	+1	+1	+1	+1																						
+1	+1	+1	+1	+1																						

Fig. 11.6 Valores de pesos uniformes de filtro passa-baixa.

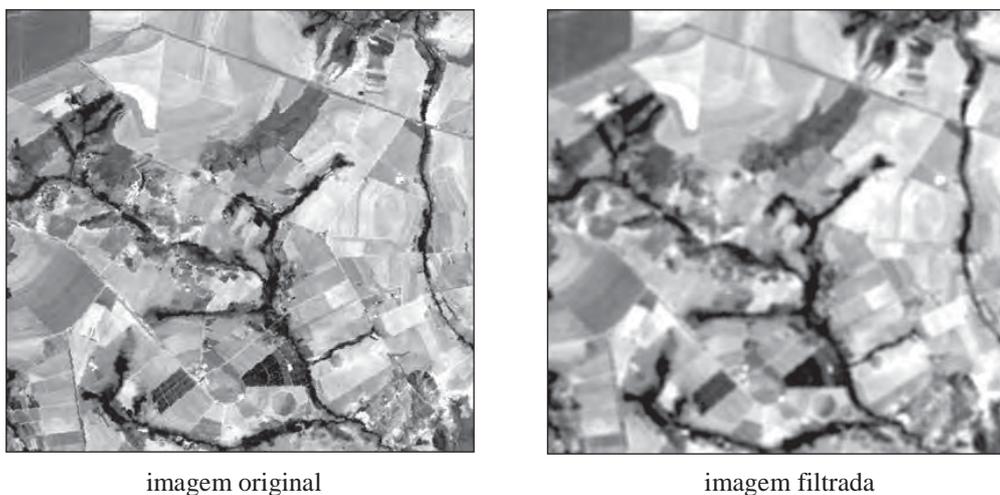


Fig. 11.7- Efeito de suavização da imagem por filtro passa-baixa de tamanho 5 x 5.

11.3.2 Filtro de Mediana

Uma alternativa para minimizar um pouco a aparência borrada da imagem pelo filtro da média é usar o filtro de mediana. O valor mediano de um conjunto de pixels na vizinhança do pixel central é de tal forma que metade dos valores é menor que a mediana e a outra metade é maior. Tomando-se como exemplo um conjunto de pixels na imagem de dimensão 3 x 3, com os valores [11, 9, 12, 32, 13, 14, 8, 10, 9], para encontrar o valor mediano deve-se

primeiro ranquear esses valores em ordem ascendente de magnitude. No exemplo, a ordem seria [8, 9, 9, 10, 11, 12, 13, 14, 32] com o valor mediano 11, que então substitui o valor do pixel central da imagem. A média é 13,11, arredondada para 13, é maior do que seis dos valores, indicando ter a influência do valor 32, o qual pode representar um pixel ruidoso na imagem. Este valor extremo é eliminado pelo filtro da mediana e as bordas são mais preservadas do que com o filtro de média. Há, assim, duas razões para a escolha da mediana e não da média. (i) a mediana do conjunto de pixels é sempre igual a um dos valores presentes no conjunto de pixels. (ii) a mediana é menos sensível a pixels de valores extremos. O filtro de mediana é bastante eficiente em imagens de radar para suprimir um tipo muito comum de ruído que estas imagens apresentam, chamado de *speckle* (ruído sal e pimenta). Um exemplo da aplicação do filtro da mediana é mostrado na Figura 11.8.

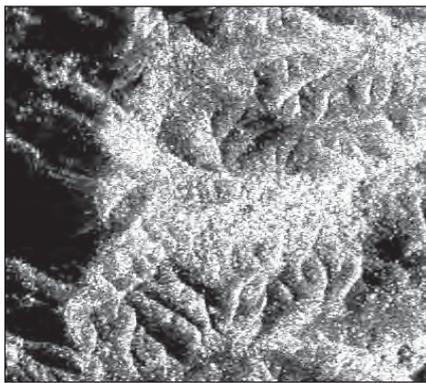


imagem original com ruído speckle

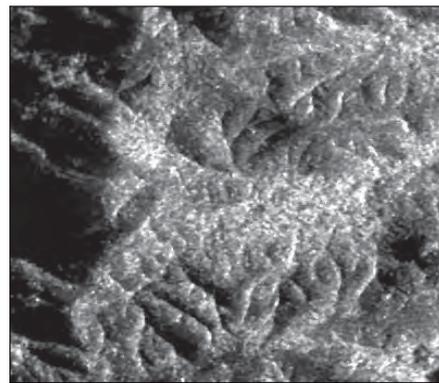


imagem com filtro de mediana

Fig. 11.8 Efeito de atenuação de ruído *speckle* em imagens de radar, com o uso de filtro de mediana.

11.4 Filtros de Bordas Direcionais

Além do simples realce dos componentes de altas e baixas frequências, um clássico problema em processamento de imagem é a detecção de repentinas mudanças nos valores de brilho de um pixel para outro, sem que isso seja um ruído. Esse tipo de mudança indica um limite, isto é, uma borda entre dois objetos espectralmente distintos. Uma borda é, simplesmente, uma fronteira entre duas regiões com relativa diferença de níveis de cinza. Numa imagem as bordas podem ter variadas direções, e a possibilidade de detectar essas direções e realçá-las na imagem pode ser algo muito desejado. Esse tipo de filtragem indica a direção preferencial em que será realçado os limites das bordas. Exemplos notáveis de bordas ocorrem em muitas das feições construídas pelo homem, e na geologia os lineamentos estruturais, que normalmente ocorrem em várias direções, são exemplos de feições naturais.

Há diversas configurações bastante simples de filtros direcionais que possibilitam realçar direções horizontal, vertical, diagonal ou isotrópica. Produzem imagens cujos valores digitais dos pixels são proporcionais às diferenças entre os números digitais de pixels vizinhos, em uma dada direção. As bordas que forem evidenciadas podem, ou ser adicionadas de volta à imagem original para aumentar o contraste nas vizinhanças da borda, ou usar pixels saturados pretos ou claros sobre elas, para realçá-las.

Os dois tipos de filtros de detecção de bordas mais utilizados são os filtros lineares de detecção de borda e os que calculam a primeira derivada espacial, os quais são apresentados a seguir.

11.4.1 Linear

É, tipicamente, uma forma de filtro passa-alta, combinado com uma limiarização de valores de brilho. Exemplos de máscaras dos filtros lineares de borda, sugeridos por Richard e Jia (2006), são apresentados na Tabela 11.3.

Tabela 11.4 Máscaras de filtros lineares de borda (Fonte: Richard e Jia, 2006)

<i>Vertical</i>	<i>Horizontal</i>	<i>Diagonal</i>	<i>Diagonal</i>
$\begin{vmatrix} -1 & 0 & +1 \\ -1 & 0 & +1 \\ -1 & 0 & +1 \end{vmatrix}$	$\begin{vmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ +1 & +1 & +1 \end{vmatrix}$	$\begin{vmatrix} 0 & +1 & +1 \\ -1 & 0 & +1 \\ -1 & -1 & 0 \end{vmatrix}$	$\begin{vmatrix} +1 & +1 & 0 \\ +1 & 0 & -1 \\ 0 & -1 & -1 \end{vmatrix}$

Note que a soma dos elementos kernel do filtro é zero. O resultado é que as áreas com valores de pixels homogêneos são zeradas na imagem de saída, enquanto as áreas com pixels de brilho variado são apresentadas como bordas brilhantes. O resultado da aplicação do filtro direcional linear na direção horizontal é mostrado na Figura 11.9, em uma área com forte presença de lineamentos geológicos. Visualmente, o efeito na imagem filtrada é um forte realce, destacando o relevo associado aos lineamentos na direção horizontal. Na imagem filtrada se vê que as áreas onde foram detectadas as direções horizontais, são mais claras, enquanto as áreas ausentes de direção horizontal mostram tons de cinza escuros. Isso pode ser considerado como uma forma muito prática de se identificar numa área os domínios estruturais existentes.

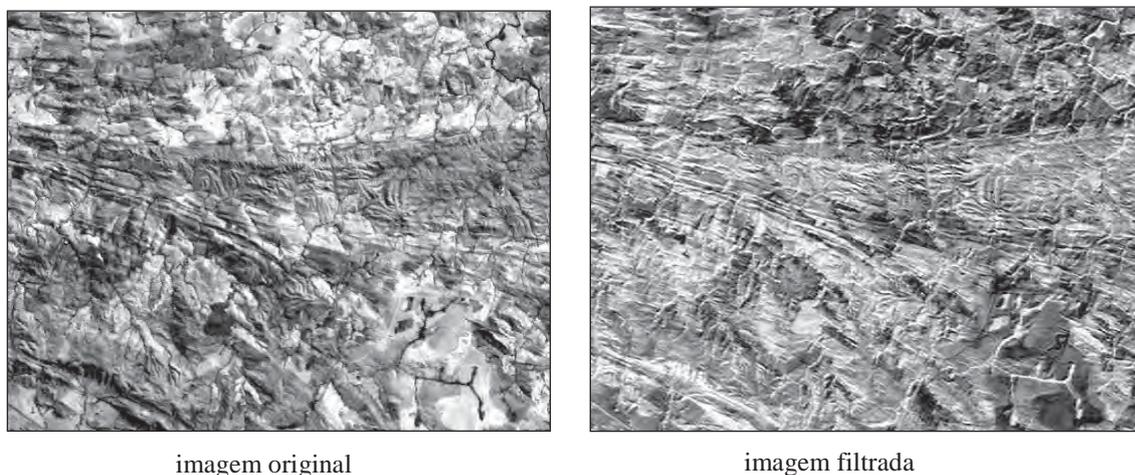


Fig. 11.9 Realce de lineamentos geológicos com o uso de filtro linear direcional, na direção horizontal.

11.4.2 Primeira Derivada

Os filtros de borda que usam o conceito matemático da primeira derivada também, seletivamente, realçam os componentes de direções específicas que a imagem possa ter,

calculando o gradiente direcional dos pixels. A derivada de uma função contínua é a taxa de mudança da função em um determinado ponto. Sendo a imagem uma função de valores de brilho, a taxa de mudança de brilho dos pixels num espaço é a primeira derivada. Para um pixel de coordenada x e y , as derivadas em x e y são as medidas de quão rapidamente os valores de brilho mudam na direção x e na direção y . Combinando os resultados por meio de um cálculo de vetor a cada pixel, a magnitude do gradiente local da imagem é obtida para qualquer direção, como demonstrado por Schowengerdt (1997) na Figura 11.10.

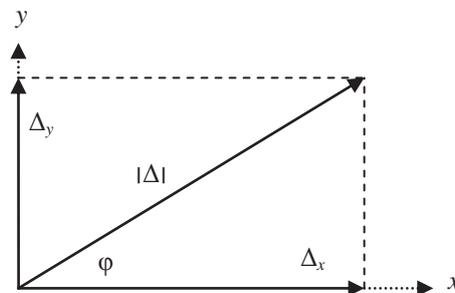


Fig.11.10- Geometria de vetor para cálculo da imagem gradiente (fonte: Schowengerdt, 2007).

Na Figura 11.10 a magnitude do gradiente local da imagem é dada pela dimensão do vetor $|\Delta|$, que é a derivada total (em relação a x e y) e que é calculada como a raiz quadrada da soma das duas derivadas individuais Δ_x e Δ_y . A direção do gradiente local é dada pelo ângulo φ entre o vetor e os eixos x e y . As respectivas equações são:

$$\Delta_1 = \frac{\partial}{\partial x} f(x, y); \quad \Delta_2 = \frac{\partial}{\partial y} f(x, y) \quad \text{eq. 11.6}$$

$$|\Delta| = \sqrt{\Delta_1^2 + \Delta_2^2} \quad \text{eq. 11.7}$$

$$\hat{\text{ângulo gradiente}} = \varphi = \tan^{-1} \frac{\Delta_y}{\Delta_x} \quad \text{eq. 11.8}$$

Todos esses valores são calculados para cada pixel da imagem. Nas áreas da imagem que são homogêneas as derivadas na direção x e y e a derivada total são pequenas, enquanto nas áreas em que ocorrem abruptas mudanças de brilho, as derivadas são altas. Neste sentido, a primeira derivada, ou gradiente da imagem, detecta as regiões de alta frequência da imagem.

Devido ao cálculo do vetor magnitude, os filtros de derivada são não lineares. Com base nessa formulação, as configurações de filtros de derivada se fazem pelo produto escalar da magnitude do vetor gradiente do pixel da imagem com os pesos particulares dos vetores. Os filtros mais utilizados são conhecidos como gradientes Roberts, Sobel e Prewit, os quais são mostrados na Tabela 11.4.

Tabela 11.4 Configurações dos filtros gradiente (fonte: Schowengerdt, 2007).

Filtro	Componente horizontal	Componente vertical
Roberts	$\begin{vmatrix} 0 & +1 \\ -1 & 0 \end{vmatrix}$	$\begin{vmatrix} +1 & 0 \\ 0 & -1 \end{vmatrix}$
Sobel	$\begin{vmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{vmatrix}$	$\begin{vmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{vmatrix}$
Prewitt	$\begin{vmatrix} +1 & +1 & +1 \\ +1 & -2 & +1 \\ -1 & -1 & -1 \end{vmatrix}$	$\begin{vmatrix} +1 & +1 & +1 \\ -1 & -2 & +1 \\ -1 & +1 & +1 \end{vmatrix}$

No filtro gradiente 2 x 2 de Roberts, por ter uma configuração quadrada, não há simetria do filtro em relação ao pixel central, e por isso o deslocamento da máscara é de ½ pixel. As máscaras 3 x 3 deslocam-se pixel a pixel, e a detecção de bordas é mais larga do que a produzida pelos filtros 2 x 2. Porque o processo de detecção de bordas direcionais computa um gradiente local, e porque as bordas detectadas são saturadas com valores de cinza (como uma binarização), é necessário a escolha de um valor de limiar, acima do qual as bordas são aceitas. Onde o gradiente excede o limiar, o valor do pixel é fixado a 255. A escolha de um limiar baixo implica em um grande número de bordas largas, enquanto um limiar alto resulta em segmentos de bordas finas. Em geral, os programas comerciais de processamento de imagens embutem um limiar pré-fixado, sem dar opção ao usuário para definir um novo limiar com base na sua experiência.

Ilustrações da aplicação de filtros gradientes são mostradas na Figura 11.11. Note que um grande número de bordas em todas as direções é detectado. A imagem filtrada está adicionada com um *background* de 30% da imagem original.

Os resultados das aplicações de filtros direcionais exemplificados nas figuras anteriores mostram que os filtros direcionais lineares são mais eficientes na detecção de lineamentos geológicos, enquanto os filtros de primeira derivada aplicam-se melhor nas áreas urbanas e agrícolas.

11.5 Operadores Laplaciano

São filtros que utilizam a segunda derivada para realçar bordas, sem considerar a direção. Comportam-se como um filtro passa-alta. Geralmente utilizam um alto valor central positivo na máscara, cercado por valores negativos nas direções vertical e horizontal.

O uso da segunda derivada para máximos e mínimos possibilita calcular que o valor é zero nas áreas onde o gradiente (primeira derivada) é constante, e valores positivos e negativos onde encontrar o topo e a base do declive nos valores de brilho da imagem.

A Figura 11.2 exhibe a máscara discreta de ordem 3 de um filtro Laplaciano e o resultado de sua aplicação. O somatório dos elementos da máscara é nulo. Todos os filtros laplacianos devem ter kernel de tamanho ímpar.

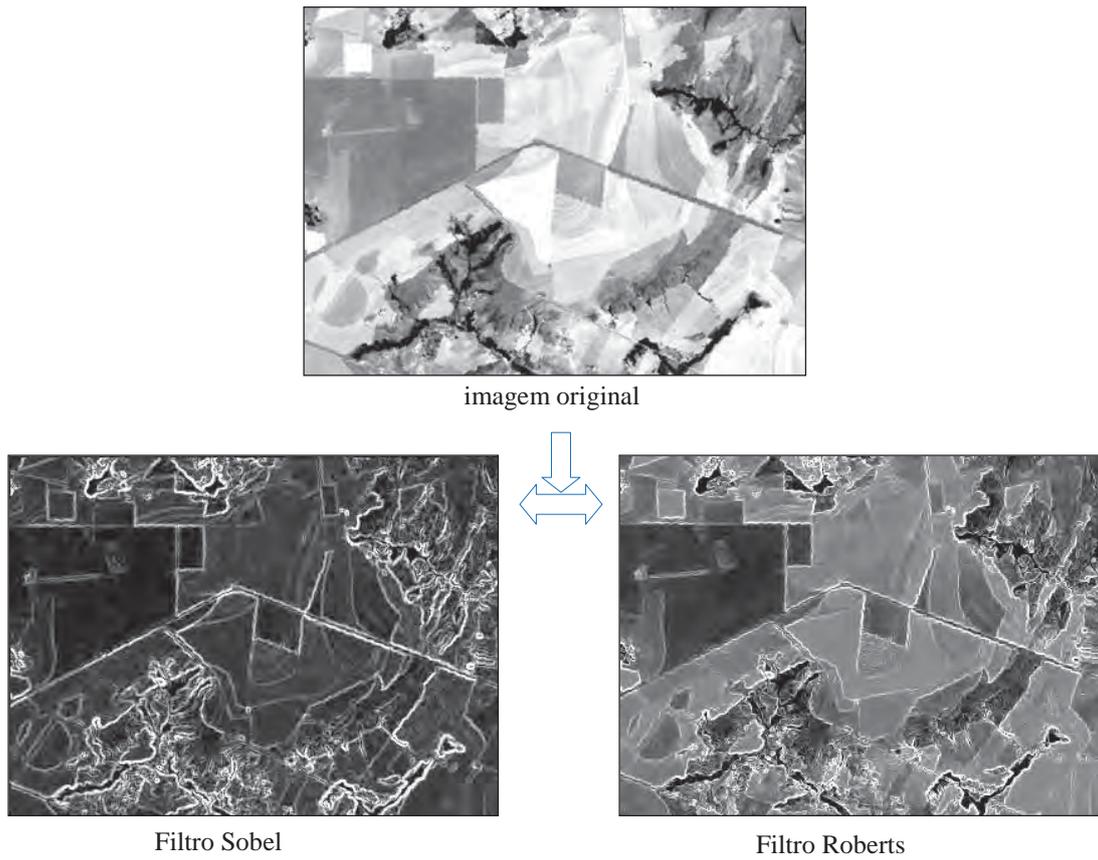


Fig. 11.11 Resultados da aplicação de filtros de gradientes (derivadas).

$$\begin{vmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{vmatrix}$$

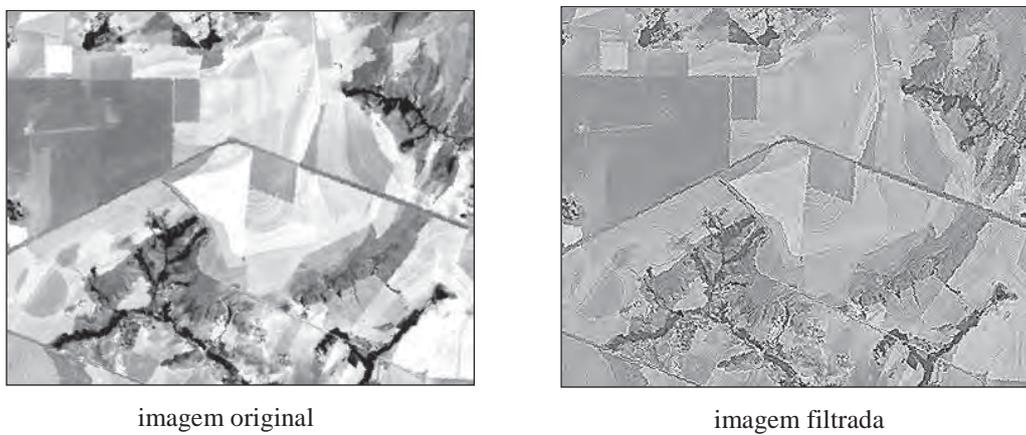


Fig. 11.12 Configuração da máscara do filtro Laplaciano e o resultado da imagem filtrada.

11.6 Filtros Morfológicos

Os filtros morfológicos atuam nas propriedades geométricas utilizando dois conceitos básicos: fechamento e abertura. Podemos combinar essas duas propriedades com as sequências: abertura seguida de fechamento, que se denomina dilatação e, fechamento seguido de abertura, que se denomina erosão. Esses filtros podem possuir algoritmos para imagens binárias e em tons de cinza. No processamento a forma da máscara é chamada de elemento estruturante, e a operação dos componentes kernel morfológicos sobre a imagem é completamente diferente da operação de convolução. As formas da máscara podem ser quadradas, retangulares, diagonais, ou qualquer forma desejada. A escolha da forma é importante porque dela depende a mudança induzida na imagem.

O filtro morfológico de erosão provoca efeitos de erosão (redução) das partes claras da imagem, gerando imagens mais escuras. O filtro morfológico de dilatação age de forma contrária, provoca efeitos de expansão das partes claras da imagem. Eles possuem aplicações na remoção do ruído e na segmentação da imagem para classificação. Alguns exemplos de kernel estruturantes são mostrados na Tabela 11.5. Os valores dos elementos estruturantes são sempre zero ou 1.

Tabela 11.5 Exemplos de máscaras de filtros morfológicos

0 1 0	1 0 1	0 0 0
1 1 1	0 1 0	1 1 1
0 1 0	1 0 1	0 0 0
0 1 0	1 0 0	0 0 1
0 1 0	0 1 0	0 1 0
0 1 0	0 0 1	1 0 0

As Figuras 11.13 e 11.14 ilustram os procedimentos para filtrar uma imagem com os filtros morfológicos (Leite, 2010). O procedimento apresentado utiliza a primeira forma de máscara da Tabela 11.5, e o mesmo procedimento se repete para qualquer uma das outras formas. Na dilatação (Figura 11.13), o filtro quando se move sobre a imagem realiza uma união de todos os pontos da imagem quando o elemento estruturante Bx intercepta X .

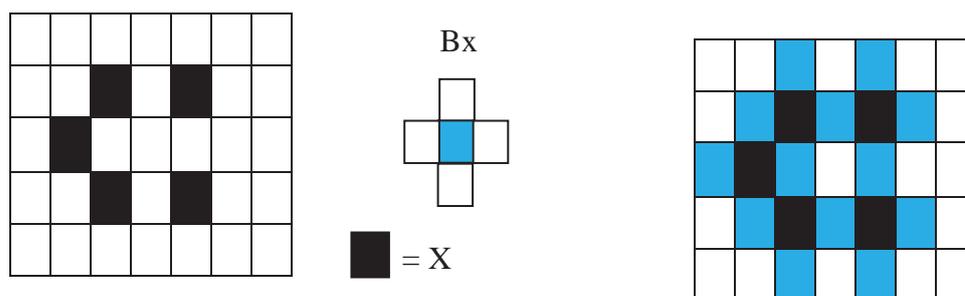


Fig. 11.13 Processo de filtragem da imagem X com o filtro dilatação.

Com o filtro erosão (Figura 11.14) o processo de erosão ocorre para o conjunto de X , quando Bx está totalmente incluído em X .

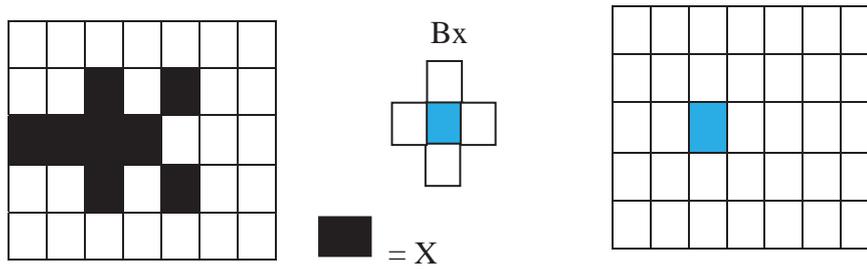


Fig. 11.14 Processo de filtragem da imagem X com o filtro erosão

Resultados da aplicação dos filtros morfológicos são mostrados na Figura 11.15.

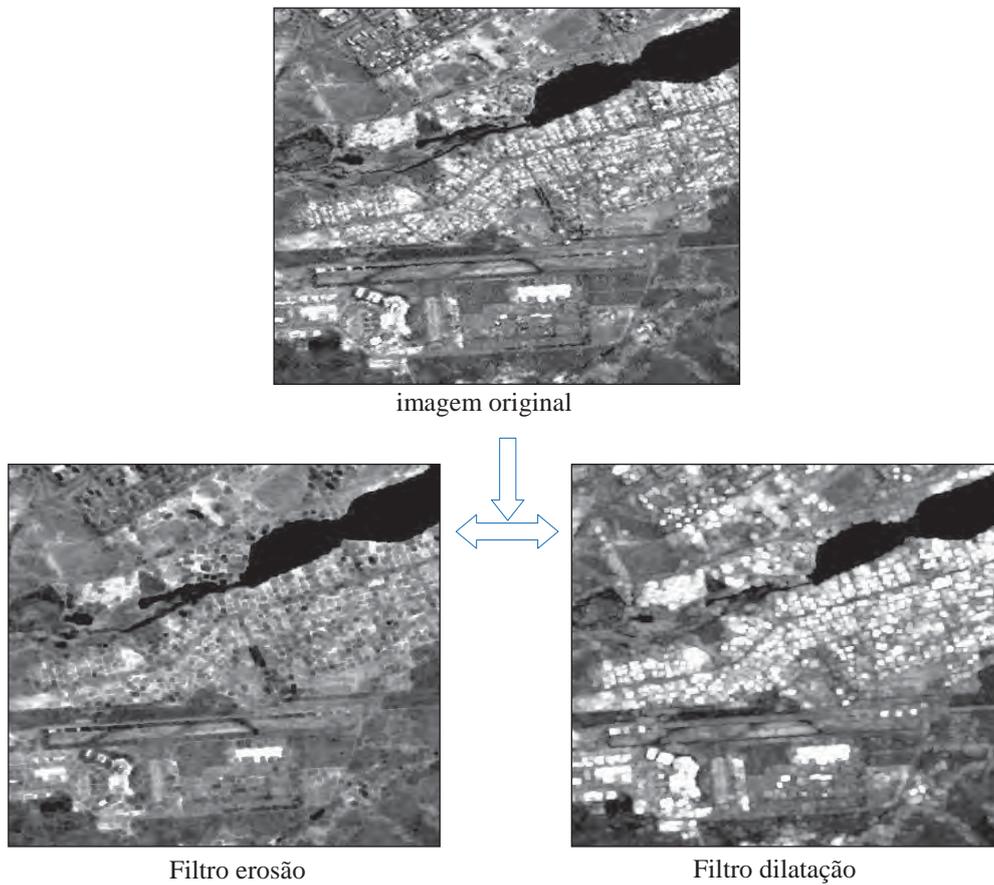


Fig. 11.15 Resultados da aplicação de filtros morfológicos de erosão e de dilatação.

11.7 Filtro de Textura

No contexto de imagens espectrais de sensoriamento remoto, textura é uma propriedade importante na percepção de regiões e de superfícies, contendo informações sobre

a distribuição espacial das variações de tonalidade dos objetos. Na imagem a textura se manifesta pela variação quase periódica de valores digitais (tons), que tem origem na reflectância dos objetos e sombras e sombreamentos devidos à topografia do relevo. O esforço é o de tentar reconhecer variações de padrões de formas por meio de uma análise das variações de padrões de tons de cinza. Não há uma definição geral para textura tonal e tal dificuldade é refletida pelo grande número de métodos de análise de texturas encontrados na literatura (Reed e Dubuf, 1993). Haralick *et al.* (1973), definiram textura a partir de medidas de uniformidade, densidade, aspereza, regularidade e intensidade, dentre outras características da imagem.

O uso da matriz de co-ocorrência está entre os métodos mais utilizados para análise de texturas. Matrizes de co-ocorrência de níveis de cinza são funções de distribuição de probabilidades conjuntas de ocorrência dos atributos de pares de pixels separados por uma determinada distância em uma direção fixa sobre uma imagem em tons de cinza (Sabino, 2004). Ou seja, a partir dessa matriz podem ser calculados vários parâmetros que representam a distribuição dos valores das probabilidades de co-ocorrência de pixels. É um método baseado na abordagem de propriedades estatísticas de dados espaciais, que há tempo é aplicado na exploração mineral, de recursos naturais e na medicina, de onde se originou, e que mais recentemente foi estendido para aplicações em imagens de sensoriamento remoto. A matriz de co-ocorrência contém uma grande quantidade de informação acerca da variação espacial da imagem, mas o maior problema é como extrair as informações que possam descrever as características texturais da imagem. Para isso, a abordagem estatística para a análise da textura utiliza um conjunto de medidas estatísticas locais para representar uma imagem texturizada. Essas medidas estatísticas de textura, extraídas da matriz de co-ocorrência, incluem a média, variância, homogeneidade, contraste, segundo momento, correlação, e outras. Cada uma dessas medidas é uma tentativa de se calcular feições texturais da imagem baseadas nas propriedades da matriz de co-ocorrência. Como método de filtragem no domínio do espaço, o seu princípio é o mesmo dos filtros apresentados, ou seja, ele descreve a imagem, ou uma região de interesse na imagem, em termos da relação entre os valores dos pixels com os valores dos pixels vizinhos. A diferença é que não se busca gerar uma imagem realçada para o analista visualizar a informação desejada. A textura é um método de processamento para ser usado no processamento de segmentação e classificação de imagens (Nascimento, *et al.* 2003, Schwarts & Pedrini, 2006).

Medidas de co-ocorrência usam uma matriz de dependência espacial de tons de cinza entre pixels vizinhos para calcular o valor da textura. É dessa forma uma matriz de frequência relativa cujos valores dos pixels ocorrem em duas janelas de processamento vizinhas, separadas por uma distância e uma direção específica (ENVI, 2006). Dita de outra maneira, a matriz de co-ocorrência contém uma tabulação da frequência relativa $P(i, j, h, \theta)$, considerando dois pixels vizinhos (pares) separados pela distância h na orientação θ , um pixel com tom de cinza i e o outro com tom de cinza j . O pixel i é chamado de pixel de referência e o pixel j de pixel vizinho. A escolha do pixel vizinho pode ser em qualquer direção θ : da linha, da coluna, ou das diagonais. A vizinhança pode ser de 1 pixel (h), 2, 3, ou qualquer valor. Haverá tantas matrizes de co-ocorrência quanto forem os valores de h e θ .

O exemplo mostrado na Figura 11.16 ilustra uma matriz de co-ocorrência produzida utilizando-se um deslocamento de valor $X = 1$ na direção $Y = 0$ (horizontal), para uma janela 3×3 . A tabulação mostra o número de ocorrências da relação entre o pixel e seus vizinhos especificados. Na primeira célula da matriz temos a informação de quantos pixels de valor 3 (três) têm como vizinho outro pixel de valor 3 na imagem de tons de cinza. Na segunda célula da primeira linha o valor corresponde a quantos pixels de valor 3 têm como vizinho um pixel com valor 4, e assim sucessivamente é calculado o número de pares de pixels de distância h entre os pares de pontos localizados em i e j .

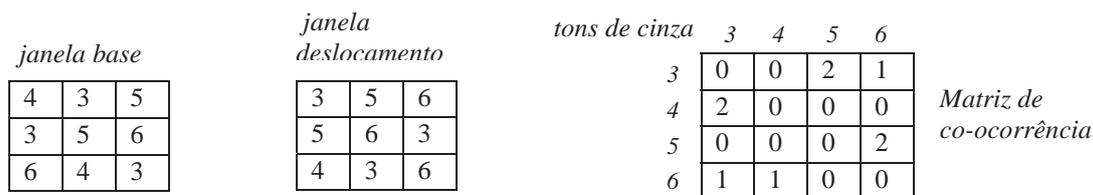


Fig. 11.16 Valores tabulados da matriz de co-ocorrência a partir dos valores dos pixels da janela base com a janela de deslocamento de distância igual a 1 na direção horizontal (Fonte: ENVI, 2006).

Para executar uma operação de filtragem textural deve-se primeiro escolher uma banda e selecionar a região de interesse. É, então, calculada a matriz de co-ocorrência da região selecionada, computando-se uma, ou simultaneamente, várias medidas estatísticas para serem usadas como medidas de textura (entropia, contraste, homogeneidade, média...). Os *software* de processamentos oferecem várias opções de medidas para caracterizar a textura da imagem.

Uma vez calculados os valores da matriz de co-ocorrência para as medidas estatísticas selecionadas, elas podem ser comparadas por valores numéricos representados em gráficos, para se verificar como cada medida distingue as texturas de diferentes classes de alvos. Um exemplo prático é mostrado na Figura 11.17, a partir de três segmentos de áreas extraídos de uma imagem na banda do visível e que se sabe possuem padrões texturais distintos. Os valores estatísticos são mostrados para contraste e dissimilaridade, apenas para ilustrar o processo.

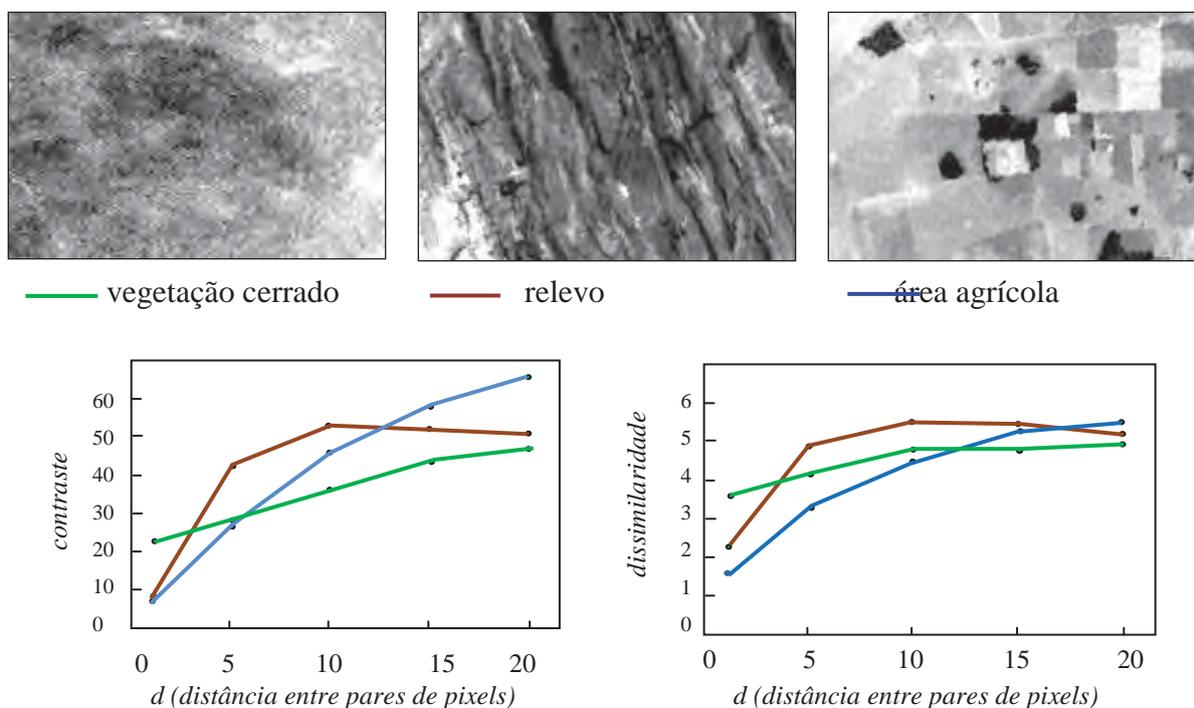


Fig. 11.17 Valores das feições texturais de contraste e dissimilaridade obtidos da matriz de co-ocorrência para as classes de vegetação, relevo e áreas de cultivo, dos segmentos de imagens mostrados acima dos gráficos.

11.8 Filtragem no Domínio da Frequência

Nas seções anteriores vimos que no domínio do espaço uma imagem pode ser decomposta em seus componentes de alta e baixa frequência. Acontece que uma imagem não é só composta de altas e baixas frequências. Se plotarmos em um gráfico as variações das frequências de brilhos que uma imagem pode conter, obteremos uma curva complexa do tipo mostrado na Figura 11.18. Essa curva complexa (não periódica) pode ser decomposta em vários componentes de seno e cosseno, que nos dá uma idéia da distribuição espacial de frequência da imagem (Crósta, 1999). Para decompor a imagem em seus componentes de seno e cosseno, como visto nesta figura, usa-se a Transformada de Fourier. No domínio de Fourier cada ponto da imagem representa uma frequência única que está contida no domínio espacial da imagem.



Fig. 11.18 Decomposição das frequências da imagem em seus componentes senos e cossenos (Adaptado de Crósta, 1999).

A Transformada de Fourier é outra opção para filtrar a imagem, mas seu uso estende-se às várias aplicações para reconstrução e compressão de imagens, tomografia e detecção de vozes. Matematicamente, seu entendimento é bem mais complexo do que filtrar uma imagem no domínio do espaço, mas a transformada Fourier torna mais fácil processar ou examinar certas frequências que influenciam na estrutura geométrica da imagem. Como exemplo, a presença de ruídos periódicos que frequentemente são encontrados em quase todos os tipos de imagens de sensoriamento multispectral (Penteado, *et al.* 1998).

Para o processamento de imagem digital, a qual é uma função bidimensional discreta, se utiliza da Transformada de Fourier Discreta, que é uma versão da transformada Fourier. A transformada discreta não contém todas as frequências da imagem, mas apenas um conjunto de frequência que é suficiente para descrever o domínio espacial da imagem, completamente.

Como está demonstrado na Figura 11.19, o processo de filtragem no domínio da frequência é um processo de dois passos. Primeiro, para que os dados do domínio espacial sejam analisados no domínio da frequência necessitamos utilizar a Transformada de Fourier

direta. Segundo, a Transformada de Fourier inversa é usada no sentido contrário, ou seja, de volta ao espaço original da imagem (frequência no tempo).

O valor de brilho médio da imagem, isto é, o componente de frequência zero, é mostrado no centro da imagem transformada. Os pixels distantes do centro representam crescentes componentes de frequência espacial da imagem. Diversas opções de filtro podem ser utilizadas para remover um componente particular de frequência da imagem.

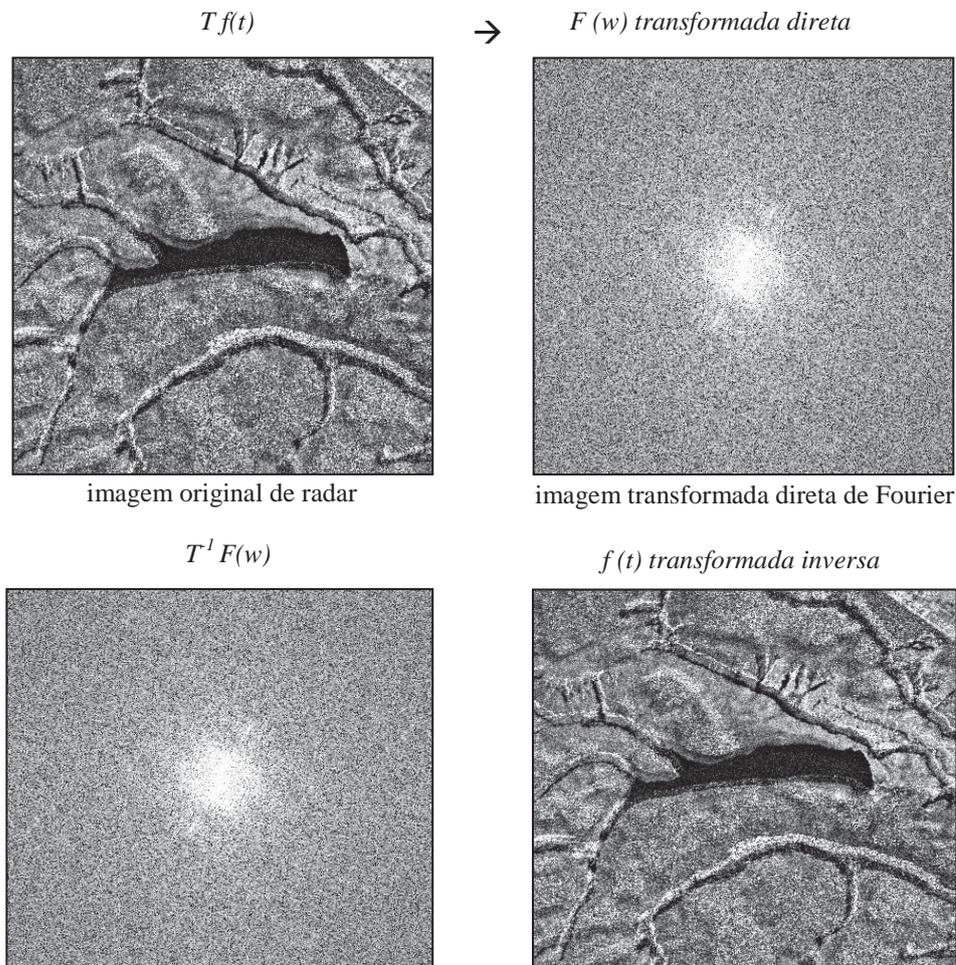


Fig. 11.19 As imagens ilustram o processo de filtragem da imagem no domínio da frequência pela transformada de Fourier e o resultado final da imagem filtrada.

11.8.1 Amostragem

Existe uma relação que descreve o compromisso entre o domínio do espaço (tempo) e o domínio da frequência, que é chamada relação de Nyquist (equação 11.9). Essa relação deve ser respeitada em função de ocorrerem efeitos denominados de *aliasing*.

$$d_t < 1/2 f$$

Eq. 11.9

onde, d_t é o intervalo de amostragem no tempo e f é uma frequência no intervalo de amostragem na frequência.

Esse limite de amostragem permite que a relação de tempo e espaço possa ser realizada sem perda de informação do sinal original. Vamos realizar um exemplo com a imagem original que estamos utilizando de tamanho de 400 x 400 pixels amostrados para 1200 x 1200 pixels. Calculando a Transformada de Fourier das duas imagens temos os resultados na Figura 11.20.

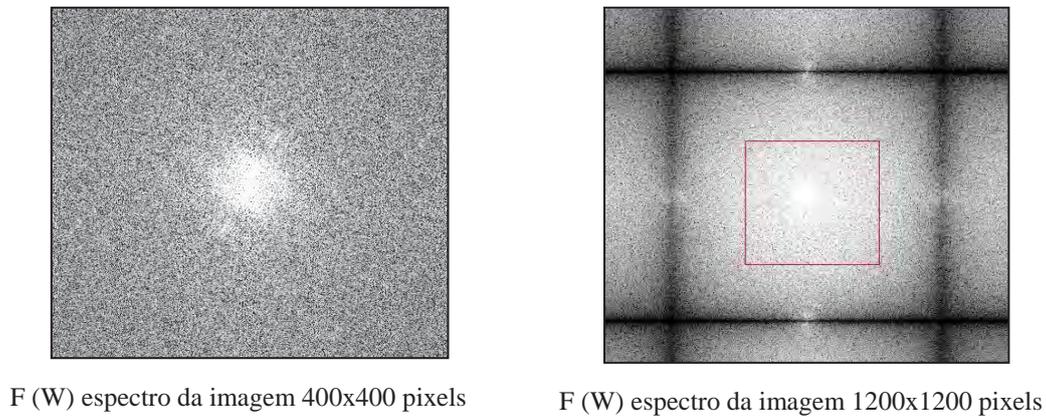


Fig. 11.20 Espectros da transformada direta de Fourier da imagem amostrada de 400 pixels para 1200 pixels.

A relação entre as operações nos dois domínios, tempo e frequência, isto é, a convolução no domínio do tempo corresponde à multiplicação no domínio da frequência.

$$\begin{matrix} f(t) \times h(t) \\ F(W) \times H(W) \end{matrix}$$

eq.11.10

onde, $F(W)$ é espectro do sinal e $H(W)$ corresponde ao espectro do filtro.

Alguns tipos de filtros são definidos:

Filtro Passa-Alta Circular. Corta as frequências externas ao círculo (região cinza) e deixa passar as frequência internas ao círculo (região clara). Pode-se concluir que a região clara da Transformada de Fourier está associada às altas frequências e a região cinza às baixas frequências. É necessário que o analista defina alguns parâmetros, tais como o raio em pixel do círculo. Utiliza-se esse tipo de filtro para obter as feições de detalhe na imagem (passa-alta), como mostra a Figura 11.21.

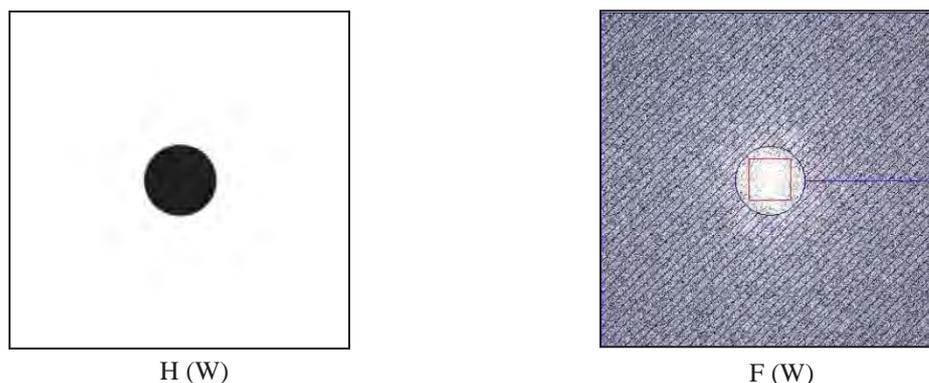




imagem original

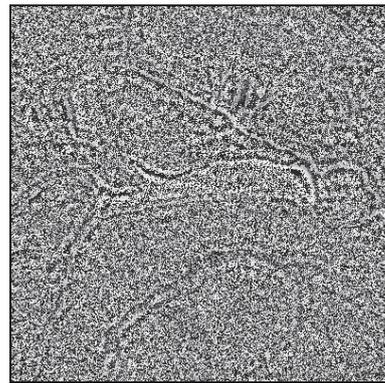


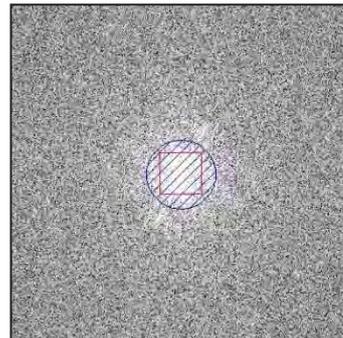
imagem filtrada

Fig. 11.21 Transformada Fourier Discreta com uso do filtro passa-alta circular.

Filtro Passa-Baixa Circular. Corta as frequências internas ao círculo (região clara) e deixa passar as frequências externas ao círculo (região cinza). Nesse caso, utiliza-se esse filtro para obter as feições de regionais na imagem (passa-baixa) (Figura 11.22).



H (W)



F (W)

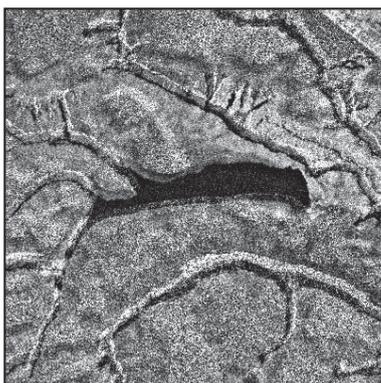


imagem original



imagem filtrada

Fig. 11.22 Transformada Fourier Discreta com uso do filtro passa-baixa circular.

Filtro Banda-Passante Circular Interno. Corta as frequências internas ao círculo menor e externas ao círculo maior (região com traços azuis) e deixa passar as frequências internas ao círculo maior e externa ao menor (região clara). Pode-se concluir que o filtro banda-passante

deixa passar as frequências na região entre os círculos e corta as demais frequências. Utiliza-se esse filtro para obter as feições de detalhes limitados (Figura 11.23).

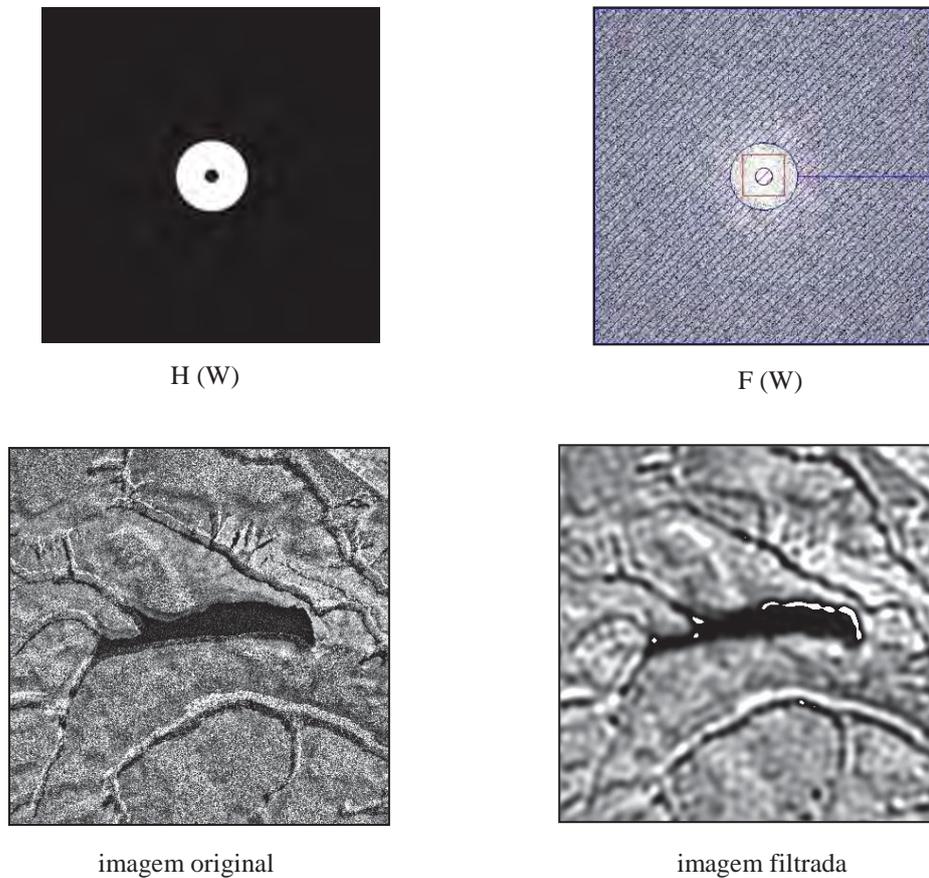
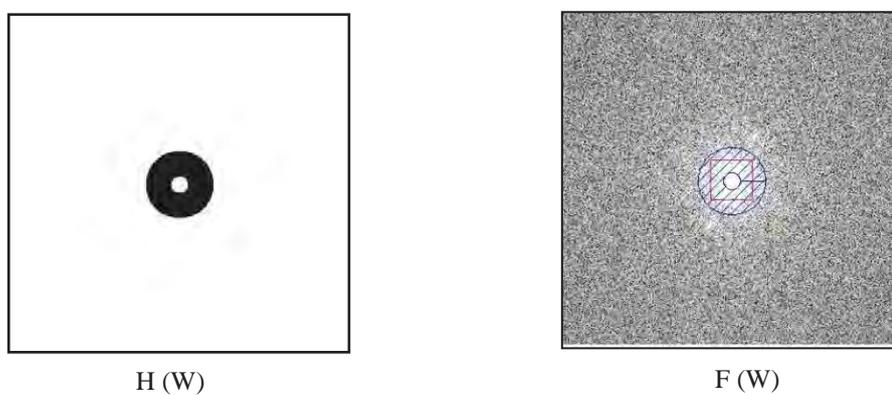


Fig. 11.23 Transformada Fourier Discreta com uso do filtro banda-passante circular interno.

Filtro Banda-Passante Circular Externo. Corta as frequências entre os dois círculos (região com traços azuis) e deixa passar as demais frequências. Pode-se concluir que as frequências entre os círculos são de frequências baixas e muito altas. Quando utilizamos esse filtro é para obtermos as feições de maiores detalhes e regionais (Figura 11.24).



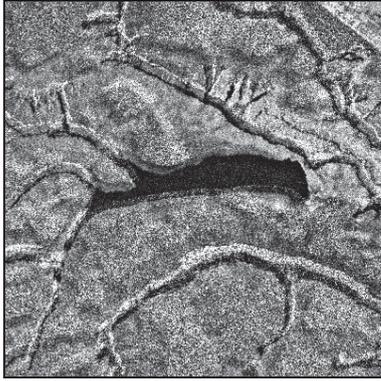


imagem original

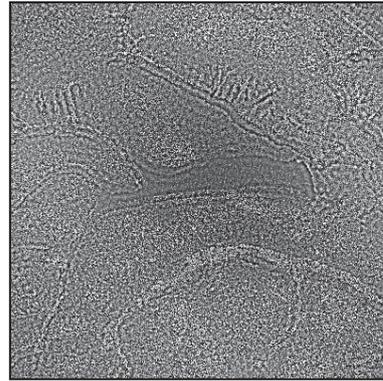


imagem filtrada

Fig. 11.24 Transformada Fourier Discreta com uso do filtro banda-passante circular externo.

Paulo Roberto Meneses
Edson Eyji Sano

12.1 Introdução

O sensoriamento remoto tem como um dos seus principais objetivos a extração das informações contidas nas imagens e a sua codificação em documentos que possam ser lidos nas formas de tabelas, gráficos ou mapas. Para extrair informações das imagens é necessário estabelecer métodos de análises com regras claras e lógicas, para que possam ser replicadas por qualquer analista na interpretação do significado do dado. Essas regras estabelecem critérios para a análise dos elementos que compõem a paisagem, utilizando-se das propriedades da cor, tonalidade, textura, estrutura, sombras e homologia, que são específicas de cada classe de alvo. Isso é o que dispõem os métodos de interpretação, herdados da experiência com a fotointerpretação. Precede a essa etapa, que os fotointérpretes denominam de fotoanálise, o domínio do conhecimento que o analista deve ter sobre todas as características técnicas dos sistemas sensores de aquisição das imagens, sem o qual a fotoanálise não se realiza. A personalidade é outro fator que interfere no processo de extração da informação e no resultado. Um indivíduo que tem obediência às regras do método chegará a um resultado, como um mapa temático, que será mais detalhado do que é capaz um indivíduo que tende a ser mais generalista. E então, os resultados se mostrarão diferentes. Por outro lado, o número de bandas que deve ser analisado, a extensão muitas vezes grande da área de estudo, ou quando há a análise de várias imagens multitemporais, tornam bastante demorado o trabalho de interpretação. Foi daí que surgiram as técnicas de classificação digital de imagens, que automatizam o processo de extração de informações das imagens eliminando a subjetividade da interpretação humana e reduzindo o esforço de trabalho do analista. O resultado final da classificação é uma imagem digital que constitui em um mapa de pixels classificados, representando em polígonos os padrões homogêneos de classes de alvos (mapa digital temático).

Os diversos métodos de classificação em uso podem ser divididos segundo diferentes critérios: classificação paramétrica e não-paramétrica, classificação espectral e espacial, e classificação supervisionada ou não-supervisionada. Há ainda a possibilidade de dividir os classificadores em classificação por pixel ou por regiões. A maioria dos classificadores executa a classificação por pixel, que se utiliza somente da informação espectral de cada pixel para encontrar regiões homogêneas, a partir de medidas de distâncias ou de probabilidades de um pixel pertencer a uma classe específica. Na classificação por regiões o processo de decisão leva em consideração um agrupamento de pixels que é usado como unidade de classificação. Com isso se procura simular o comportamento de um fotointérprete, ao reconhecer áreas homogêneas nas imagens baseadas nas propriedades espectrais e espaciais dos objetos (Kury & Vieira, 2001).

A forma mais comum e difundida entre os usuários de sensoriamento remoto e que foi adotada pelos *software* comerciais de processamento de imagens, separa os classificadores em supervisionados e não-supervisionados. Seguiremos essa forma neste capítulo.

Classificação de imagens multiespectrais é o processo de associar os pixels da imagem a um número finito de classes individuais que representam os objetos do mundo real,

com base nos seus valores digitais. Se um pixel satisfaz um determinado conjunto de critérios, normalmente avaliados por medidas estatísticas, o pixel é atribuído à classe que melhor satisfaz os critérios estabelecidos. Por exemplo, se os valores digitais de um pixel nas bandas dos intervalos de comprimento de onda do visível azul, verde e vermelho, do infravermelho próximo e do infravermelho de ondas curtas são, respectivamente, {15, 25, 14, 115, 23}, eles poderiam ser rotulados à classe de vegetação, porque esses valores digitais são condizentes com o padrão de comportamento de refletância da vegetação. Então, o usuário deve esperar por procedimentos automáticos de processamentos que possam mapear nas imagens todos os pixels que possuam esses mesmos valores ou valores próximos, resultando em um mapa digital automático de vegetação. O resultado final de um processo de classificação é uma imagem digital que constitui um mapa de "pixels" classificados, representados por símbolos, gráficos ou cores. Esse é o processo conhecido como classificação de imagens. A imagem classificada é, assim, uma forma de um mapa digital temático. Está implícito que somente as classes que são espectralmente distinguíveis na imagem estarão presentes no mapa digital temático obtido por meio da classificação da imagem. É importante ressaltar que quem faz a delimitação dos diferentes polígonos de cada classe na imagem é o algoritmo de classificação digital, mas quem constrói a legenda do mapa temático continua sendo o analista. Aos valores de pixels que identificam uma classe específica de alvo ou objeto real da natureza, denomina-se de padrões. Portanto, a classificação automática de imagens é nada mais do que um reconhecimento de padrões.

Reconhecimento de padrões é a ciência de encontrar padrões significativos nos dados da imagem que possam ser extraídos por operadores automatizados. O reconhecimento de padrões é realizado pelo cérebro humano que rotula certas texturas e cores em classes de alvos ou objetos. Esse é um processo realizado por treinamento neuro-cerebral desenvolvido ao longo da experiência de vida. Em um computador, o reconhecimento de padrões em imagens pode ser feito de modo mais científico. Medições estatísticas são derivadas a partir das características espectrais dos pixels em uma imagem, a fim de que todos os pixels sejam destinados às suas mais prováveis classes, usando uma regra de decisão.

Mather (1987) resumiu em dois modos o problema de alocar pixels individuais às suas classes mais prováveis. Se previamente sabemos que numa área existe um número de diferentes tipos de alvos, e que nas imagens são padrões espectralmente separáveis, pode-se estimar propriedades estatísticas que descrevem e medem cada um desses padrões, e então, cada pixel da imagem pode ser comparado a cada um dos padrões e ser rotulado como pertencente ao padrão que mais similaridade encontrar. O outro modo é não se ter conhecimento dos tipos de alvos (padrões) que possam estar presentes na imagem. Nesse caso, são definidos arbitrariamente alguns padrões básicos e o método usado é alocar e realocar os pixels da imagem a esses padrões. Ao final de cada tentativa, quando todos os pixels tiverem sido alocados, os padrões definidos podem ser alterados, de acordo com a natureza dos pixels que lhe foram associados e, se necessário, alguns desses padrões básicos podem ser descartados ou mesmo divididos. Dá-se, respectivamente, a esses dois modos de alocar pixels as suas classes mais prováveis, o nome de classificação supervisionada e classificação não-supervisionada.

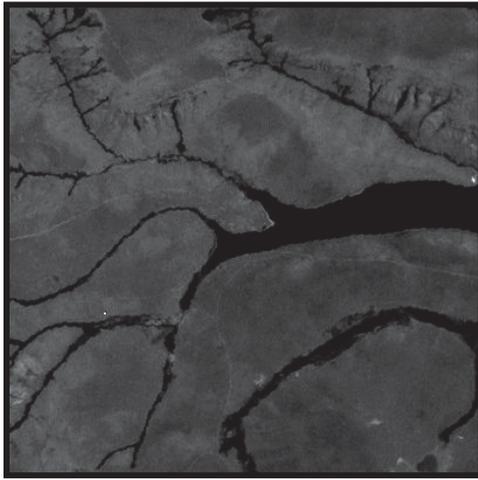
Aparentemente, o processo de classificar os alvos presentes na imagem é uma questão simples. Mas há uma série de fatores que podem interferir nessa tarefa. Por exemplo, muitos dos alvos na natureza podem não ser espectralmente distintos nas bandas existentes num sensor, a atmosfera pode reduzir os contrastes espectrais ou mesmo impedir a obtenção de imagens em comprimentos de onda que sofrem fortes absorções, a topografia interfere na refletância, além de adicionar sombras, ruídos frequentemente estão presentes na imagem, e a resolução espacial torna os pixels uma mistura de alvos. Alguns desses efeitos podem ser modelados pelos algoritmos, mas nem sempre é possível modelá-los completamente. Mesmo

que fosse possível um modelamento completo, a maioria dos algoritmos de classificação se baseia nos valores digitais dos pixels, o que sabemos não ser suficiente para se ter uma perfeita classificação. Quando o analista interpreta uma imagem, ele é capaz de separar uma classe de vegetação vigorosa de mata de galeria, de uma vegetação também vigorosa de um reflorestamento, mesmo que espectralmente ambas sejam muito similares. Elas serão confundidas por um classificador, mas o analista utiliza-se de propriedades da textura, forma e estrutura para diferenciá-las. Modelar textura e estrutura é um desafio ainda não satisfatoriamente conseguido pelos classificadores. A classificação de imagens deve, portanto, ser vista como um processo estatístico e probabilístico que tenta ao máximo aproximar o mapa digital à realidade. O resultado da classificação deve ser avaliado com base no desempenho do classificador proposto e validado por critérios numéricos para estimar a precisão e a sua acuracidade. Sobre esse assunto, uma discussão é feita no final deste capítulo.

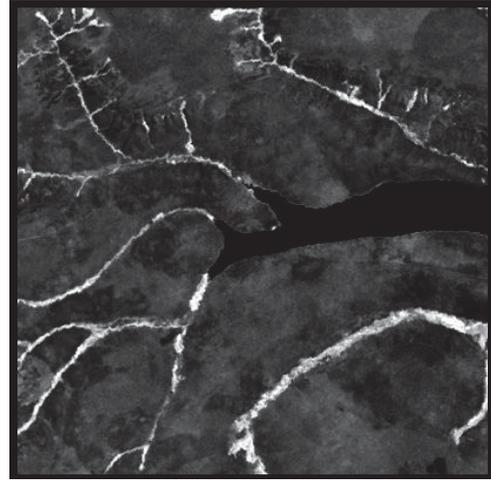
12.2 Princípio básico de classificação de imagens

Um modo simples de demonstrar como os pixels podem ser alocados às classes pode ser feito plotando os valores digitais dos pixels num gráfico em que os dois eixos representem duas bandas. Chamamos esse gráfico de dispersograma. Vamos considerar uma banda na região da luz vermelha visível e a outra banda no infravermelho próximo, e duas classes de alvos existentes nestas imagens – vegetação e água. Se simplificarmos que os algoritmos de classificação alocam os pixels às classes em função de seus valores digitais, e sabendo que os valores dos pixels são respostas da reflectância da luz, facilmente podemos imaginar as posições dos grupos de pixels (*clusters*) relacionadas às duas classes de alvos no dispersograma. Para isso, é simplesmente suficiente que conheçamos o comportamento espectral de reflectância dos respectivos alvos, traduzidos em valores digitais na imagem. Esse exemplo é demonstrado na Figura 12.1 considerando-se os alvos vegetação e água limpa. Na banda do vermelho sabemos que a vegetação tem uma forte absorção da radiação eletromagnética, a ela associando-se, portanto, valores digitais baixos. Ao contrário, uma alta reflectância ocorre na banda do infravermelho próximo, e a ela se associam pixels com altos valores digitais. Para a água limpa o comportamento espectral indica que valores digitais muito baixos serão encontrados para ambas as bandas. Com base nisso podemos, por nossa decisão, definir no dispersograma o espaço de agrupamento dos pixels de cada uma das duas classes. O algoritmo levaria a vantagem de definir, numericamente, o valor dos centros dos agrupamentos que identificam as duas classes de alvos na imagem, e reconheceria na imagem os pixels englobados por cada um desses agrupamentos, classificando-os e assim compondo um mapa digital temático das áreas de vegetação e de água.

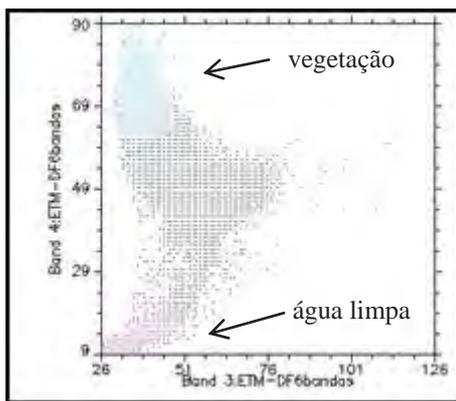
Esse exemplo demonstra uma idéia fundamental: a de que os agrupamentos são definidos por uma regra de decisão. No exemplo exposto, a regra definida foi que os pixels da imagem para serem associados à classe vegetação têm de ter valores digitais baixos na banda do vermelho e valores digitais altos na banda do infravermelho. Para pertencerem ao agrupamento água terão que ter valores digitais baixos em ambas as bandas. É dessa forma uma regra baseada somente no valor do dado espectral. Um algoritmo de classificação realiza automaticamente essa operação, com a vantagem de trabalhar num espaço n dimensional, o qual seria impossível para nós representá-lo graficamente.



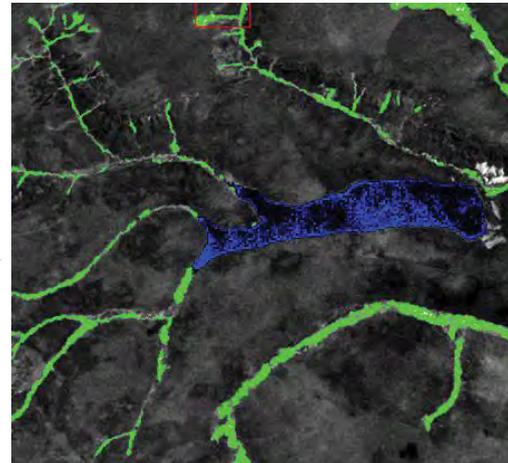
Banda 3 do vermelho



Banda 4 do infravermelho próximo



dispersograma



classificação

Fig. 12.1 O dispersograma com as bandas do vermelho e infravermelho próximo mostra as posições dos pixels que definem os agrupamentos para os alvos vegetação e água, e a classificação desses alvos na imagem (vegetação em verde e água em azul).

Olhando para o dispersograma da Figura 12.1 vemos que o espalhamento dos pontos está representado por eixos ortogonais, na forma como se representa o espaço euclidiano. Usando a idéia do espaço euclidiano, vamos imaginar a existência destas duas classes de alvos, vegetação e água, existentes numa imagem de grande dimensão, muitas vezes maior que a imagem da Figura 12.1. E também, as posições dos centros dos agrupamentos dessas duas classes de alvos, as quais podem ser facilmente obtidas por meio de pequenas áreas de amostragem que sabemos de antemão onde elas ocorrem. Com as informações obtidas das áreas de amostragens, ou áreas de treinamentos, o problema agora se resume em alocar os pixels da imagem às duas classes. Isso pode ser feito pela medida entre a distância de cada pixel da imagem ao centro dos agrupamentos. Os pixels que se encontrarem espectralmente mais próximos a um centro, a ele serão alocados. Pixels que se encontram distantes de ambos os centros não serão alocados nos agrupamentos de vegetação ou água. Nesse espaço

euclidiano, a medida de distância é uma simples aplicação do teorema de Pitágoras. Esse é um conceito de uma medida geométrica para alocação de pixels às classes de alvos existentes na imagem. Também se pode estimar o grau de separação dos dois agrupamentos, olhando para a distância entre seus centros, para saber se as classes de alvos selecionadas são de fato espectralmente separadas.

O princípio da distância euclidiana é utilizado em algoritmos de classificação de imagens, que usam os vetores média de pixels espectralmente homogêneos para definir as classes de alvos, e calcula a distância euclidiana de cada pixel desconhecido ao vetor média para cada classe. Veremos adiante que outras medidas de distância, que não a euclidiana, chamadas de distâncias estatísticas, são empregadas na classificação de imagens.

12.3 Classificação Não-Supervisionada

São classificadores que requerem pouca ou nenhuma participação do analista no processo de classificação da imagem. Há duas situações em que isso pode acontecer. Uma delas é quando não se tem suficientes conhecimentos acerca do número e natureza das classes de alvos que possam estar presentes numa área. A outra é quando desejamos fazer uma classificação exploratória da imagem, para rapidamente e sem grande esforço, saber as possíveis classes de alvos que podem ter na imagem. Não há, portanto, possibilidades de se estimar os centros das classes, como antes visto, usando áreas de treinamento representativas de cada classe. É da responsabilidade do analista, depois da classificação, associar um significado às classes resultantes. O resultado da classificação é útil somente se as classes podem ser interpretadas apropriadamente.

Treinamento não-supervisionado é quase que totalmente automatizado pelo computador. Ele apenas permite ao analista especificar alguns parâmetros que o computador irá usar para descobrir padrões que são inerentes aos dados. Esses padrões não necessariamente correspondem às características reais da cena em termos de classes de alvos que reconhecemos. Eles são simplesmente agrupamentos de pixels com características espectrais similares (*clusters*). Mas, em alguns casos, pode ser mais importante identificar grupos de pixels com características espectrais similares, do que separar os pixels em classes reconhecidas.

Há dois principais algoritmos de classificação não-supervisionada de amplo uso em sensoriamento remoto: ISODATA e *K-médias*. Ambos se baseiam no agrupamento de pixels por suas similaridades, usando técnicas de distância mínima. Por isso, a classificação não-supervisionada é também chamada de *clustering*, devido à técnica usada. Um algoritmo *clustering* usa frequentemente todos os pixels da imagem de entrada para iniciar a análise.

12.3.1 ISODATA

O método *clustering* denominado de ISODATA usa a distância espectral num processo feito em três etapas: (i) classifica iterativamente os pixels; (ii) com isso vai redefinindo os critérios para cada classe; (iii) para reclassificar a imagem até que os padrões de distância espectral nos dados apareçam. ISODATA significa *Iterative Self-Organizing Data Analysis Technique*. Ele é *Iterative*, uma vez que realiza repetidamente uma classificação inteira (produzindo uma imagem temática de saída) e recalcula as estatísticas.

Self-Organizing refere-se ao modo como ela localiza os agrupamentos com mínima informação fornecida pelo usuário.

O classificador ISODATA fundamenta-se no princípio de que todos os agrupamentos encontrados na imagem devem ser compactos, com todos os pixels agrupados em volta da média, ocupando uma região esférica no espaço. Um valor de desvio-padrão deve ser tomado como a medida desta compactidade (Mather, 1987). Caso o desvio-padrão do agrupamento seja maior do que o valor estabelecido, o agrupamento que representa aquela classe de alvo é dividido. A outra condição é que os agrupamentos serão bem separados se seus centros são separados por uma distância mínima maior do que o valor de entrada. Se essa distância entre os centros de agrupamento for menor do que o valor de entrada, então os agrupamentos são fundidos. Divisão e fusão de agrupamento é um processo típico do ISODATA e, portanto, não mantém fixo um número de agrupamento.

O processo de classificação começa com um número aleatório de médias de agrupamentos arbitrários uniformemente distribuídos no espaço de dados, os quais representam uma hipotética possibilidade de centros de agrupamentos. Então, iterativamente as distâncias mínimas são calculadas para cada pixel da imagem e eles são reunidos nos agrupamentos mais próximos usando a técnica de distância mínima (menor distância ao centro dos agrupamentos). No fim dessa primeira sequência de alocação, a média dos valores de todos os pixels alocados a cada agrupamento arbitrário é computada para cada uma das bandas, obtendo-se as coordenadas dos centros de cada cluster. Usando esses novos centros uma nova iteração é realizada e a cada nova iteração é recalculada as médias, e os pixels são então reclassificados com relação às novas médias. As divisões ou fusões de clusters que irão ocorrer durante o processo de classificação dependem dos parâmetros dos padrões de entrada definidos pelo analista, que é o único momento em que ocorre uma participação interativa do analista com o processo de classificação. Alguns desses parâmetros, a exemplo do que é solicitado pelos *software* de processamento de imagens são:

- i) Número máximo de agrupamentos a serem considerados. Uma vez que cada agrupamento é a base de uma classe, esse número é o número máximo de classes a serem formadas. O método ISODATA começa determinando N médias de agrupamentos arbitrários. Alguns agrupamentos com poucos pixels podem ser eliminados;
- ii) Limiar (*threshold*) de convergência, que é a porcentagem máxima de pixels cujos valores de classe irão permanecer sem mudança entre iterações;
- iii) Um número mínimo de pixels em cada classe e caso houver um menor número de pixel na classe ela é desconsiderada e os pixels vão para a classe mais próxima;
- iv) Número de iterações; e
- v) Se o desvio-padrão de uma classe é menor do que o *threshold*, então a classe é dividida em duas classes. Em alguns casos alguns pixels podem ser não classificados, se eles não concordam com os parâmetros selecionados. A classificação finalizará quando o máximo de número de iterações for alcançado.

Essa classificação tem grande sucesso em descobrir os agrupamentos espectrais inerentes aos dados. Não importa onde estão os agrupamentos iniciais desde que um número suficiente de iterações seja permitido. As desvantagens do método são: o processo pode se repetir diversas vezes, consumindo tempo; o método não leva em consideração a homogeneidade espacial dos pixels; e se o número pré-definido de agrupamentos for alto, eles terão de ser fundidos, o que é um gasto desnecessário de processamento. Exemplificando: para 30 agrupamentos e 50.000 pixels, a cada iteração os cálculos para determinar cada distância do pixel ao centro dos agrupamentos são determinados. Se forem 100 as iterações, então teremos $30 \times 50.000 \times 100$, o que requer 150 milhões de multiplicações por banda. Por isso, os algoritmos ISODATA limitam um número máximo de agrupamentos que o usuário deve definir inicialmente.

12.3.2 K-médias

A diferença da classificação K-médias com o classificador ISOTADA é que o K-médias assume que um número de agrupamento é conhecido a priori. Ele fixa um número de agrupamento, enquanto o ISODATA não mantém fixo um número. O objetivo do *K-médias* é minimizar a variabilidade interna do agrupamento que é dimensionada pela função soma das distâncias ao quadrado (erros) entre cada pixel e o centro ao qual é alocado. A soma da distância ao quadrado (*SS*) tem a forma:

$$SS_{distância} = \sum_{xy} [x - C(x)]^2 \quad eq. 12.1$$

onde: $C(x)$ = média do agrupamento ao qual o pixel x é alocado.

É um critério para se avaliar a qualidade do cluster, que não se encontra no ISODATA. No restante, o K-médias segue os mesmos processos que foram apresentados para o ISODATA, mas como se fixa um número arbitrário de agrupamentos, divisão e fusão de clusters não ocorrem. Um exemplo comparativo de classificação pelos métodos ISODATA e K-médias é apresentado na Figura 12.2.

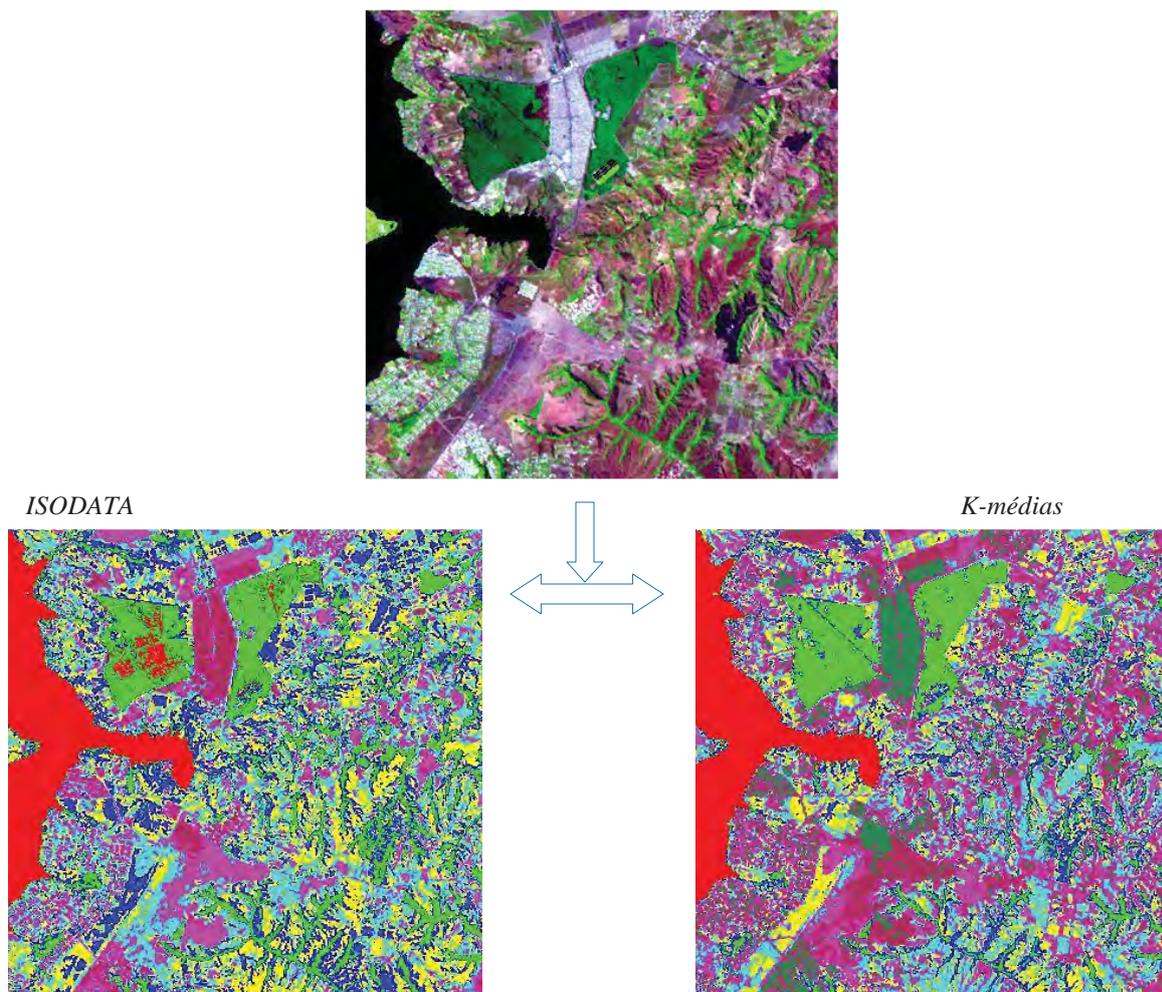


Fig. 12.2 Resultados da classificação ISODATA e K-médias para um conjunto de seis bandas e sete classes. Acima, composição colorida 543/RGB da área selecionada para a classificação.

12.4 Classificação Supervisionada

Ao contrário da classificação não-supervisionada, a classificação supervisionada requer conhecimentos prévios das classes de alvos, a fim de classificar a imagem nas classes de interesse pré-fixadas pelo analista. O algoritmo necessita ser treinado para poder distinguir as classes uma das outras. O treinamento supervisionado é controlado de perto pelo analista. Nesse processo o analista escolhe pequenas áreas de amostras na imagem, contendo poucas centenas de pixels que sejam bem representativo, espectralmente, de padrões ou feições dos alvos por ele reconhecidos, ou que podem ser identificados com a ajuda de outras fontes, tais como dados coletados no campo ou de mapas. É necessário o conhecimento dos dados e das classes de objetos que existem na área, antes de se iniciar o processo de classificação. Não há nenhuma restrição no número de classes a serem classificadas, apenas que o analista faça uma seleção de classes bem distintas porque, caso contrário, no final da classificação ocorrerá muita confusão entre as classes. Se o treinamento tiver uma boa precisão, as classes resultantes representam as categorias dos dados que o analista identificou originalmente. Também, para assegurar uma boa classificação, as imagens devem ser corrigidas dos efeitos atmosféricos, se severos, e da presença de ruídos. As características estatísticas das classes que são estimadas das amostras de treinamento dependem do método de classificação que é utilizado. Há vários métodos de classificação supervisionada: paralelepípedo, distância mínima, distância de Mahalanobis e máxima verossimilhança.

12.4.1 Paralelepípedo

O classificador supervisionado paralelepípedo tem esse nome porque em um espaço de dados bidimensional (duas bandas), os valores dos pixels de cada classe de treinamento são estimados por um limite superior e um limite inferior de valores digitais, que são identificados como as dimensões das bordas do paralelepípedo. Para estimar esses limites tomam-se os valores terminais da curva histogrâmica das amostras de treinamento em cada banda, como mostra a Figura 12.3. Os dois histogramas desta figura representam o padrão de brilho de uma classe de treinamento visto em duas bandas (eixos x_1 e x_2). Na classificação, o pixel cujo valor cair entre os limites inferior e superior para todas as n bandas que estão sendo classificadas é designado àquela classe. Por meio desse simples processo os padrões dos paralelepípedos são construídos para o espaço de n dimensão. Na Figura 12.4 eles estão representados para um espaço bidimensional.

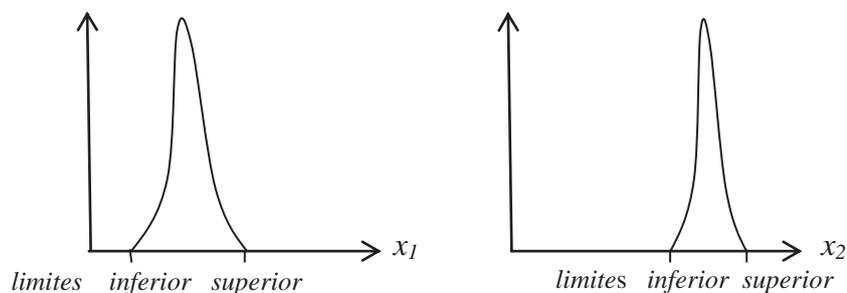


Fig. 12.3 Histogramas das classes de treinamento tomadas de duas bandas, com os limites inferior e superior que estimam os valores de pixels da classe.

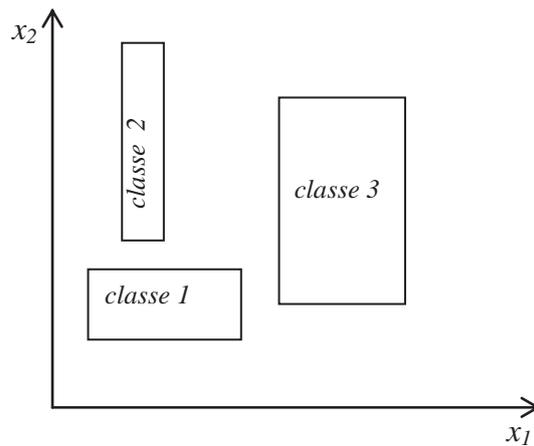


Fig. 12.4 Padrões de paralelepípedos de classes de treinamento com dimensões determinadas pelos limites dos histogramas.

Essa simples regra de decisão pode ser estendida, acrescentando um limiar (*threshold*) baseado no desvio-padrão. Nesse caso, as dimensões da classificação paralelepípedo são estimadas pelo limiar do desvio-padrão da média de cada classe selecionada. Da mesma forma, se o valor do pixel cair acima do limiar inferior e abaixo do limiar superior para as n bandas que estão sendo classificadas, ele é alocado àquela classe (Figura 12.5). Fato comum na classificação de imagens é ocorrer pixels que são candidatos a várias classes ou que não se encaixam a nenhuma classe. No primeiro caso, como os pixels são pixels classificados, o algoritmo paralelepípedo usa a decisão de realocá-los à primeira ou à última das classes. A segunda situação é bem mais comum de acontecer, porque são muitos os espaços "vazios" entre os paralelepípedos. Na verdade, nesses espaços estão os pixels que não caíram dentro dos paralelepípedos, e na classificação serão rotulados como não-classificados.

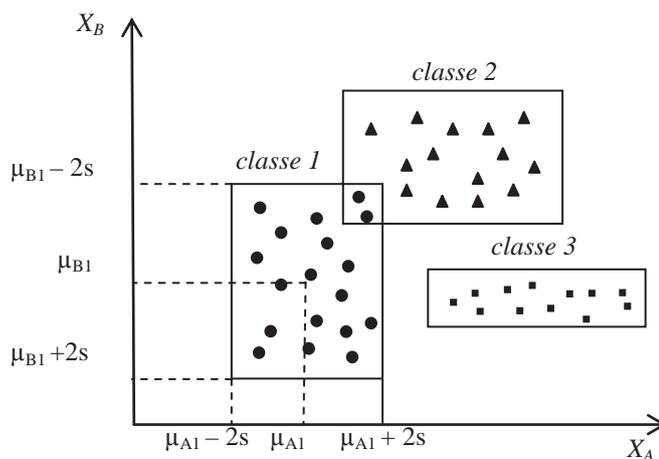


Fig. 12.5 Representação das dimensões dos paralelepípedos das classes selecionadas levando em conta um limiar (*threshold*) de desvio-padrão.

O método do paralelepípedo tem a vantagem de ser rápido e simples, uma vez que os valores dos pixels são comparados aos limites que permanecem constantes para cada banda. É frequentemente usado como uma primeira exploração de classificação. Com ele se tem uma idéia de quantas classes poderão ser usadas nas classificações mais consumidoras de tempo. Como é um método que não depende de distribuições normais, uma de suas desvantagens é que os paralelepípedos possuem "cantos" e, sendo assim, um pixel pode ser classificado mesmo estando distante espectralmente da média da classe, como mostra a Figura 12.6. Então, as classes poderão conter pixel espectralmente "impuros."

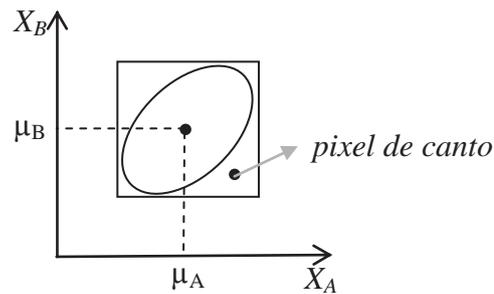


Fig. 12.6 Situação em que um pixel de canto, que se encontra distante da média da classe, é classificado à classe no método de classificação paralelepípedo.

Para a classificação é aconselhável o uso de um maior número de bandas porque isso ajuda a aumentar a separabilidade das áreas de treinamento das classes. E as áreas de treinamento devem ser homogêneas, mas que também incluam a variabilidade que possa estar presente, porque na natureza os alvos normalmente se compõem de associações de objetos. Também se recomenda adquirir mais do que uma amostra de área de treinamento por classe. Na classificação paralelepípedo não há necessidade das amostras de treinamento ter uma grande quantidade de pixels, como é necessário na classificação máxima-verossimilhança. De 50 a 200 pixels são suficientes.

Um resultado prático da classificação pelo método do paralelepípedo é mostrado na Figura 12.7. A Figura 1.27a mostra as áreas de treinamento das classes selecionadas e a Figura 1.27b o resultado da classificação. Foram selecionadas oito classes e usadas as seis bandas da faixa óptica do sensor ETM⁺ do Landsat 7. Embora o resultado possa ser considerado bom, algumas falhas podem ser notadas. Por exemplo, vários trechos da mata de galeria (cor amarela) foram classificados como reflorestamento (cor marrom), e o lago (cor azul) apesar de ser aparentemente homogêneo não foi completamente classificado. Pixels não classificados são mostrados em preto. Uma parte desses pixels são estradas, que não foram incluídas nas classes selecionadas devido à dificuldade de amostragem. Após a classificação é aconselhável que o analista compare a imagem original com a imagem classificada para ver as área que porventura não foram classificadas. Nesse caso, podemos refazer a classificação adquirindo mais amostras de cada classe, até que toda a imagem esteja classificada, ou então fazer uma edição matricial, na qual selecionaremos os pixels que não foram classificados, e de acordo com a imagem, editar para a classe correspondente. Os *software* normalmente incluem ferramentas de pós-classificação com várias opções para ajustar os resultados.

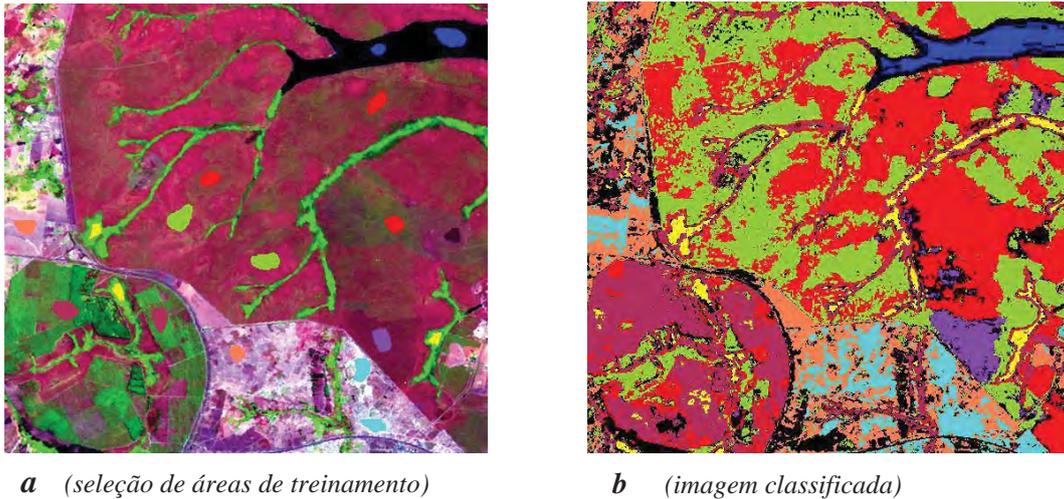


Fig. 12.7 (a) Seleção de áreas de amostragem de oito classes e (b) o resultado da classificação paralelepípedo com um limiar de desvio-padrão de valor três.

12.4.2 Distância mínima

O método da distância mínima calcula a distância espectral entre o vetor de medida para o pixel candidato e a média para cada assinatura de classe. O método se utiliza da medida de distância Euclidiana. Cada pixel será incorporado a um agrupamento através da análise da medida de similaridade de distância Euclidiana, que é dada por:

$$D(x, n) = \sqrt{(x_i - m_i)^2} \tag{eq. 12.2}$$

onde: x_i = pixel candidato; m_i = média das classes; n = número de bandas.

A Figura 12.8 ilustra a medida da distância pelas linhas entre o pixel candidato e as médias de três classes. O classificador compara a distância Euclidiana de cada pixel à média de cada agrupamento. O pixel candidato é designado à classe com média mais próxima, isto é, à classe que apresenta a menor distância Euclidiana.

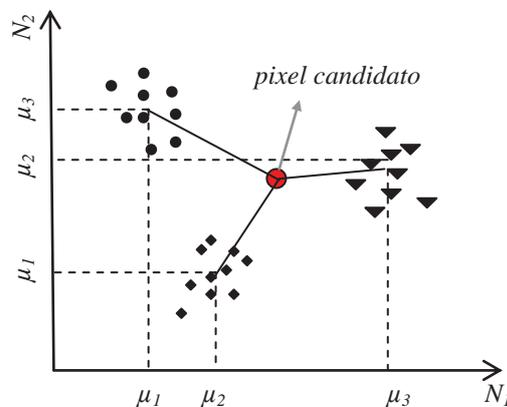


Fig. 12.8 As linhas cheias indicam as medidas da distância mínima para um pixel candidato às classes.

A vantagem do método é que todos os pixels encontrarão uma média à qual estarão espectralmente mais próximos, e assim, não existirão pixels não-classificados. É a regra de decisão mais rápida depois do paralelepípedo. As desvantagens são: *i*) pixels que deveriam permanecer não-classificados, isto é, eles não estão espectralmente próximos a nenhuma amostra dentro de limites razoáveis, serão classificados; *ii*) o método não considera a variabilidade espacial da classe. Por exemplo, uma classe de área urbana tem uma alta variabilidade espacial, incluindo muitos pixels que tendem a ser distantes da média da assinatura da classe. Usando a regra de decisão por distância mínima, esses pixels urbanos podem ser classificados em outras classes. Por outro lado, uma classe com menor variabilidade, como um corpo de água, tende a classificar mais pixels que o apropriado para a classe, porque os pixels que pertencem à classe estão, normalmente, mais próximos espectralmente da sua média, do que aqueles das outras classes às suas médias.

Na Figura 12.9 é apresentado o resultado do classificador por distância mínima, usando a mesma imagem e as mesmas áreas de treinamento da Figura 12.7, para que se possa comparar o desempenho dos dois classificadores. Notam-se pequenas diferenças nas áreas classificadas, sobretudo, porque o classificador por distância mínima aglutina mais os polígonos das classes, reduzindo a aparência excessivamente segmentada do mapa digital obtido pelo método do paralelepípedo.

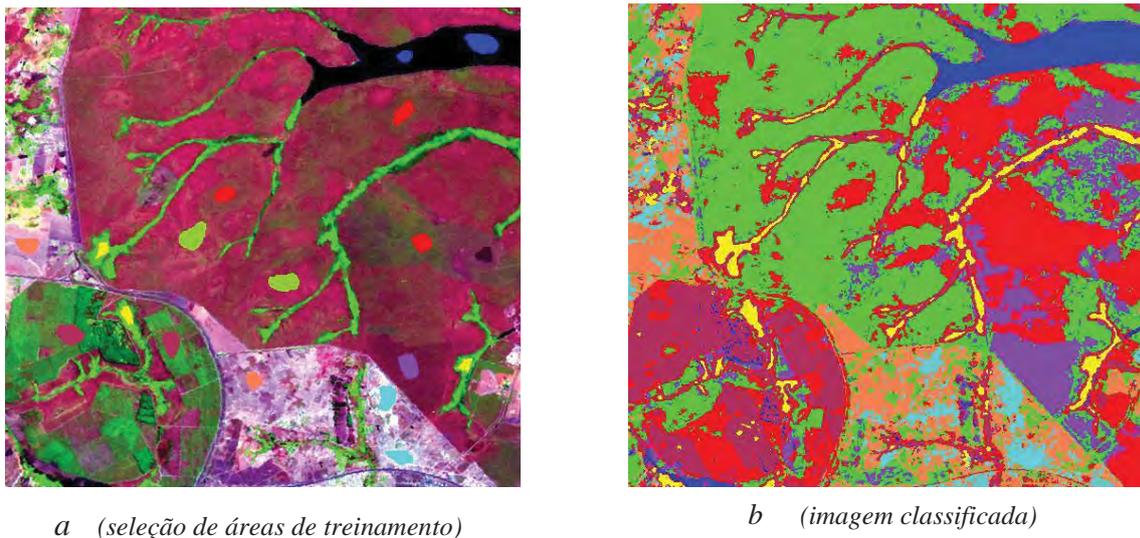


Fig. 12.9 Resultado da classificação distância mínima, com as mesmas áreas de amostragem da Figura 12.7.

12.4.3 Máxima-Verossimilhança

O classificador por máxima verossimilhança (MaxVer) considera a ponderação das distâncias entre as médias dos valores dos pixels das classes, utilizando parâmetros estatísticos. Assume que todas as bandas têm distribuição normal e calcula a probabilidade de um dado pixel pertencer a uma classe específica (INPE, 2008). É um classificador mais eficiente porque as classes de treinamento são utilizadas para estimar a forma da distribuição dos pixels contidos em cada classe no espaço de n bandas, como também a localização do centro de cada classe. Essa abordagem é diferente do que foi mostrado anteriormente, que se

fundamentava no princípio de compacidade de que os pontos são distribuídos à volta do centro de média de um modo esférico. Se a distribuição dos pontos for claramente não esférica, como um elipsóide, seria esperado que a possibilidade (probabilidade) de um ponto pertencer ao agrupamento irá depender não somente da distância ao centro do agrupamento, mas também das dimensões e direções dos eixos do elipsóide.

Quanto a isso, vimos no capítulo 9 como representar a distribuição dos pixels delimitando-os no espaço de uma elipse, e que a orientação e as dimensões relativas dos eixos da elipse que vão definir qual será a sua forma, dependem da matriz de covariância. Vamos considerar no espaço bidimensional que as distribuições dos pixels de duas classes de treinamento assumem as formas dos elipsóides que mostra a Figura 12.10. A classe 1 tem uma orientação inclinada para a direita, significando uma orientação de covariância positiva alta entre as duas bandas. Já a classe 2 tem uma inclinação para a esquerda, que indica que a orientação da covariância é negativa. Elas têm distribuições de probabilidades distintas, e essas distribuições representam a probabilidade do pixel A pertencer à classe 1 e do pixel B pertencer à classe 2. Isso significa que a alocação dos pixels às suas classes depende da posição do pixel em relação às distribuições. Mas, note que se fosse usado apenas a medida da distância aos centros das classes, como nos algoritmos anteriores, depararíamos com um problema. Na Figura 2.10 os centros das duas classes são indicados nos elipsóides, assim como os dois pixels A e B, de pertencerem, respectivamente, às classes 1 e 2. Apenas pela medida de distância dos pontos A e B aos centros das duas classes, o pixel A deveria pertencer à classe 2 porque é menor a sua distância ao centro da classe 2, comparado com a distância ao centro da classe 1.

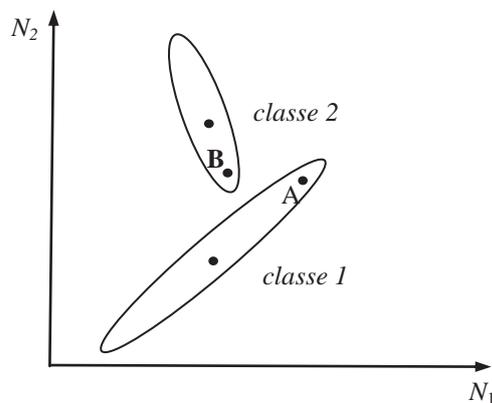


Fig. 12.10 As distribuições de probabilidades representadas pelas elipses e calculadas pela covariância mostram que o ponto A pertence à classe 1 a despeito de sua distância ao centro da classe 2 ser menor.

Portanto, na classificação de máxima verossimilhança cada pixel é destinado à classe que tem a mais alta probabilidade, isto é, a máxima verossimilhança. Isso significa que para um pixel na posição x do espaço multiespectral, um conjunto de probabilidades são computadas e que dão as possibilidades relativas do pixel pertencer a cada classe disponível ($p(x|\omega_i)$). Segundo Richard & Jia, (2006) a classificação de um ponto x é realizada de acordo com:

$$x \in \omega_i \text{ se } p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j)$$

eq. 12.3

onde, a probabilidade $p(x|\omega_i)$ dá a possibilidade de x pertencer à classe ω_i e $p(\omega_i)$ é a probabilidade de a classe ocorrer na imagem, que de fato é conhecida das áreas de treinamento. Tantas quanto forem as classes de treinamento selecionadas, tantas serão $p(x|\omega_i)$. Todos os pixels serão classificados, a menos que seja definido um limiar. Assim, tem-se que:

$$p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j) \text{ e } p(x|\omega_j)p(\omega_j) > \text{limiar} \quad \text{eq. 12.4}$$

A necessidade de se usar um limiar é quando ocorrem situações ruins de classificação. Essas situações surgem se as classes espectrais se sobrepõem ou se conhecendo que existem outras classes, não há, contudo, suficientes áreas de treinamento para estimar com confiança os parâmetros de suas distribuições. Aplica-se o limiar para estabelecer um limite para o processo de decisão de separabilidade.

Para entender o significado de limiar observe a Figura 12.11. As duas curvas representam a distribuição de probabilidade de duas classes onde há uma sobreposição, indicando que alguns pixels têm iguais probabilidades de pertencer às duas classes. Nessa condição, o resultado da classificação seria baixo. O limiar é um valor real positivo que indica a porcentagem de pixels da distribuição de probabilidade de uma classe que será classificada como pertencente a essa classe. Abaixo do limiar os pixels não são considerados como pertencentes a uma classe, ou seja, pode-se fixar uma verossimilhança máxima a partir da qual o ponto não será considerado como pertencente à classe analisada. Esses pixels normalmente estão situados nas extremidades da curva de distribuição de probabilidade. O limiar fornece ao usuário a possibilidade de variar o rigor da classificação. Quanto menor o limiar, mais rigorosa será a classificação. Um ótimo compromisso pode ser alcançado com o classificador máxima-verossimilhança se nossa estimativa da distribuição de probabilidade for correta, e para isso é preciso selecionar cuidadosamente as áreas de treinamento. A desvantagem que pode apresentar é se existir uma dispersão dos pixels em uma classe de treinamento. Neste caso, a matriz de covariância irá mostrar valores altos.

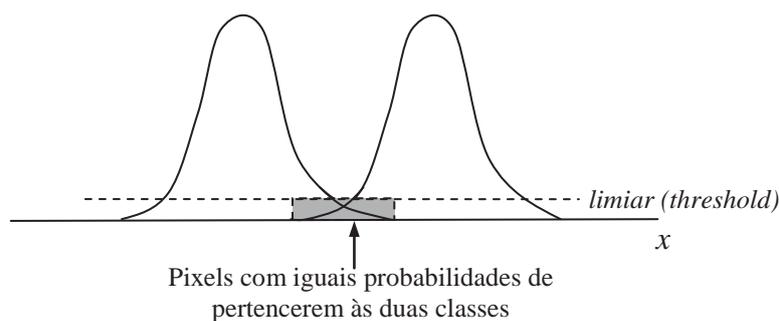
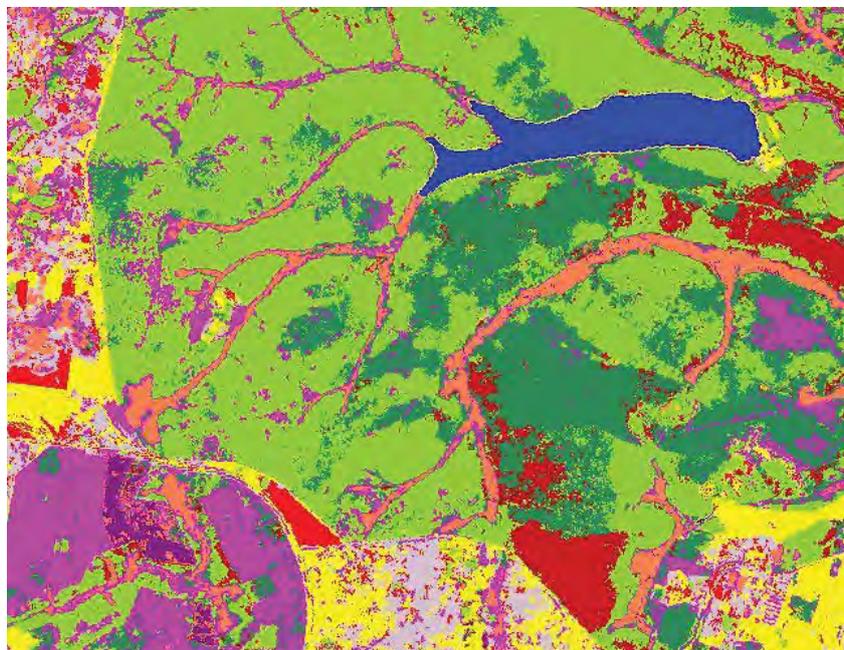


Fig. 12.11 Condição em que pixels serão pobremente classificados quando se situam nas extremidades da curva de distribuição de probabilidade. O limiar remove o erro questionável de classificação.

A Figura 12.12 mostra o resultado da classificação máxima verossimilhança para oito classes selecionadas e seis bandas do sensor ETM⁺. O uso desse classificador exige que as áreas de amostragem das classes de treinamento tenham uma grande quantidade de pixels, da ordem de centenas. Por ser um classificador com base na probabilidade é recomendável que se tenha números de pixels por classe de amostragem mais ou menos iguais, e que sejam tomadas mais do que uma área de amostragem por classe.



Seleção de áreas de amostragem de oito classes



Classificação MaxVer

Fig.12.12 Resultado da classificação máxima verossimilhança das seis bandas ópticas do sensor ETM para oito classes selecionadas a partir de áreas de treinamento indicadas na composição colorida RGB.

12.4.4

Distância Mahalanobis

Na Figura 12.10 apresentada na discussão do classificador por máxima verossimilhança, observamos que a direção onde o elipsóide tem um eixo menor, o ponto deverá estar mais próximo ao seu centro, mas se o eixo for maior, o ponto estará mais distante do centro. E vimos que o elipsóide que melhor representa a distribuição de probabilidade da classe é estimado pela matriz de covariância das classes de treinamento. A distância de Mahalanobis é, simplesmente, a medida da distância do pixel na posição x do espaço multidimensional ao centro da classe, dividida pelo comprimento do elipsóide na direção de x . Isso tem a propriedade de minimizar a distância do ponto ao centro de média. É dessa forma um classificador de distância sensível à direção que usa estatística para cada classe, o que o faz similar ao classificador por máxima verossimilhança, mas assume que todas as classes tem covariâncias iguais. Isso lhe dá a vantagem de ser um classificador mais rápido do que o de máxima verossimilhança.

Para se usar a distância Mahalanobis para classificar um pixel a uma das n classes, inicialmente calcula-se a matriz de covariância com base nas amostras de treinamento das n classes, e o pixel será destinado à classe na qual a distância de Mahalanobis seja a menor de todas. Usando a interpretação probabilística, comparativamente isso equivale à classe que apresenta a máxima verossimilhança. A medida da distância de Mahalanobis considera que um pixel tem uma distância menor ao centro de média que um outro pixel candidato, se ele se distribuir ao longo do eixo da classe com maior variabilidade. Ele deve, então, ser classificado a essa classe. As medidas Mahalanobis computadas definem um espaço multidimensional cujos limites determinam o intervalo de variação tido por aceitável para que pixels candidatos possam ser classificados como pertencentes a uma das classes existentes.

A medida de Mahalanobis é usada para identificar pixels que se distanciam bastante dos pixels da distribuição. Muitas vezes, quando são selecionadas as áreas de amostragens das classes de treinamento, alguns pixels podem contaminar a homogeneidade das classes, levando a erros nos cálculos da média e da matriz de covariância. Técnicas de regressão podem ser utilizadas para determinar se um pixel é atípico ou não no espaço multivariado, usando medidas da distância ao quadrado que classifica os pixels na base da menor das distâncias $d(x, m_i)$ sensível à direção, na forma de:

$$d(d, m_i^2) = \ln \left| \sum i \right| + (x_m - m_i)^2 \sum i^{-1} (x - m_i)$$

eq. 12.5

A Figura 12.13 é o resultado da classificação pela distância Mahalanobis, utilizando as mesmas áreas de treinamento mostradas na Figura 12.12 e as mesmas bandas.

12.4

Validação da Classificação

Uma das últimas etapas da classificação digital de imagens é a da validação dos resultados da classificação. O que se busca nessa etapa é avaliar a acurácia da classificação.

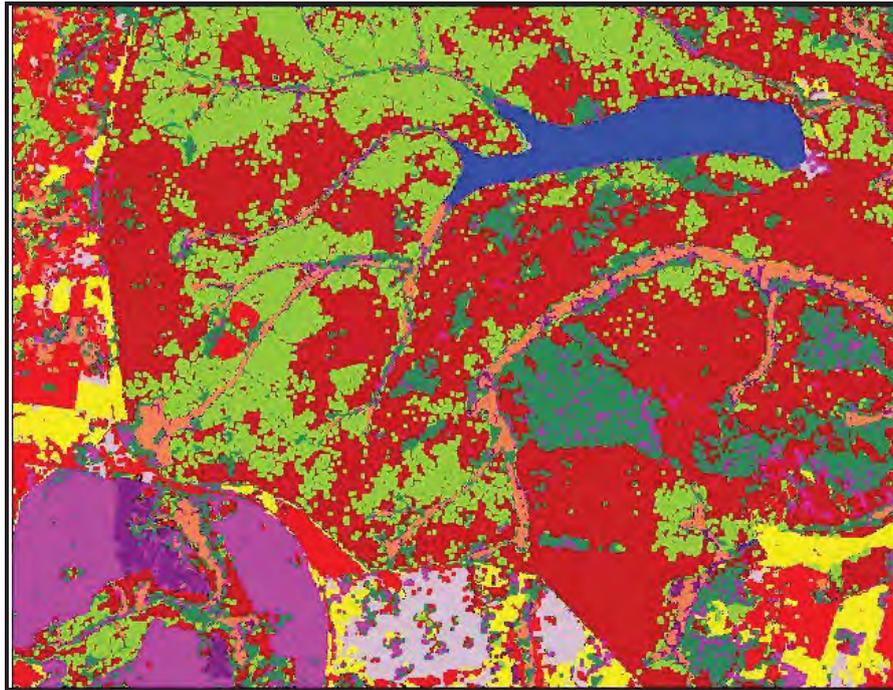


Fig. 12.13 Resultado da classificação distância de Mahalanobis utilizando as mesmas áreas de amostragem da Figura 12.12.

Um resultado com 100% de acurácia significa que todos os pixels da imagem foram classificados de forma correta, segundo um conjunto de dados que compõe a verdade terrestre. Um resultado com 50% de acurácia significa que, em teoria, metade dos pixels da imagem foi classificada corretamente. A acurácia depende de uma série de fatores como a complexidade do terreno, as resoluções espaciais e espectrais do sistema sensor, o próprio algoritmo de classificação utilizado, a legenda utilizada no processo de classificação e o conjunto de dados que representa a verdade terrestre. Por exemplo, considere os resultados da classificação de imagens de satélite de um determinado município. Se a legenda for composta de duas classes, terra e água, a acurácia tende a ser maior do que a de outra legenda composta por três classes de vegetação natural – formações campestres, savânicas e florestais – e três classes de uso da terra – culturas agrícolas, pastagens cultivadas e reflorestamento.

A acurácia é normalmente expressa em termos de índices que são calculados a partir de matrizes de erros que expressam a concordância entre a imagem classificada e o conjunto de amostras de referência. A matriz de erros compara, classe por classe, a relação entre os dados de verdade terrestre (dados de referência) e os correspondentes resultados da classificação. O número de linhas e o número de colunas dessa matriz devem ser iguais ao número de classes espectrais do estudo. Erros de omissão (exclusão) e de comissão (inclusão) de cada classe são calculados a partir dessa matriz.

Na Tabela 12.1 é mostrada uma matriz típica de erros, apresentada por Sano *et al.* (2010) que foi obtida ao validar o mapa de cobertura vegetal natural e antrópica do Bioma Cerrado por meio de 315 verificações de campo. Colunas da matriz referem-se à verdade terrestre, enquanto as linhas representam a interpretação de imagens. Valores em negrito da diagonal principal da matriz correspondem ao número de pixels que foram corretamente classificados. Valores fora da diagonal correspondem a erros de omissão (EO) e comissão (EC) e que podem ser expressos na forma de percentagens.

Tabela 12.1 Erros de omissão e comissão referentes ao mapeamento de cobertura vegetal natural e antrópica do Bioma Cerrado.

Interpretação de imagens	Verdade terrestre						TOTAL	EO (%)	EC (%)
	1	2	3	4	5	6			
1	1	0	1	0	0	0	2	75,0	50,0
2	1	57	20	3	0	24	105	1,7	45,7
3	1	1	33	0	0	1	36	43,1	8,3
4	0	0	1	71	21	5	98	10,1	27,6
5	1	0	0	5	53	1	60	29,3	11,7
6	0	0	3	0	1	10	14	75,6	28,6
TOTAL	4	58	58	79	75	41	315		

Formações campestres (1); Formações savânicas (2); Formações florestais (3); Pastagens cultivadas (4); Culturas agrícolas (5); Reflorestamentos (6). (Fonte: Sano *et al.* 2010).

Outras medidas descritivas podem ser obtidas a partir dessa matriz de confusão. Uma delas é a exatidão global, que é computada dividindo-se o número total de pontos corretamente classificados (soma dos elementos ao longo da diagonal principal = 225) pelo número total de pontos de validação = 315). Dividindo-se 225/315, tem-se uma exatidão global de 71,43%, em uma escala que varia de 0 a 100%.

O índice Kappa (K) é outro método bastante utilizado na avaliação dos resultados de classificação. Esse índice varia de 0 (concordância nula) a 1 (concordância perfeita)

$$K = \frac{\theta_1 - \theta_2}{1 - \theta_1}$$

eq. 12.6

onde, $\theta_1 = \frac{\sum_{i=1}^c x_{ii}}{n}$ e $\theta_2 = \frac{\sum_{i=1}^c x_i}{n^2}$

De acordo com os dados da Tabela 12.1 tem-se que $\theta_1 = 0,71$ e $\theta_2 = 0,21$, o que resulta em $K = 0,64$, considerada como sendo muito boa, de acordo com a qualidade da classificação associada aos valores da estatística Kappa que foi proposta por Landis e Koch (1977): 0 – 0,2 = ruim; 0,2 – 0,4 = razoável; 0,4 – 0,6 = boa; 0,6 – 0,8 = muito boa; e 0,8 – 1,0 = excelente.

Mais recentemente, Ma e Redmond (1995) propuseram ainda o uso do coeficiente Tau (τ) para avaliar a acurácia da classificação. Os autores citaram as seguintes vantagens do uso do τ em relação à estatística Kappa: conceitualmente τ é mais simples de entender; τ é mais simples de ser calculado; e τ considera o número de categorias ou classes consideradas na análise. Uma comparação relativamente detalhada do desempenho dos três métodos aqui mencionados (exatidão global, índice Kappa e índice Tau) pode ser encontrada no estudo desenvolvido por Brites *et al.* (1996).

O tamanho (número) de amostras a serem adquiridas nesse processo de validação é outra questão delicada. Como uma regra geral, Congalton (1991) e Lillesand *et al.* (2008) sugeriram que um mínimo de 50 amostras de cada classe deveria ser considerado na construção da matriz de erros. Fitzpatrick-Lins (1981), citado por Jensen (2005), definiram, com base na teoria de probabilidade binomial, um número mínimo de 203 observações para um percentual de exatidão de 85% e um erro admissível de 5%. No entanto, essa regra nem sempre pode ser seguida na prática, por causa das dificuldades de acesso à área de estudo e do tempo e custos envolvidos na aquisição de números grandes de pontos de validação.

Ricardo Seixas Brites

Edilson de Souza Bias

Antonio Nuno de Castro Santa Rosa

13.1

Segmentação de Imagens

A segmentação de imagens consiste num processo de agrupamento de pixels que possuem características semelhantes. De acordo com Gao (2009), trata-se da decomposição de uma imagem em regiões discretas, contíguas e que não se interceptam, constituindo, semanticamente, segmentos significativos.

O processo pode se dar de forma manual ou automática. A forma manual nada mais é do que estabelecer sobre a imagem os polígonos que representam regiões homogêneas, de forma semelhante à usada pelos fotointérpretes. Como é comum nesses casos, diferentes intérpretes podem gerar produtos diferentes a partir de uma mesma imagem. O processo automático, por considerar dados de natureza quantitativa, produz resultados bastante bons em uma fração do tempo muito menor do que seria dispendido no caso da segmentação manual. Em virtude desses aspectos, é ele o mais utilizado em processamento de imagens.

O processo de segmentação faz com que o contexto em que se encontra inserido o pixel seja considerado na classificação, isso é, leva em conta as características do meio (regiões) e não exclusivamente, os valores espectrais dos pixels. Isso o distingue dos processos de classificação realizados pixel a pixel, vistos no capítulo anterior.

O processamento das imagens se dá, inicialmente, pela utilização de um algoritmo de segmentação que, ao definir regiões homogêneas na imagem, prepara-a para uma classificação posterior com base nessas regiões e não com base em valores individuais dos pixels. Como as condições texturais da imagem passam a ser consideradas nesse tipo de abordagem, a classificação por segmentação se aproxima mais daquela feita, de forma qualitativa, por intérpretes humanos, acabando por produzir índices de exatidão mais elevados. Ela surgiu com o advento dos modernos sensores de alta resolução espacial, que produzem imagens onde os objetos podem ser identificados individualmente. Assim, uma mudança substancial teve de ser implementada na concepção dos tradicionais algoritmos de classificação, estes mais preparados para classificar imagens de baixa resolução espacial. Como afirmaram Neubert *et al.*, (2006), os objetos em imagens de sensoriamento remoto são frequentemente homogêneos e podem ser delineados por meio da segmentação.

Em virtude da alta resolução espacial observa-se nas imagens uma maior variância interpixels do que intrapixel, como ocorre com as imagens adquiridas por sensores de baixa e média resolução. A maior facilidade para se discriminar alvos de pequenas dimensões faz com que os resultados das classificações tradicionais apresentem uma aparência repleta do que se convencionou chamar de efeito “*salt-and-pepper*” (sal e pimenta), caracterizado por pequenos polígonos disseminados por toda a área mapeada e que acabam por demandar operações de pós-processamento, como filtragens, para a sua eliminação. No caso de classificações baseadas em regiões, o grande grau de controle sobre o número de polígonos no momento inicial da segmentação elimina previamente esse problema, uma vez que as

amostras de treinamento são consideradas os segmentos ou unidades básicas, e não pixels individuais dentro de cada amostra.

Na maioria dos atuais aplicativos de processamento de imagens comercializados, encontramos vários tipos de algoritmos de segmentação. Como regra geral desses algoritmos fica a cargo do usuário definir o limiar de similaridade e o tamanho mínimo para os polígonos que serão gerados, este normalmente expresso em número de pixels contidos na região. Esse processo, inevitavelmente, acaba levando a procedimentos de tentativa e erro até que se consiga uma configuração apropriada dos segmentos gerados. Essa tarefa se torna mais complexa na medida em que mais heterogênea é a área de estudo. Por exemplo, a segmentação de áreas urbanas, onde normalmente é pretendido de se obter muitas categorias diferentes no processo de classificação, é um exemplo da variedade de possibilidades que se tem para a geração de polígonos dependendo, naturalmente, dos limiares de similaridade estabelecidos.

Por limiar de similaridade deve-se entender o grau de similitude entre o pixel candidato à inclusão em um determinado segmento e os parâmetros estatísticos referentes aos pixels que já fazem parte do segmento em questão. O tamanho mínimo dos polígonos, também conhecido por limiar de área, se refere ao número mínimo de pixels admitidos em qualquer um dos segmentos.

Dentre os algoritmos disponibilizados pelos classificadores, o mais utilizado é o de crescimento de regiões. Inicialmente, ele considera um pixel, dito “semente”, como sendo uma região. Na sequência, ele inicia as comparações com as outras regiões adjacentes levando em consideração o limiar de similaridade fixado pelo analista, executando um teste de médias em que o limiar define a distância entre elas. No caso de a distância ser inferior ao limiar, as regiões são unidas, caso contrário continuam separadas. É importante notar que sempre que regiões são unidas, os parâmetros estatísticos são recalculados e novas comparações são feitas com as regiões adjacentes. O limiar estabelecido para o número mínimo de pixels consiste em outro requisito para que uma nova região seja criada, ou seja, quanto menor for esse número, menores poderão ser as regiões, o que em decorrência pode gerar um grande número de pequenos polígonos que muito pouco acrescenta à qualidade da classificação posterior. De qualquer forma, essa é uma opção do usuário que deve, de forma criteriosa, avaliar a conveniência para o estabelecimento de cada limiar requerido pelo algoritmo. É importante ressaltar, como afirma Gao (2009), que o processo é iterativo, de forma que uma região cresce até que novos pixels não possam mais ser alocados a nenhum dos segmentos. A repetição se dá até que a imagem toda se encontre segmentada. Os exemplos mostrados a seguir tentam ilustrar o comportamento do procedimento de segmentação utilizando o algoritmo de crescimento de regiões do aplicativo SPRING (Câmara *et al.*, 1996). As imagens são do satélite IKONOS nas bandas 2, 3 e 4, e foram cedidas por Santos *et al.*, (2010).

Na Figura 13.1 utilizou-se um valor 15 para o limiar de similaridade (valor máximo para a Distância Euclidiana entre a média dos pixels componentes do segmento e qualquer pixel candidato) e 50 como o número mínimo de pixels para que se estabelecesse um segmento. Da análise dos segmentos sobrepostos à composição de bandas nota-se um grande número de polígonos, decorrente do pequeno valor do limiar de similaridade. Quanto menor é esse limiar, menor é a probabilidade de um pixel candidato ser incluído num dado segmento – considerando-se é claro, que a imagem contém feições de razoável heterogeneidade. Nesse caso em particular, tem-se de acordo com Santos *et al.*, (2010), água, estrada pavimentada, fragmentos florestais, solo exposto, áreas urbanizadas e pastagens. Observe que na porção sul da figura uma parte de um provável caminho não pavimentado deixou de se constituir em segmento. Embora seja composto por pixels espectralmente próximos, o não surgimento do

segmento se deve ao fato de que o número mínimo de pixels é ainda superior ao número dos pixels que poderiam vir a se agrupar nesse novo segmento.



Fig. 13.1 Imagem segmentada com limiar de similaridade = 15 e área (pixels) = 50.

Na Figura 13.2 manteve-se o limiar de similaridade 15 e alterou-se o número mínimo de pixels para que se possa individualizar um segmento. Como era de se esperar, pelo fato de a área mínima haver dobrado (100), reduziu-se sensivelmente o número de polígonos.



Fig. 13.2 Segmentação com limiar de similaridade = 15 e área (pixels) = 100.

Analisando-se a Figura 13.3, na qual se mudou o limiar de similaridade para 30, o que significa uma diminuição na rigidez do critério de se aceitar em um segmento determinado pixel, diferenças são percebidas. Em outras palavras, admite-se em um dado segmento o pixel cuja distância euclidiana seja de até 30 em relação à média do segmento em questão. Comparando-se os novos polígonos com os da Figura 13.2, que utiliza o mesmo limiar para a área, nota-se, por exemplo, no extremo sudoeste, que um polígono nela existente desaparece na imagem da Figura 13.3. A razão disso, bem como de outros que não se encontram mais presentes, é que ao se aumentar a distância euclidiana, pixels que pertenciam a outro polígono foram enquadrados, devido à similaridade, em outro polígono, tornando-o maior. O mesmo fenômeno pode ser notado no centro-sul da imagem.



Fig. 13.3 Segmentação com limiar de similaridade = 30 e área (pixels) = 100.

Numa última opção aumentou-se ainda mais o limiar de similaridade (50) mantendo-se a área mínima (100) em número de pixels. A Figura 13.4 mostra essa situação, que considerando as características de heterogeneidade da imagem pode ser vista como um caso extremo. Nesse caso, os polígonos que restaram são apenas aqueles que espectralmente contém pixels muito diferenciados e que não poderiam, dados os limiares estabelecidos, compartilharem o mesmo segmento.

Como exemplificado nas figuras anteriores, percebe-se que a segmentação de uma imagem requer do analista, dado o seu aspecto empírico, um bom conhecimento do que está presente na área e do grau de generalização que ele estaria disposto a assumir. A Figura 13.5, extraída do trabalho de Corte *et al.*, (2008), mostra o grande número de tentativas, variando-se os limiares, até que se chegasse a uma definição de qual seria a combinação ideal entre limiar de similaridade e área mínima, num trabalho que objetivava detectar plantios florestais a partir de uma imagem SPOT.



Fig. 13.4 Segmentação com limiar de similaridade = 50 e área (pixels) = 100.

Similaridade					
5	10	15	25	35	45
----- Areas -----					
100	100	100	100	100	100
200	200	200	200	200	200
300	300	300	300	300	300
400	400	400	400	400	400

Fig. 13.5 Combinações dos pares de limiares. (Copiado de Corte *et al.*, 2008).

Ao se utilizar esse recurso em um classificador por regiões, como será visto a seguir, o resultado da classificação irá em grande parte refletir a composição dos segmentos obtidos nesse processo, o que pode colaborar, de forma decisiva, para uma maior exatidão nos resultados a serem obtidos.

13.2 Como se dá a Classificação por Região

Os procedimentos de classificação de imagens fazem parte de um vasto campo de pesquisas que objetiva o reconhecimento de padrões representados nas imagens orbitais. Como vimos no capítulo anterior, os pixels de uma imagem podem ser classificados pelas suas multivariadas propriedades estatísticas, como é o caso da classificação multiespectral

(*clustering*), ou por segmentação baseada em estatísticas e relações espaciais com os pixels vizinhos.

As técnicas de classificação por região também podem ser divididas em supervisionada e não supervisionada. Na classificação supervisionada, para que o *software* possa efetuar a classificação, torna-se necessário que o usuário estabeleça as classes que ele deseja que sejam classificadas, orientando o aplicativo pela utilização de amostras de treinamento. No caso da classificação não supervisionada, o próprio aplicativo realiza o agrupamento das classes a partir de alguns parâmetros simples inseridos pelo usuário.

O processo de segmentação apresentado inicialmente representa a etapa que deve preceder a classificação por região. O *software* SPRING, por exemplo, inclui vários tipos de classificadores, como Iseseg, Bhattacharyya e ClaTex. O IDRISI apresenta a solução de classificação por região a partir de sua versão Taiga e o ENVI não apresentava um módulo específico para classificação por região até a versão 4.7. Tecnicamente, não existe a impossibilidade de se aplicar as técnicas de classificação supervisionada pixel a pixel, na classificação por região, utilizando o resultado da segmentação como amostras de treinamento, embora como será apresentado no final deste capítulo, os resultados possam vir a ser dramaticamente diferentes, pois a diferença mais substancial reside na forma com que os algoritmos de classificação, pixel a pixel e por regiões, são implementados.

Com relação à aplicação do modelo de classificação por região e pixel a pixel, alguns estudos demonstraram as diferenças existentes entre ambos sem, contudo, apresentar uma definição de qual deles seria a melhor alternativa. Um desses trabalhos, desenvolvido por Veronese & Gonçalves *et al.*, (2003), considerou insatisfatórios os resultados da classificação por região, tendo em vista o alto índice de confusão dos alvos urbanos e de vegetação, decorrentes da mistura espectral dentro da área do polígono. Os autores descreveram os erros enfatizando que apesar de representarem, predominantemente, uma classe espectral, na verdade os polígonos podem englobar pixels, cujo número de classes escapa ao “filtro” de similaridade, os quais irão afetar os parâmetros estatísticos e aumentar o risco de erros de classificação. Desse trabalho depreende-se que embora seja verdadeira a afirmação, o problema encontrado, muito provavelmente, não está afeto ao processo de classificação e sim à maneira como foi conduzida a segmentação. Dependendo de como são estabelecidos os limiares de similaridade e área mínima, o resultado poderá conter um número menor ou maior de polígonos. No primeiro caso isso se deve ao fato de se aceitar um maior limiar de similaridade. Em outras palavras, coisas não tão parecidas estatisticamente seriam aceitas como pertencentes a um mesmo segmento. No outro caso, ao contrário, pequenas diferenças nos valores dos pixels poderiam gerar segmentos distintos.

Outro trabalho que procurou avaliar os classificadores pixel a pixel e por região foi o de Góes *et al.*, (2006), que demonstrou que os classificadores que apresentaram o melhor desempenho, discriminando os diferentes tipos de alvos, foram aqueles que utilizaram uma imagem segmentada. O classificador Iseseg, como procedimento não supervisionado, foi considerado como o mais eficiente por apresentar uma classificação mais coerente com a verdade de campo e por dispensar o conhecimento prévio da área de estudo. Os autores descreveram que a maior dificuldade encontrada nesse tipo de classificação é a obtenção da imagem segmentada, uma vez que devem ser testados diversos limiares de segmentação até obter uma segmentação satisfatória.

Na etapa de classificação aconselha-se a utilização de uma imagem de referência já classificada, utilizando qualquer outro método, supervisionado ou não. A imagem de referência é utilizada com a finalidade de designar a classe majoritária dentro de cada segmento. Para efetuar a classificação o algoritmo aplica a regra definida pelo modelo do classificador escolhido, para determinar as diferentes classes dos alvos analisados. É importante salientar que uma classe é normalmente constituída de vários polígonos, todos

eles considerados pelo classificador como amostras de treinamento para aquela classe específica. De acordo com diversos autores, apesar de o produto dessa classificação apresentar dificuldades nos ajustes dos parâmetros para atingir bons limiares na segmentação, via de regra produz um resultado de melhor qualidade do que os obtidos pelos processos pixel a pixel.

13.3 Descrições dos Tipos de Classificadores

Serão apresentados, a título de exemplo, os classificadores disponíveis no *software* livre SPRING.

13.3.1 Isoseg

O Isoseg é um algoritmo de agrupamento de dados (não supervisionado) aplicado sobre conjuntos de regiões que foram caracterizadas por seus atributos estatísticos (média e matriz de covariância). Trata-se de uma técnica de classificação que procura agrupar regiões a partir de uma medida de similaridade entre elas. Essa medida é dada pela distância de Mahalanobis, calculada entre a classe e as regiões candidatas, como mostrado na Figura 13.6.

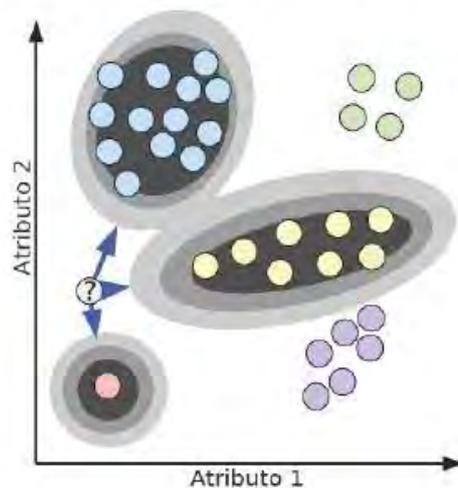


Fig. 13.6 – Distância de Mahalanobis (Fonte: Körting, 2006).

De acordo com os arquivos de ajuda incluídos na versão 5.1.7 do SPRING, em transcrição literal o classificador Isoseg utiliza os atributos estatísticos da matriz de covariância e do vetor de média das regiões, para estimar o valor central de cada classe. Os procedimentos resumem-se em:

- i. Define-se um limiar (percentagem) de aceitação. Esse limiar significa uma distância de Mahalanobis, sendo que as regiões pertencentes a alguma classe estão distantes por um valor inferior ou igual a essa distância. Inferimos que, quanto maior o limiar, maior esta distância e, conseqüentemente, menor será o número de classes detectadas pelo algoritmo;

- ii. Detecção das classes: as regiões são ordenadas em ordem decrescente de área, utilizando parâmetros estatísticos para associação das classes, para em seguida associar a essa classe todas as regiões cuja distância de Mahalanobis for inferior à distância definida pelo limiar de aceitação. Assim, a primeira classe terá como parâmetros estatísticos aquelas regiões com maior área. As classes seguintes terão parâmetros estatísticos de média das regiões de maior área que não tenham sido associadas a nenhuma das classes previamente detectadas. Essa fase repete-se até que todas as regiões tenham sido associadas a alguma classe; e
- iii. Competição entre classes: as regiões são reclassificadas, considerando-se os novos parâmetros estatísticos das classes definidos na etapa anterior.

A fase seguinte consiste basicamente na detecção de classes, sendo um processo sequencial que pode favorecer as classes que são detectadas em primeiro lugar. Com vista a eliminar este favorecimento, procede-se a "competição" entre classes. Essa competição consiste em reclassificar todas as regiões. O parâmetro estatístico média de cada classe é então recalculado. O processo repete-se até que a média das classes não se altere (convergência).

Ao término, todas as regiões estarão associadas a uma classe definida pelo algoritmo. O usuário deverá então associar essas classes às classes por ele definidas.

13.3.2 Bhattacharyya

A medida da distância de Bhattacharyya é usada para medir a separabilidade estatística entre um par de classes espectrais. Ela mede a distância média entre as distribuições de probabilidades de classes espectrais.

O classificador Bhattacharyya, diferentemente do que ocorre com o Iseseg, não realiza a classificação de forma automática, exigindo uma etapa de treinamento de acordo com as regras da classificação supervisionada. As amostras são as regiões formadas na segmentação de imagens.

O princípio é análogo ao utilizado para o classificador Iseseg. A distância Bhattacharyya é calculada pela seguinte expressão:

$$B(p_i, p_j) = \frac{1}{2} (m_1 - m_2)^T \sum (m_i - m_j) + \frac{1}{2} \ln \frac{|\sum (m_i - m_j)|}{|\sum_i|^{1/2} |\sum_j|^{1/2}}$$

eq. 13.1

sendo, B = distância de Bhattacharyya
P_i e *p_j* = pixels nas classes *i* e *j*
m_i e *m_j* = médias das classes *i* e *j*
 T = matriz transposta
 ln = logaritmo neperiano
i e *j* = classes dentro do contexto

Para melhor entendimento da distância de Bhattacharyya vale destacar inicialmente que ela não é uma distância euclidiana, que em matemática representa a distância entre dois pontos. Ela é uma distância calculada a partir da análise das médias e das covariâncias das amostras, como pode ser visto na Figura 13.7. Como demonstra a equação 13.1 a primeira operação é obtida com a diferença das médias e a segunda operação pelas médias das matrizes de covariância das duas amostras. Observando-se a parte superior da Figura 13,7, as

amostras 1 e 3 seriam as mais próximas pela distância euclidiana. Porém, pela distância de Bhattacharyya, como mostrado na porção inferior, as amostras 1 e 2 é que são mais próximas, ou seja, apresentam menor distância de Bhattacharyya.

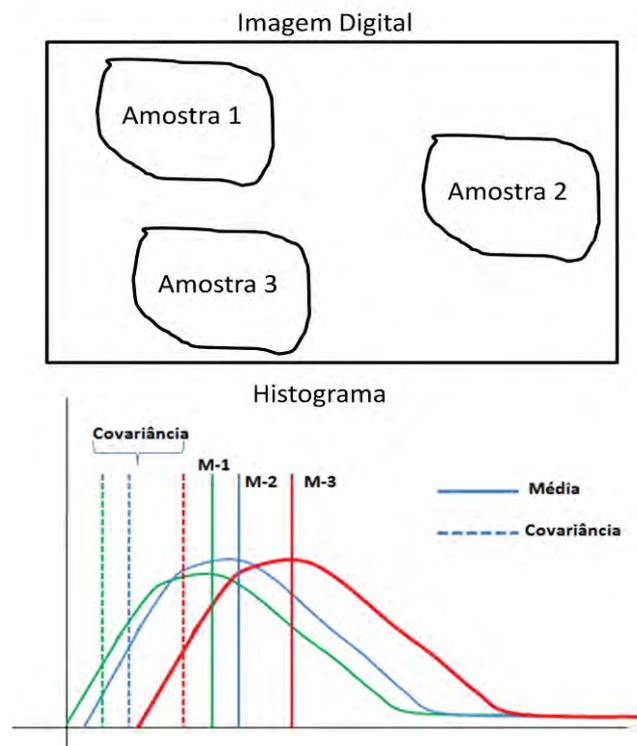


Fig. 13.7 Exemplificação da seleção de classes e histograma de análise.

13.3.3 Clatex

O classificador ClaTex é um algoritmo supervisionado que utiliza atributos texturais das regiões de uma imagem segmentada para efetuar a classificação. Ela é realizada pelo agrupamento de regiões a partir de uma medida de similaridade entre elas (distância de Mahalanobis).

13.4 Classificação Utilizando o Algoritmo Bhattacharyya

No exemplo de classificação que é apresentado na Figura 13.8, foi usada uma segmentação que utilizou um limiar de similaridade de valor 15 e uma área mínima de valor 20. Essa segmentação conseguiu contemplar de maneira bastante satisfatória a variabilidade contida na imagem, embora algumas confusões tenham ocorrido. A partir dos resultados dessa segmentação, utilizando as bandas 2, 3 e 4 do satélite IKONOS, foi realizada a classificação utilizando-se o algoritmo Bhattacharyya, na versão 5.1.7 do SPRING.

Antecedendo a classificação propriamente dita, foi realizada a seleção das amostras de treinamento. As amostras foram selecionadas por região, indicando-se os segmentos que representassem cada uma das classes: água, fragmento (florestal), pastagem, asfalto, solo

exposto e área urbanizada. A Figura 13.9 mostra os segmentos utilizados como amostras de treinamento.



Fig. 13.8 Segmentação com limiar de similaridade = 15 e área (pixels) = 20 sobre composição RGB 342.

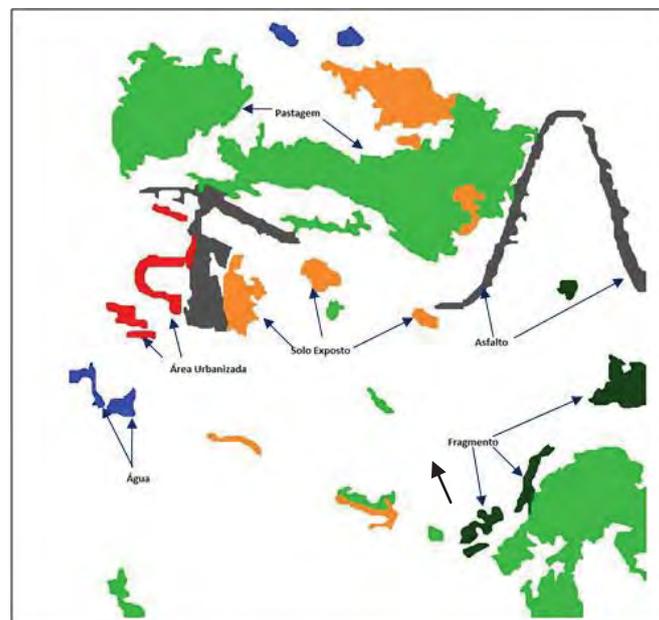


Fig. 13.9 Segmentos utilizados como amostras de treinamento para o classificador Bhattacharyya.

A Figura 13.10 mostra a classificação resultante. A fim de proporcionar meios para uma comparação de resultados dessa classificação com uma classificação pixel a pixel, as mesmas amostras de treinamento foram utilizadas em um classificador de máxima

verossimilhança (MAXVER) do aplicativo SPRING. Como mostrado na Figura 13.11, nota-se um acentuado efeito “*salt and pepper*” (sal e pimenta) e uma maior confusão entre as classes.

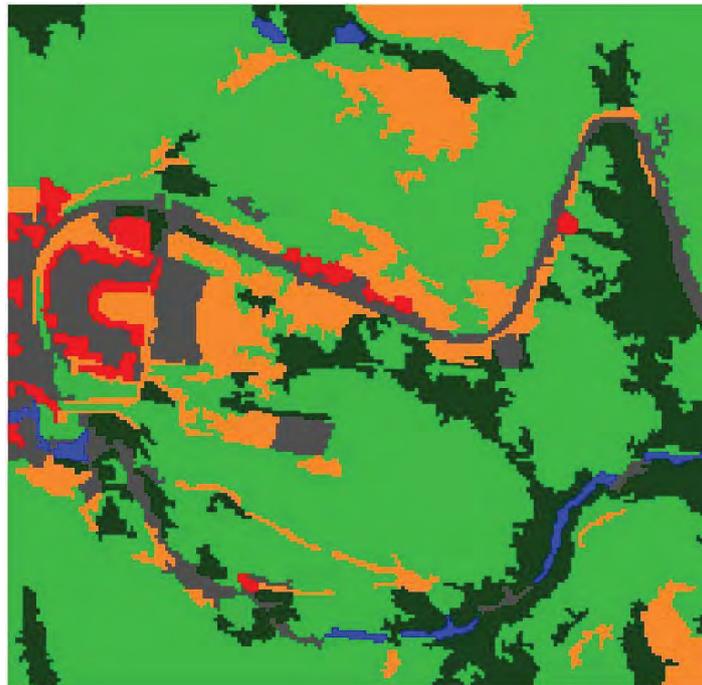


Fig. 13.10 Resultado da classificação Bhattacharyya a partir das amostras de treinamento da Figura 13.9 nas cores correspondentes.

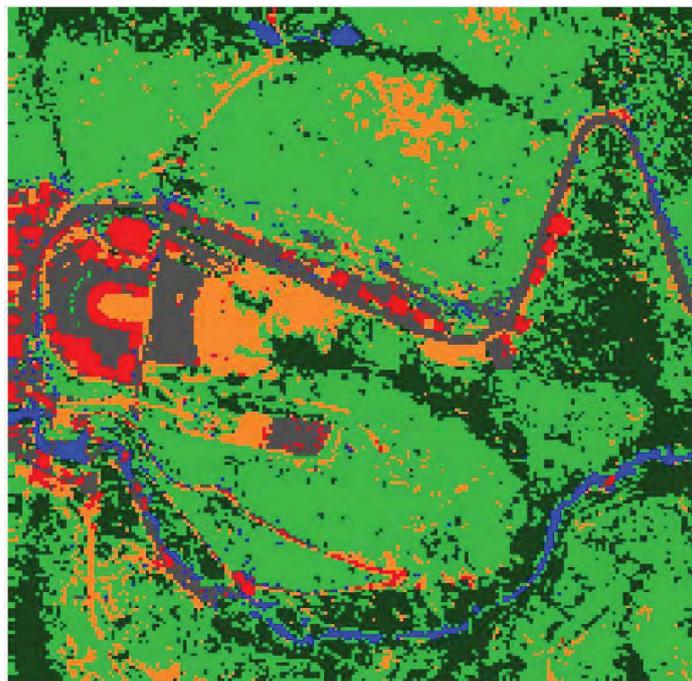


Fig. 13.11 Resultado da classificação MAXVER a partir das amostras de treinamento da Figura 13.9

Cabe mencionar a existência de outros classificadores que de certa forma demonstram as modernas tendências tecnológicas no desenvolvimento de novos algoritmos, incluindo os de natureza não-paramétrica e aqueles orientados a objetos. A título de exemplo de outras possibilidades merecem destaques os de classificação hierárquica e *fuzzy*, árvores de decisão, redes neurais e aqueles diretamente orientados a objetos. Eles estão presentes em alguns *software*, como no e-Cognition e no INTERIMAGE, esse último com a vantagem de ser um *software* livre.

A Figura 13.12 ilustra a classificação hierárquica, construída com uma estrutura de classes e subclasses por meio de uma relação de dependência subordinada ao conhecimento adquirido, podendo ser formada por regras booleanas oriundas das propriedades que compõem os objetos.



Fig. 13.12 Classificação hierárquica (Fonte: Gonçalves *et al.*, 2007).

A classificação orientada a objeto, como preceitua Darwish *et al.* (2003), permite ao usuário definir regras complexas baseadas em características espectrais e relações espaciais. Esse modelo permite que a semântica possa ser desenvolvida, apoiada em parâmetros físicos e de conhecimento sobre relacionamentos. A Figura 13.13 esquematiza como, a partir de duas distintas e abrangentes classes, vão se formando subdivisões. Há uma estreita dependência entre as classes de nível inferior e aquelas de nível superior para que a existência daquelas possa ser assegurada. Note-se na Figura 13.12 que se for tomada a classe araucária como exemplo, ela não poderia existir se não existisse a classe de nível hierárquico superior mata, e esta, por sua vez, depende da existência da classe vegetação.

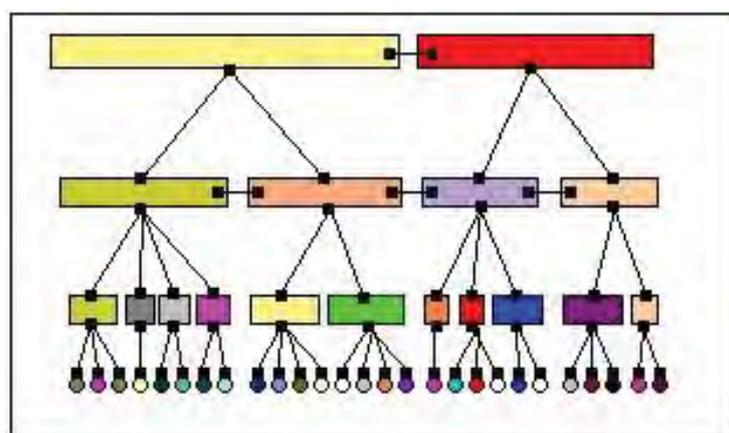


Fig. 13.13 Esquema da classificação orientada a objetos com dependência hierárquica (Fonte: Gonçalves *et al.*, 2007).

Gustavo Macedo de Mello Baptista

14.1 **Introdução**

O final do século passado foi marcado por uma das rupturas paradigmáticas mais impactantes no sensoriamento remoto: os dados hiperespectrais. Esses dados mexeram com a compreensão e os procedimentos usuais sobre processamento de imagens, pois as imagens saltaram da dimensão de algumas poucas bandas para a dimensão de centenas de bandas, contínuas no espectro da reflectância.

O objetivo do sensoriamento remoto hiperespectral é de possibilitar a extração, nas imagens, das feições espectrais de reflectância/absorção que identificam a composição dos materiais, assim como se faz da análise dos espectros de reflectância obtidos com os espectrorradiômetros. Como cada pixel da imagem tem o registro da radiância do alvo medida por centenas de bandas, um detalhado espectro de reflectância pode ser obtido de cada pixel, por processamento. Isso consiste em um processamento estritamente na análise do domínio espectral da imagem, com a ressalva de que reconhecimentos de padrões de pixels (classes) ou vizinhanças (correlações espaciais) não são considerados. Por exemplo, quando observamos nas imagens hiperespectrais uma área de solo exposto, devemos encontrar e mapear quais são os pixels que identificam a composição desse solo, o que pode ser em termos de sua composição mineral em porcentagem de hematita ou goethita, e não simplesmente se é uma classe de solo mais rica ou pobre em óxidos de ferro, que é o máximo possível do tipo de informação que se pode inferir com as imagens de sensores multiespectrais. No caso de uma rocha, teremos uma boa chance de descobrir os tipos de minerais dominantes na sua composição e assim termos uma informação mais precisa da litologia. Essa é a mudança de paradigma. Deixamos de lado a "macro" identificação dos alvos com os sensores multiespectrais, para entrarmos na quantificação de observações de caráter mais microscópicos da matéria, presentes nos espectros de cada pixel.

Pelo fato de as imagens hiperespectrais ultrapassarem duas centenas de bandas, elas tem larguras espectrais muito estreitas, normalmente da ordem de 10 nm. A combinação dessas duas características implica numa completa mudança na forma de processamento dos dados. Não cabem mais a essas imagens usar os métodos que foram apresentados nos capítulos anteriores para o processamento de imagens multiespectrais. Até para se fazer uma simples composição colorida que mostre um alto contraste dos alvos não é um processo tão simples, porque as bandas de um sensor hiperespectral possuem alta correlação espectral. Imagine também que milhares de composições coloridas poderiam ser feitas com centenas de bandas, e o tempo para interpretá-las seria algo totalmente inviável.

Neste capítulo iremos apresentar as bases para se executar os procedimentos mais comuns para o processamento dos dados hiperespectrais. Veremos que eles se baseiam na análise e interpretação dos espectros de reflectância, e para isso o analista necessita ter um conhecimento mínimo sobre os processos que dão origem às feições de absorção dos

materiais, os quais acontecem ao nível eletrônico do átomo e ao nível das vibrações das moléculas.

O conceito de sensoriamento remoto hiperespectral ou espectroscopia de imageamento, como assim é chamado, é apresentado na Figura 14.1. O AVIRIS (*Airborne Visible/Infrared Imaging Spectrometer*) é um sensor experimental aerotransportado com 224 bandas e várias faixas de imageamento foram feitas no território brasileiro, em 1995.

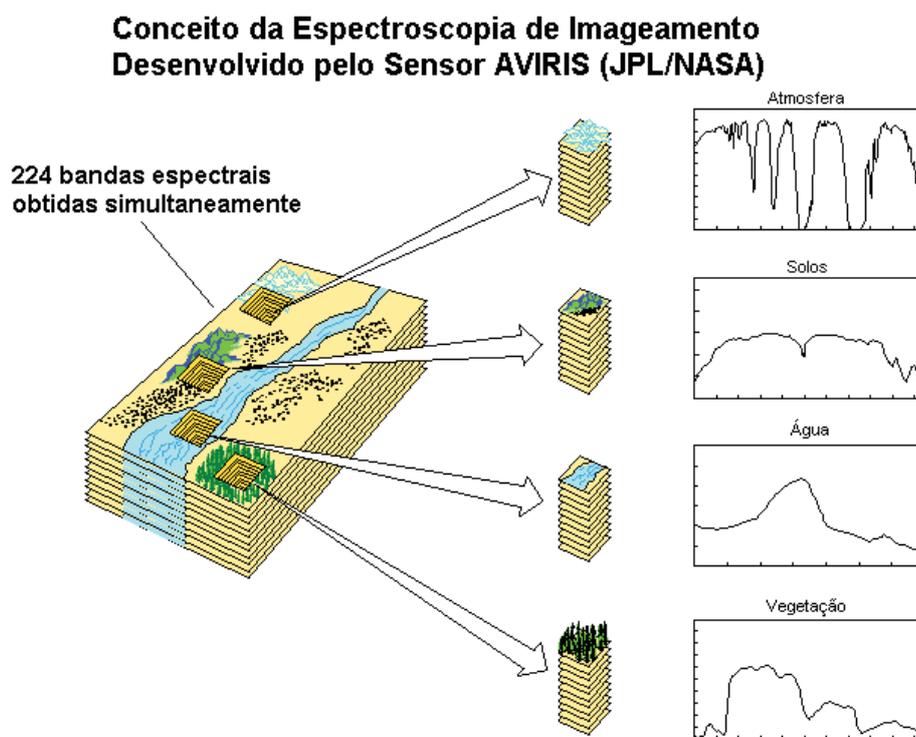


Fig. 14.1 Múltiplas imagens se superpõem possibilitando a obtenção do espectro de reflectância do alvo contido no pixel. (Adaptado de Baptista, 2006).

14.2 Correção Atmosférica dos Dados

Um dos aspectos mais controversos no processamento de dados hiperespectrais refere-se ao pré-processamento para correção dos efeitos atmosféricos e redução dos dados de radiância para a reflectância de superfície. Os algoritmos que fazem essas operações baseiam-se, normalmente, em modelos de transferência radiativa ou de radiação solar. Nesses modelos busca-se reduzir os efeitos que o espalhamento e a absorção dos gases atmosféricos causam nos dados.

De forma bem simplificada, o espalhamento é um desvio de trajetória que elementos atmosféricos causam na radiação eletromagnética, tanto no sentido descendente (irradiância) como ascendente (radiância). Esses elementos podem ser gases ou aerossóis, estes entendidos como partículas não gasosas presentes na atmosfera. As absorções que ocorrem na faixa do espectro óptico refletido (0,4 a 2,5 μm) reduzem acentuadamente a intensidade da radiação eletromagnética incidente e acabam obliterando as feições dos alvos que queremos identificar ou mesmo quantificar. No capítulo 1 foi apresentada a Figura 1.10 que mostra as regiões espectrais de absorção causadas pelos principais gases atmosféricos na faixa do espectro

óptico refletido, aos quais chamamos de gases de efeito estufa. Por meio dessa figura notamos que a quantidade de radiação que chega ao topo da atmosfera é maior que a quantidade medida no nível do mar e que essa diferença se dá basicamente pela absorção dos gases como o ozônio (O₃), o dióxido de carbono (CO₂), o vapor d'água (H₂O) e outros não destacados na figura.

O espalhamento e a absorção ocorrem concomitantemente, mas a maioria dos algoritmos de correção dos efeitos atmosféricos trata os processos de forma separada e depois os integram. Outro problema são os dados que devem ser inseridos nos algoritmos para rodá-los, principalmente quanto à visibilidade da atmosfera no momento da tomada da imagem. A visibilidade, grosso modo, é entendida como o quanto se pode ver através da atmosfera e, para tanto, alguns fatores são importantes para sua determinação. Eles incluem as propriedades ópticas da atmosfera, a quantidade de luz, sua distribuição, além dos aspectos inerentes ao objeto a ser observado, bem como as características dos sistemas sensores. Porém, normalmente esses dados não estão tão facilmente disponíveis para o analista, e quando se vai fazer a correção atmosférica da imagem, acaba-se utilizando o valor *default* que o *software* sugere para a visibilidade.

Outro aspecto salientado por Bo Cai Gao e colaboradores, autores do algoritmo de correção atmosférica ATREM, é que por causa da variabilidade da concentração do vapor d'água em função da hora de obtenção da imagem e da altitude do sensor, não é possível remover completamente seus efeitos no procedimento de redução dos dados de radiância para reflectância, utilizando os modelos de correção atmosférica atualmente em uso.

Porém, criou-se um dogma de fé de que não se pode utilizar dados hiperespectrais sem antes corrigir os efeitos atmosféricos. Estudos recentes apontam que problemas de correção atmosférica podem mascarar resultados, principalmente quando as feições de água a 1,4 e a 1,9 μm não são bem removidas. Além disso, estudos comparativos na aplicação de índices espectrais para a determinação de relações mineralógicas em solos, tanto em dados corrigidos como em dados brutos de radiância, não apresentaram diferenças significativas quando comparados com os valores obtidos analiticamente em laboratório.

Os algoritmos mais usuais disponíveis para correção atmosférica são o método Green, o ATREM, o FLAASH e o ACORN. O método Green, desenvolvido por Robert Green, investigador responsável pelo sistema AVIRIS, roda em plataforma UNIX e seu tempo de processamento é muito longo. O ATREM foi desenvolvido pela Universidade do Colorado e é bem mais rápido em termos de processamento. Teve um ajuste para o software ENVI para versão 3.2 e roda também em Windows. O FLAASH é um algoritmo também de processamento rápido e é comercializado como um módulo à parte para o ENVI. O ACORN é também um software comercial.

Praticamente todos eles se baseiam em ajustes do tipo mínimos quadrados associados a um modelo de transferência radiativa como o apresentado a seguir.

$$LO(\lambda) = Lsun(\lambda) \times T(\lambda) \times R(\lambda) \times \cos(\theta) + Lpath(\lambda)$$

eq. 14.1

onde, $LO(\lambda)$ = radiância observado no nível do sensor;
 $Lsun(\lambda)$ = radiância solar acima da atmosfera;
 $T(\lambda)$ = transmitância total atmosférica;
 $R(\lambda)$ = reflectância de superfície;
 θ = ângulo de incidência;
 $Lpath(\lambda)$ = radiância de trajetória espalhada

Para exemplificar os diferentes métodos de correção atmosférica apresentamos na Figura 14.2 espectros de reflectância obtidos a partir de um mesmo pixel da cena AVIRIS do

município de São João D'Aliança em Goiás, obtida no âmbito da missão SCAR-B de 1995. O espectro “a” representa o método de correção atmosférica Green, o “b” representa o ATREM e o “c”, o FLAASH.

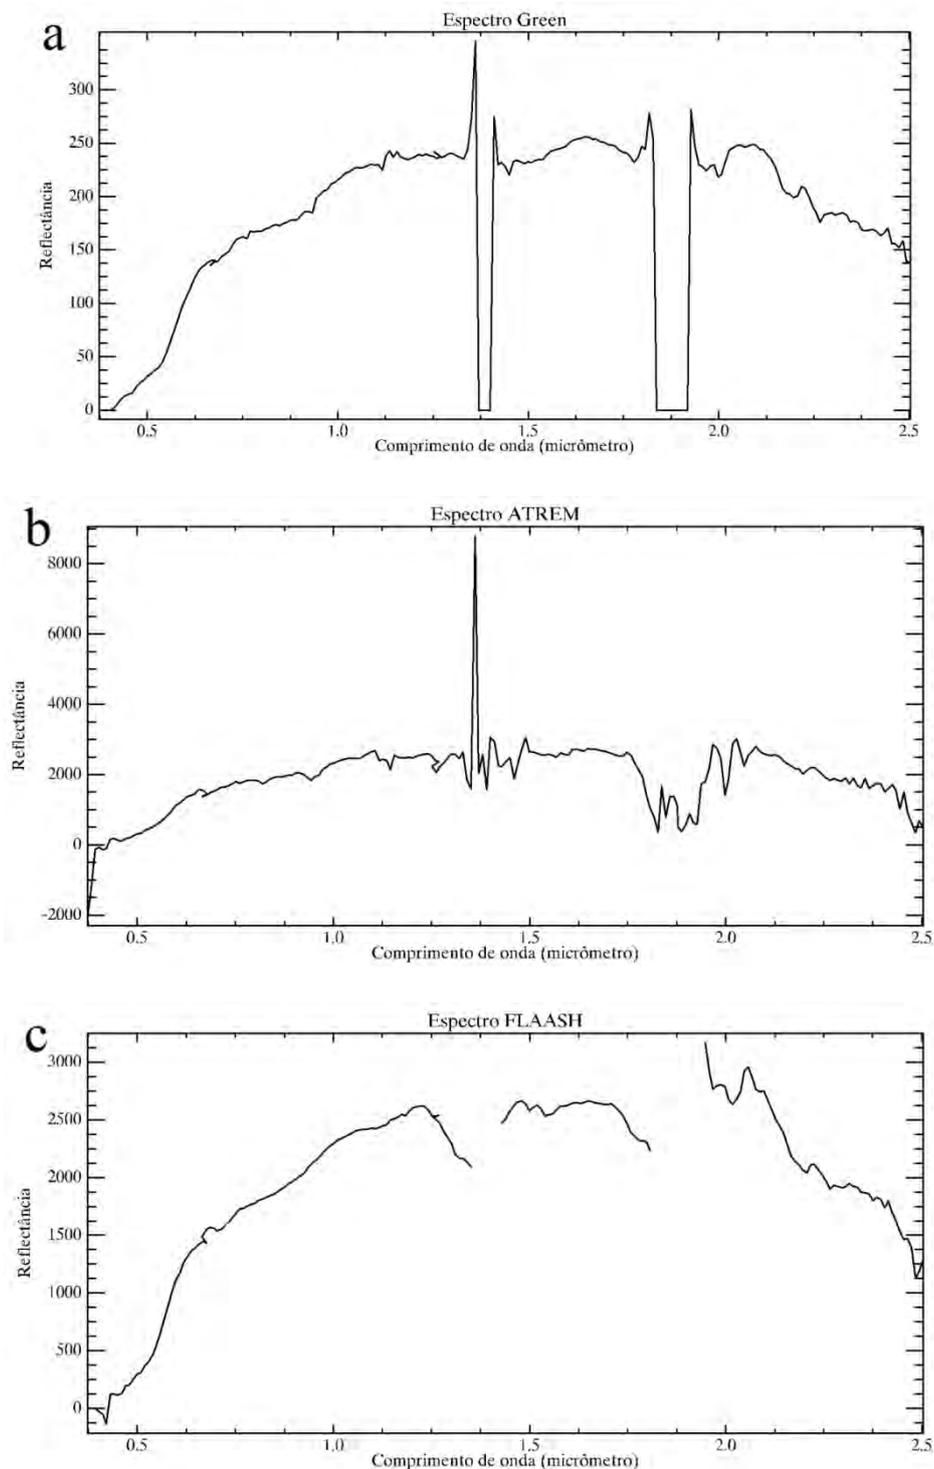


Fig. 14.2 Espectros de reflectância de um pixel de solo extraído de uma cena AVIRIS após correção atmosférica pelos métodos a) de Green; b) ATREM; c) FLAASH.

Os espectros obtidos pelo método Green e FLAASH removem as bandas de absorção da água localizadas em 1,4 μm e 1,9 μm , enquanto o ATREM, na tentativa de removê-las acaba criando um ruído nesses dois locais. As feições de absorção da caulinita (2,205 μm) e a da gibbsita (2,265 μm) aparecem nos três espectros, porém é no método Green que sua visualização é mais privilegiada, seguido do FLAASH, e o ATREM apresenta um espectro mais ruidoso que dificulta a identificação direta da gibbsita, ou seja, sem a necessidade de remoção do contínuo espectral, que será abordado posteriormente neste capítulo. As ombreiras dos sesquióxidos de ferro aparecem nos três espectros, mas a pior visualização é no espectro obtido pelo método ATREM, seguido do Green, e a melhor visualização aparece no FLAASH. Essas constatações foram verificadas nesses espectros e não devem ser adotadas como regra geral.

O aspecto mais intrigante nessa análise são as escalas em valores relativos à reflectância. O espectro Green variou de 0 a 350; o ATREM de -2030 a 8800 e o FLAASH de -130 a 2300. É uma discrepância muito grande para uma mesma cena submetida a condições atmosféricas de um dia de céu claro sem nuvens, ou seja, sem espalhamento não seletivo. O que mudou foram os algoritmos de correção atmosférica.

A maioria dos trabalhos utiliza a correção atmosférica como uma forma de reduzir os dados brutos de radiância para dados de reflectância de superfície, para facilitar a identificação das feições nos espectros. Porém existem alguns procedimentos de pré-processamento que permitem essa transformação sem alterar os efeitos de espalhamento e absorção e quanto mais informações espectrais desejamos, menos devemos alterar nossos dados originais. Vamos tratar rapidamente de três métodos disponíveis para esse tipo de calibração visando à transformação dos dados em reflectância aparente: o *Flat Field*, o *Internal Average Relative Reflectance (IARR)* e o *Empirical Line*.

O *Flat Field* consiste num método simples de normalização dos dados de radiância para reflectância aparente baseado numa área plana sem grandes variações de reflectância (areias de uma praia), ou seja, a mais homogênea possível ou a mais uniforme espectralmente. O espectro médio de radiância dessa área é entendido como sendo composto basicamente de efeitos atmosféricos e da irradiância solar, e para a correção divide-se o espectro de cada pixel pelo espectro médio. O resultado dessa divisão é a reflectância aparente e que pode ser comparada aos *endmembers* de bibliotecas espectrais.

O IARR (*internal average relative reflectance*) é um método de normalização muito semelhante ao *Flat Field*. Parte do pressuposto que há ausência na cena de uma área espectralmente uniforme e brilhante e, portanto, ele pega o espectro médio de toda a cena e o adota como referência, dividindo todos os pixels da cena por ele. Ele tem apresentado bons resultados em regiões secas e com pouca vegetação, o que o torna mais problemático para uso em regiões intertropicais.

Já o *Empirical Line* é mais complexo, sendo utilizado para coincidir os dados da imagem com os *endmembers* coletados no campo. Portanto, ele requer um conhecimento da região imageada e que dois ou mais alvos sejam identificados na cena e seus espectros obtidos *in situ*. A partir de regressão linear dos espectros de campo sobre os da cena, determinam-se os ganhos e *offsets* e a partir de uma transformação linear os dados de radiância são convertidos para reflectância aparente, banda a banda, pixel a pixel.

14.3 Bibliotecas Espectrais

No processamento de dados hiperespectrais é muito comum a busca das feições espectrais de absorção dos alvos a serem investigados e a sua comparação com espectros

conhecidos desses alvos, que passam a ser chamados de *endmembers*, termo que é atribuído às referências que serão investigadas nas cenas. Se, por exemplo, procuramos pela existência nas imagens de pixels de caulinita, devemos primeiro investigar as feições de absorção que esse mineral apresenta. Na caulinita ($\text{Al}_2\text{Si}_2\text{O}_5(\text{OH})_4$), suas principais absorções ocorrem devido às harmônicas de alongamentos de ligação ($2\nu_1$) em $1,4 \mu\text{m}$ e às combinações envolvendo o alongamento de OH^- e as curvaturas de ligação entre Al-OH ($\nu_1 + \nu_3$), em $2,2 \mu\text{m}$ aproximadamente (Hlavay et al., 1977). A feição em $1,4 \mu\text{m}$ acaba se misturando à feição da água e, portanto, não deve ser investigada, mas a centrada em $2,2 \mu\text{m}$ é uma feição dupla diagnóstica da caulinita que é facilmente identificada, como pode ser observada no espectro da Figura 14.3. Esse espectro é considerado um *endmember*, pois é a referência que deverá ser utilizada para identificar os pixels que apresentam, em seus espectros, feições de caulinita.

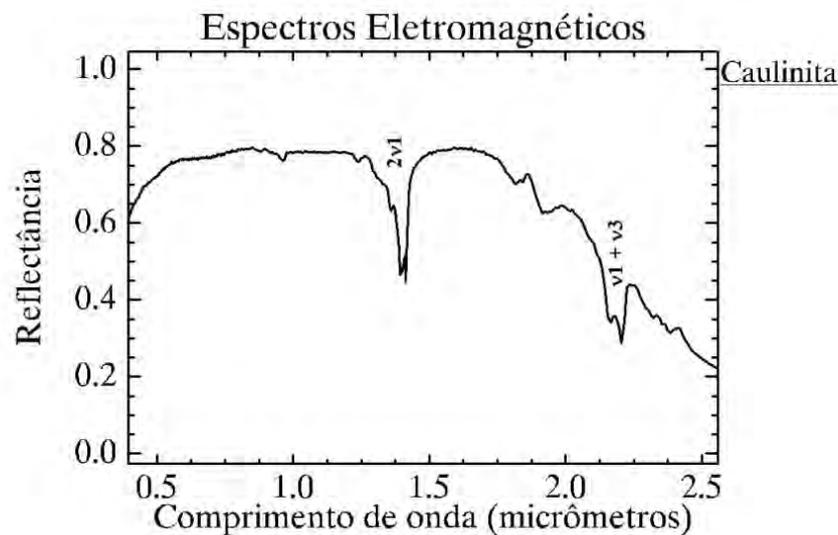


Fig. 14.3 Espectro de reflectância da caulinita (CM9 da biblioteca do USGS - Clark et al., 1993).

As bibliotecas espectrais armazenam uma quantidade de espectros que podem ser obtidos tanto em medidas em campo, como em laboratório, bem como nos chamados “pixels puros” na imagem.

A maioria dos *softwares* que processam dados hiperespectrais apresenta módulos de construção e de processamento de bibliotecas espectrais. O procedimento é geralmente muito simples e os espectros são inseridos a partir de arquivos ASCII ou em formato de texto sem formatações especiais. Normalmente apresentam uma coluna para os comprimentos de onda e outra coluna com os valores de radiância ou de reflectância, dependendo do tipo de informação levantada. Os arquivos mais completos apresentam ainda a amplitude de cada banda definida pela largura à meia altura (FWHM). Essa informação considera que a função de resposta espectral da banda é gaussiana e que sua amplitude seria a medida da largura da área abaixo da função determinada na metade da altura da crista da função, como apresentado na Figura 14.4.

Outro aspecto de relevância para os sistemas hiperespectrais reside na possibilidade de simular outros sistemas sensores muito antes de estarem operacionais. Isso porque, tanto as imagens quanto os espectros, podem ser reamostrados desde que se disponha das funções de resposta dos ganhos dos detectores (ideal) ou simplesmente o valor central da banda do

sistema a ser simulado. A Figura 14.5 apresenta as funções de resposta de ganho dos detectores do sistema ASTER.

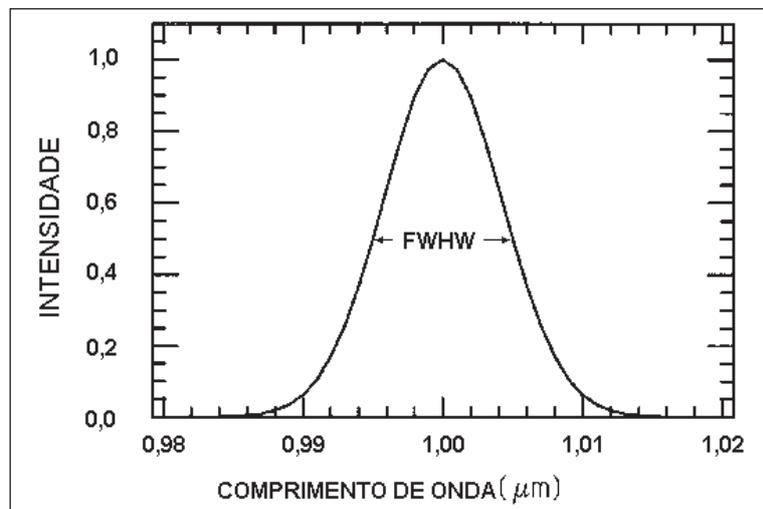


Fig. 14.4 Perfil gaussiano da função de distribuição dos detectores de uma banda genérica com a largura a meia altura (FWHM) de 10 nm. Modificado de Clark (1999).

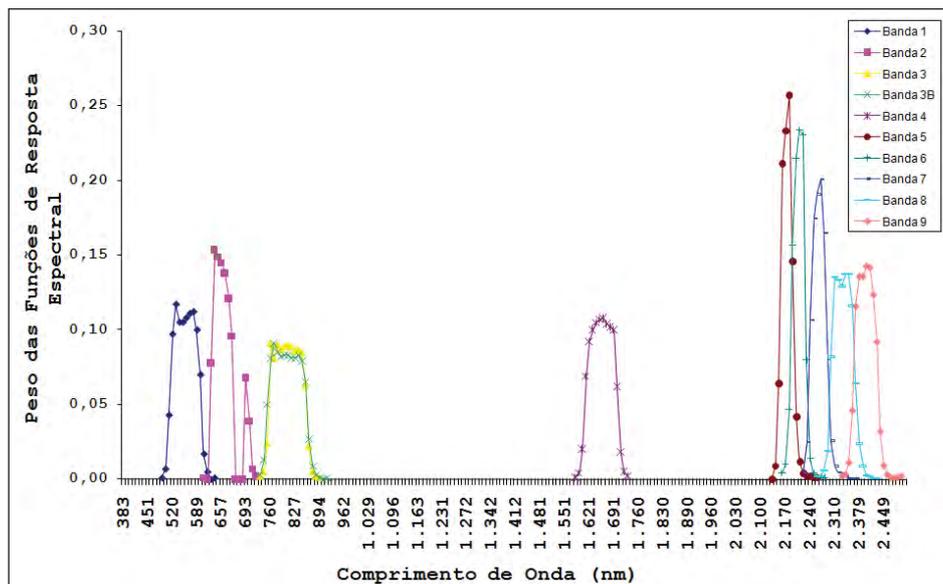


Fig. 14.5 Função de resposta de ganho dos detectores dos sensores VNIR (*Visible and NearInfraRed*) e SWIR (*Short Wave InfraRed*) do sistema ASTER.

Como podemos notar as funções nem sempre se apresentam como gaussiânicas e por isso, ao se utilizar as funções de ganhos dos detectores, a simulação é mais perfeita. Porém, nem sempre esses dados são disponibilizados para os usuários em geral, e a solução mais eficiente é simular com o valor central das bandas, mais facilmente obtido.

O exemplo a seguir, das Figuras 14.6 à 14.9, mostra a simulação de cinco espectros de solos reamostrados para os sistemas Landsat, ALOS, ASTER e Hymap.

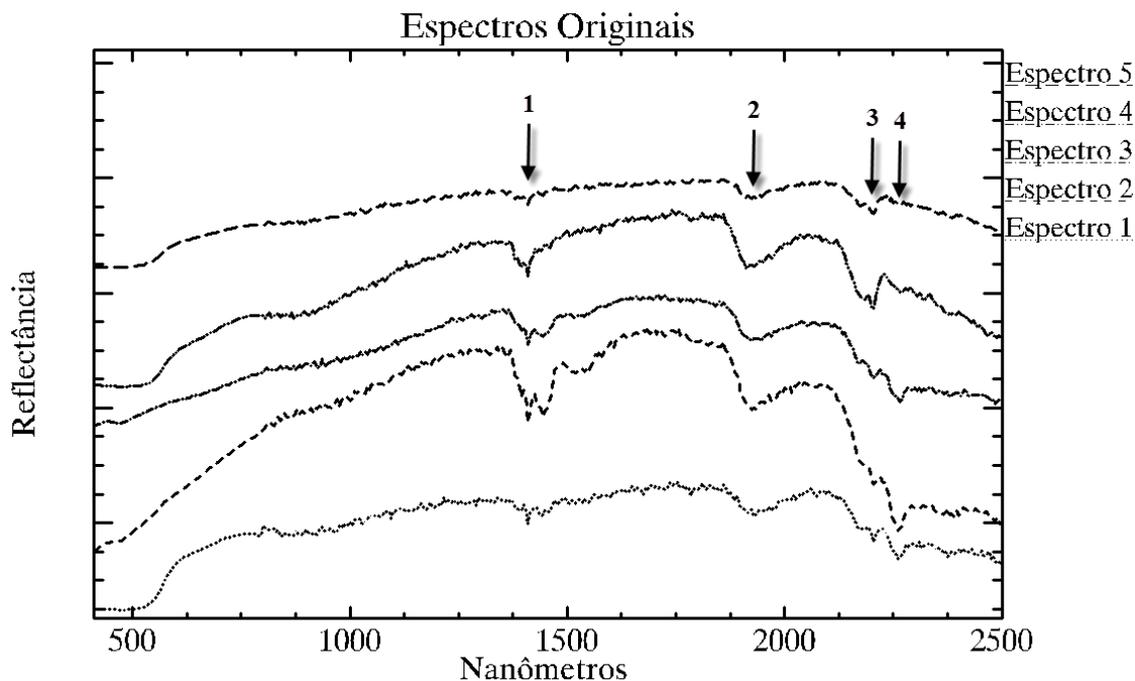


Fig. 14.6 Espectros de solos obtidos com o espectrorradiômetro GER-IRIS da Embrapa Cerrados. Cortesia de Madeira Netto.

Podemos notar na Figura 14.6 que todos os cinco espectros contém as duas feições de absorção típicas da água, em 1400 nm (1) e 1900 nm (2), com maior ou menor intensidade. Em 2200 nm (3) há a mesma dupla feição que vimos na Figura 14.3 e que indica a presença da caulinita. Já em 2265 nm (4) encontramos outra feição típica de solos tropicais decorrente da presença de gibbsita ($\text{Al}_2\text{O}_3 \cdot 3\text{H}_2\text{O}$), e que são identificadas nos espectros 1, 2 e 3. As ombreiras que aparecem por volta de 500 nm até 1000 nm são decorrentes da presença de sesquióxidos de ferro, no caso, hematita e goethita. Esses espectros apresentam 419 pontos de medidas, o que num dado hiperespectral corresponderia a 419 bandas.

Visando simular esses espectros para as respostas de ganho dos detectores do sensor ETM do satélite Landsat se obtém espectros multiespectrais (Figura. 14.7) que obliteram as feições destacadas na Figura 4.16. Isso decorre pelo fato de as seis bandas do Landsat serem largas e não serem contínuas ao longo do intervalo espectral do visível ao infravermelho de ondas curtas. O impedimento da atmosfera de permitir que qualquer sensor possa ter bandas em torno de 1400 nm e 2900 nm elimina nos espectros reamostrados as feições decorrentes da presença de água (1 e 2). Outro problema verificado é que como as feições da caulinita e da gibbsita encontram-se integradas na banda 7 (2080 nm a 2350 nm), suas identificações tornam-se impossíveis. Esses espectros apresentam seis pontos correspondentes às seis bandas desse sensor.

Com sensor SWIR do ASTER é possível identificar as feições da caulinita (1) e da gibbsita (2), mesmo que os dados sejam multiespectrais, porque no intervalo correspondente à largura da banda 7 do Landsat, nesse sensor foram colocadas cinco bandas. O espectro 1 apresenta as duas feições de absorção. Mas, como no sensor VNIR não existe uma banda que

contemple o intervalo correspondente à faixa do azul, as ombreiras a partir de 400 nm até 560 nm não aparecem, como pode ser visto nos espectros da Figura 14.8. Ao todo, esses espectros apresentam nove bandas (três bandas VNIR e seis bandas SWIR).

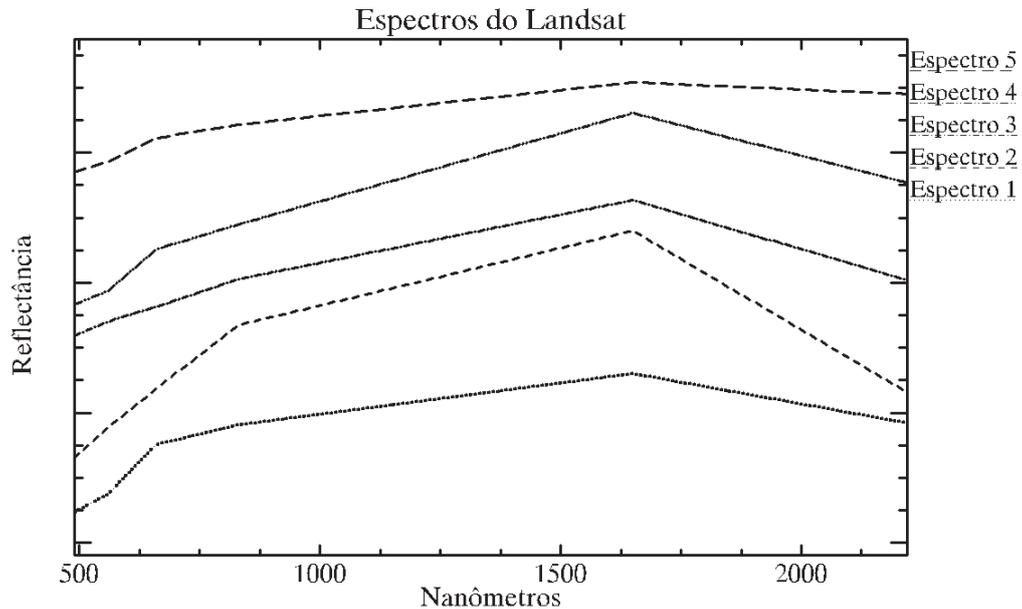


Fig. 14.7 Espectros dos solos da figura 14.6 reamostrados para as bandas do sensor ETM do Landsat.

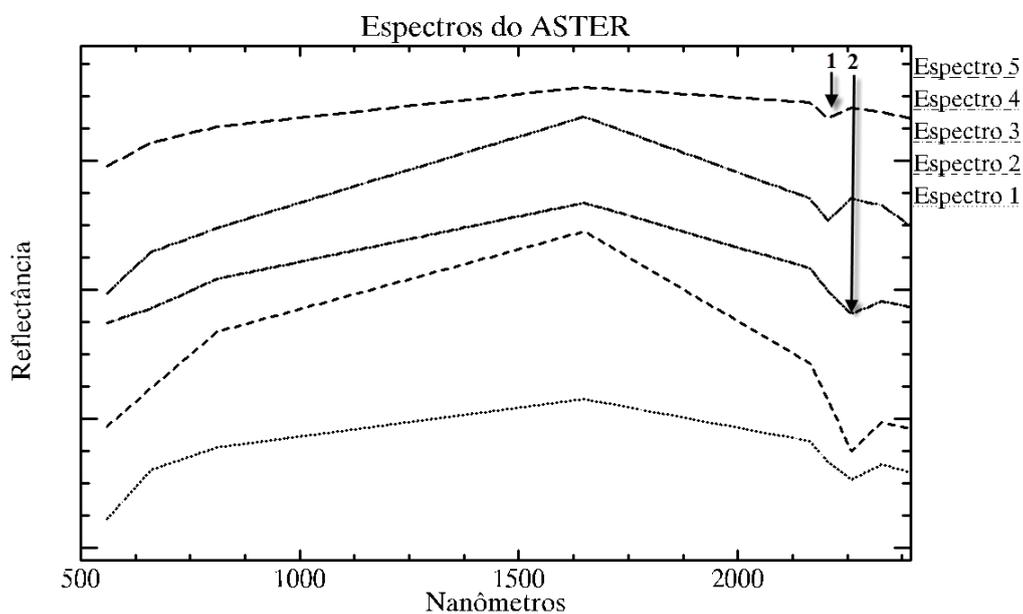


Fig. 14.8 Espectros de solos da Figura 14.6 reamostrados para os sensores VNIR e SWIR do sistema ASTER.

O sistema AVNIR2 do ALOS possui quatro bandas similares às quatro primeiras bandas do Landsat, ou seja, recobrendo a faixa do visível e do infravermelho próximo. Somente as feições dos sesquióxidos são identificadas e as vibrações moleculares que ocorrem a partir de 1,0 μm não são contempladas. A Figura 14.9 apresenta os cinco espectros reamostrados para as bandas do sensor AVNIR2 do ALOS.

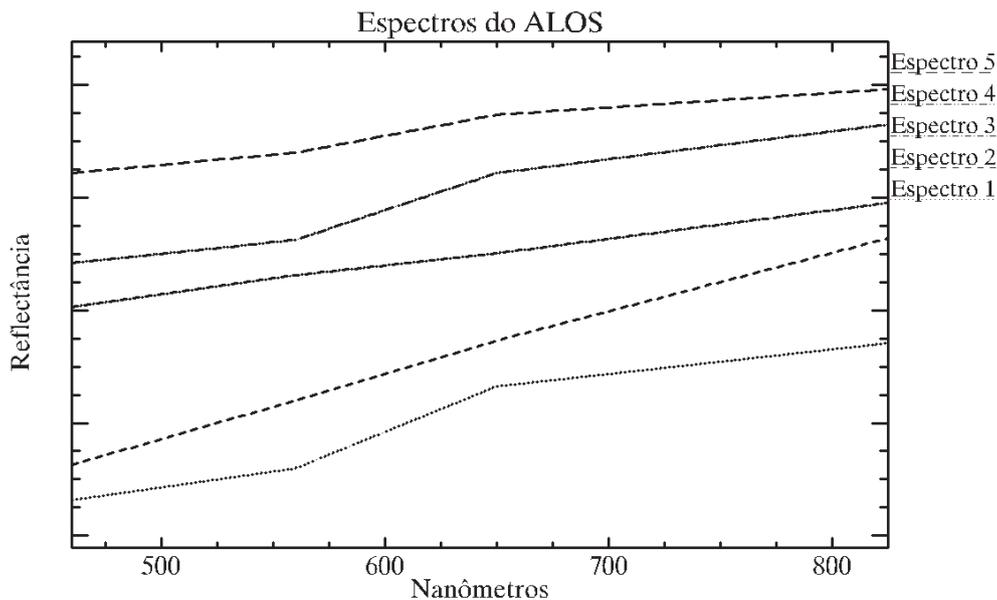


Fig.14.9 Espectros de solos da Figura 14.6 reamostrados para o sensor AVNIR2 do sistema ALOS.

Mas não apenas sistemas multiespectrais podem ser simulados. Outros sistemas hiperspectrais também podem. Isso traz facilidades, pois nem sempre temos de imediato as cenas de nossa área de estudo e podemos assim antecipar o trabalho realizando coletas de amostras em campo. E ao obter os espectros das amostras coletadas, eles podem ser reamostrados para o sistema sensor que irá imagear a área, e podemos prever como o sensor irá “ver” os alvos que foram amostrados. Um exemplo disso é apresentado na Figura 14.10 na qual simulou-se o sensor aerotransportado australiano Hymap para os cinco espectros originais apresentados na Figura 14.6. Esses espectros apresentam 419 bandas no seu formato original, porém o Hymap possui 125 bandas, o que gera espectros com menor precisão quanto aos pontos de inflexão das feições espectrais, mas vemos que elas estão presentes, como as da caulinita (1), da gibbsita (2), bem como as ombreiras decorrentes das transições eletrônicas do ferro (3 e 4). Além disso, por apresentar espectros contíguos, as feições decorrentes da presença de água centradas a 1400 nm e em 1900 nm são detectadas.

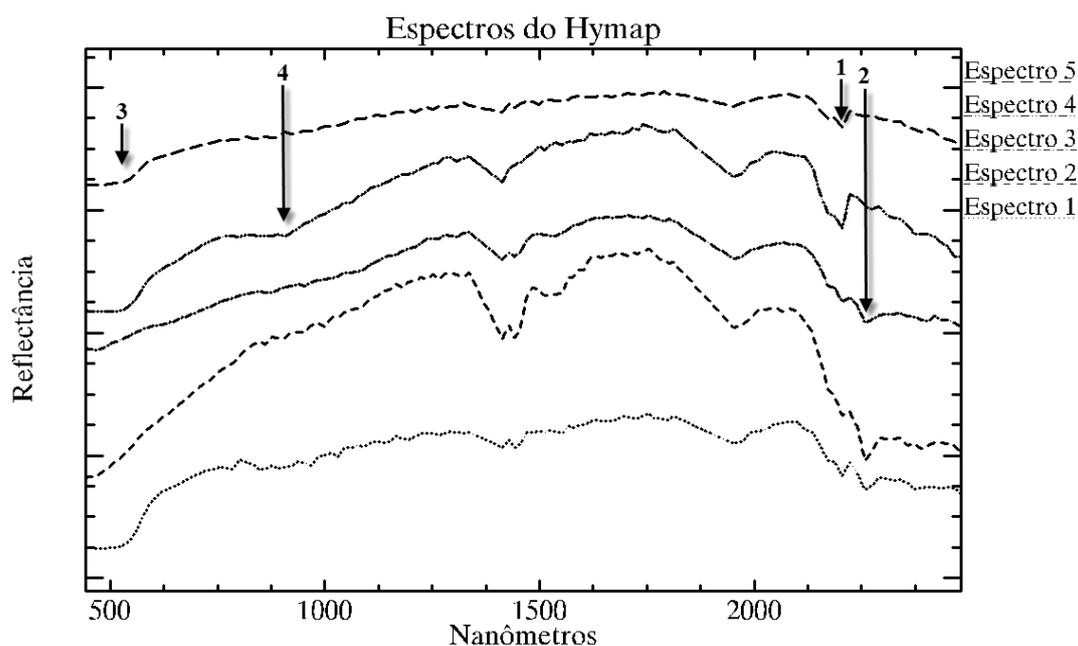


Fig. 14.10 – Espectros de solos da figura 14.6 reamostrados para o sensor aerotransportado Hymap.

14.4 Identificação de *Endmembers*

Além da simulação de sistemas sensores, os dados hiperespectrais permitem a identificação de espectros de referência, os *endmembers*. Para tal, é necessário reduzir a dimensão dos dados, pois com centenas de bandas sempre haverá alta correlação espectral.

O procedimento adotado para atingir esses objetivos é chamado de *Minimum Noise Fraction* ou MNF. O MNF é um procedimento baseado na Análise de Componentes Principais (ACP ou PCA em inglês) e, além de reduzir a dimensionalidade dos dados permite a remoção do ruído e a demanda computacional, por meio de duas transformações. A primeira baseia-se na matriz de covariância do ruído e, por meio de descorrelação, o reescala. A segunda transformação ocorre após a remoção do ruído e baseia-se na PCA dos dados. A dimensionalidade dos dados é avaliada a partir do gráfico de autovalores (*eigenvalues*) (Figura 14.11). O exemplo utilizado é baseado em uma cena AVIRIS com cinquenta bandas a partir de 2200 nm, da região de Cuprite no estado de Nevada, Estados Unidos.

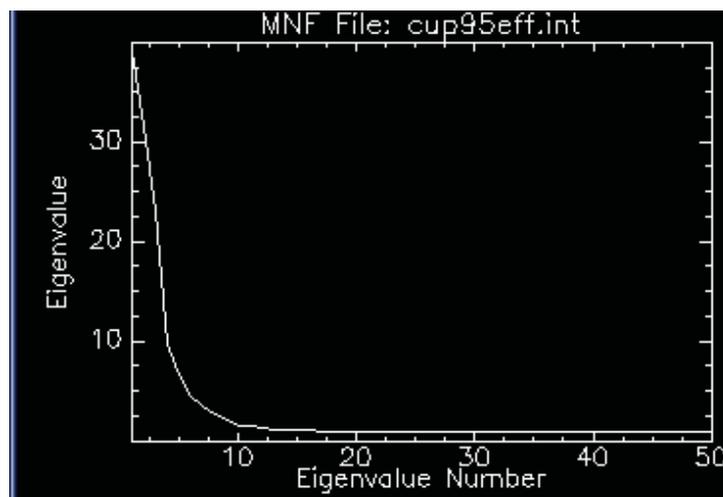


Fig.14.11 – Gráfico de autovalores obtidos a partir da transformação MNF de cinquenta bandas do sensor AVARIS.

No processamento por PCA, o número de bandas de entrada é igual ao número de MNF geradas. Como nesse caso foram cinquenta bandas, temos 50 MNF. Note que depois da MNF 10 os autovalores baixam significativamente e a partir de então considera-se haver basicamente ruído. Podemos trabalhar com 10 MNFs reduzindo em 1/5 a dimensão desses dados, o que agiliza o processamento. A Figura 14.12 apresenta uma composição colorida com as três primeiras MNFs da cena de Cuprite, apresentando a diversidade mineralógica característica da área.



Fig. 14.12 Composição colorida com as três primeiras MNFs geradas de cinquenta bandas do AVARIS da região de Cuprite, estado de Nevada.

De posse dessas dez MNFs pode-se realizar o procedimento inverso, ou seja, de MNF para as bandas em separado, removendo-se assim o ruído dos dados. Porém, para a determinação dos *endmembers* não há a necessidade de realizar esse procedimento inverso. Basta apenas utilizar as dez imagens MNFs para encontrar os pixels puros existentes na cena (*Pixel Purity Index*)

Esse procedimento de Índice de Pixel Puro baseia-se num processo iterativo de geometria convexa e ocorre banda a banda. Cada vez que um pixel aparece no extremo do escaterograma (ou dispersograma) n-dimensional, ele é marcado. A imagem resultante apresenta os pixels brancos que foram marcados e seu valor corresponde em quantas vezes ele foi considerado como extremo. O restante da cena apresenta-se com cor preta que representa os pixels não puros ou pixels misturas, como se pode ver na Figura 14.13.

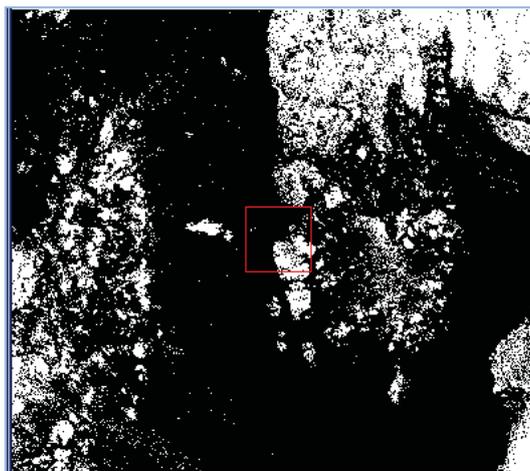


Fig. 14.13 Imagem PPI mostrando em branco os pixels puros, após 10.000 iterações.

Ao selecionarmos todos os pixels diferentes de zero estaremos selecionando os chamados pixels puros e se os exportarmos para o visualizador n-dimensional poderemos identificar os *clusters* ou nuvens de pixels que representam os agrupamentos de pixels espectralmente similares (Figura 14.14). Nesta figura, o escatergrama refere-se às imagens de reflectância, ou seja, as que foram utilizadas para determinar os MNFs.

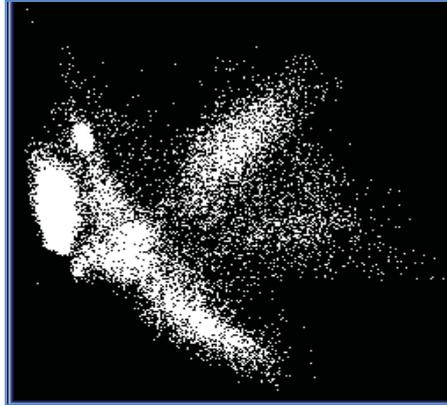


Fig. 14.14 Escatergrama n-dimensional das bandas de reflectância apresentando apenas o comportamento dos pixels puros.

Como esse espaço apresenta mais de duas bandas ele pode ser rotacionado, facilitando a identificação e demarcação dos agrupamentos (*clusters*). A Figura 14.15 mostra a seleção de vários *clusters*, um para cada cor, e a posterior exportação dos mesmos sobre uma imagem de composição colorida de bandas originais de reflectância, a fim de demonstrar as diferenças minerais existentes na área.

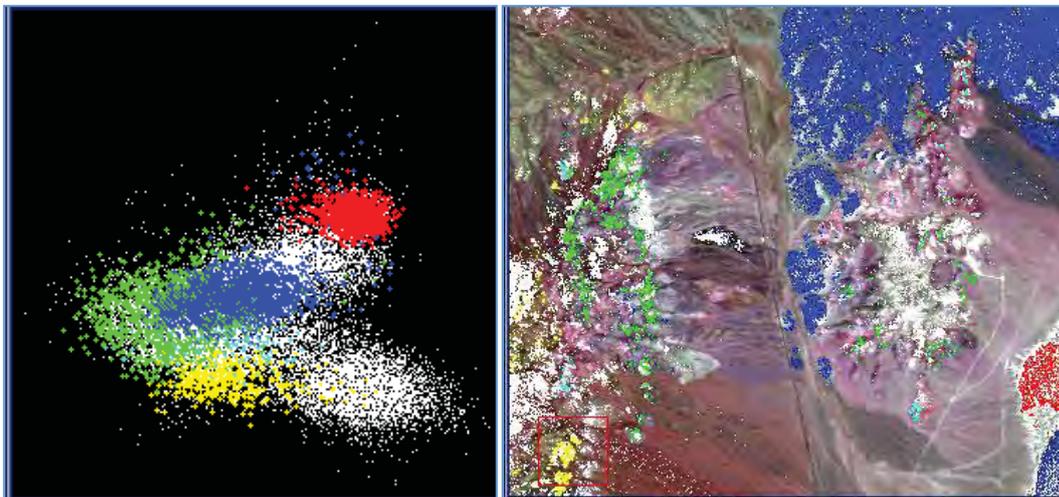


Fig. 14.15 À esquerda escatergrama n-dimensional com os clusters selecionados e à direita eles exportados para as imagens de reflectância, separando os diversos minerais existentes em Cuprite.

Se obtivermos os espectros dos pixels que foram exportados, ou seja, dos pixels ditos puros, estaremos extraindo os *endmembers* a partir da imagem conforme pode ser observado na Figura 14.16, na qual selecionou-se a caulinita, cuja localização coincide com os mapeamentos de campo.

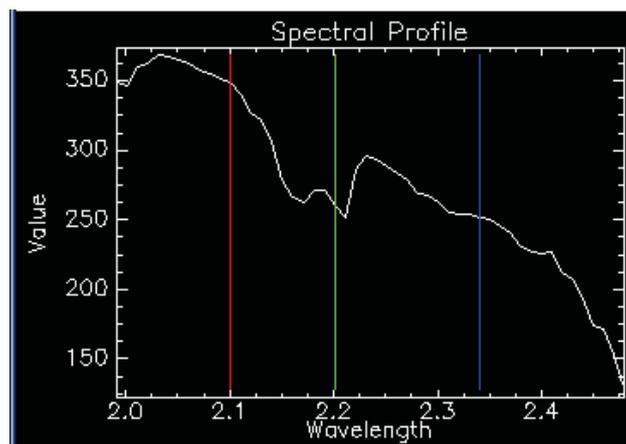


Fig. 14.16 Espectro do *Endmember* de caulinita selecionado a partir da análise de PPI na cena de Cuprite, imagem acima, e o zoom da área.

14.5 Medição de Intensidade das Feições Espectrais

A maioria dos alvos imageados guarda uma relação linear entre a intensidade da absorção e o conteúdo da matéria que lhe deu origem. Por isso, é possível estimar os conteúdos dos materiais por meio das medições das intensidades das absorções. Um dos procedimentos mais simples para fazer isso é por meio de uma operação denominada de remoção do contínuo espectral. Essa remoção consiste numa normalização dos espectros de reflectância a partir de uma linha de base comum que deve tangenciar ao máximo a curva espectral. A Figura 14.17 apresenta a lógica da remoção do contínuo espectral.

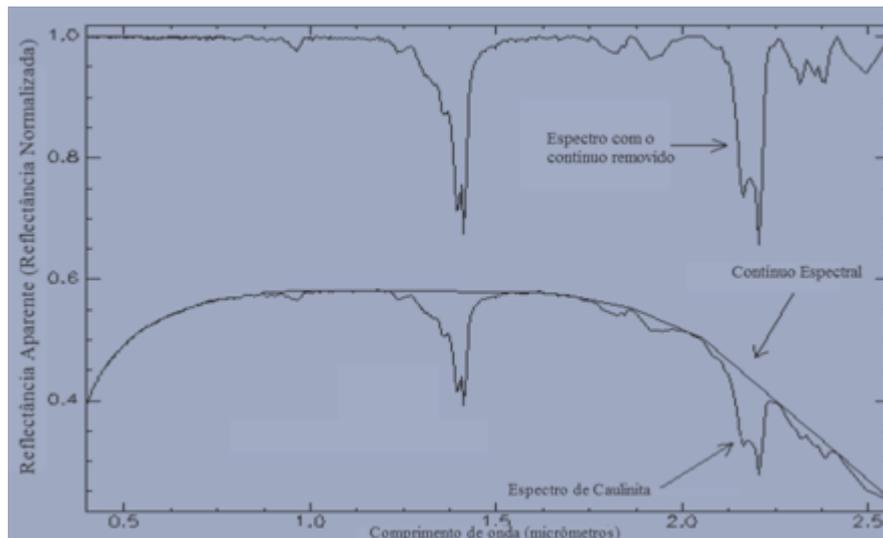


Fig. 14.17 – Conceito de remoção do contínuo espectral, usando como exemplo o espectro da caulinita.

Para determinar a intensidade da feição de absorção pode-se adotar o procedimento descrito pela equação abaixo, como se vê para a absorção da caulinita na Figura 14.18.

$$D = 1 - R'$$

eq. 14.2

onde, D = profundidade da banda de absorção

R' = valor de reflectância correspondente ao ponto de absorção no espectro com o contínuo removido

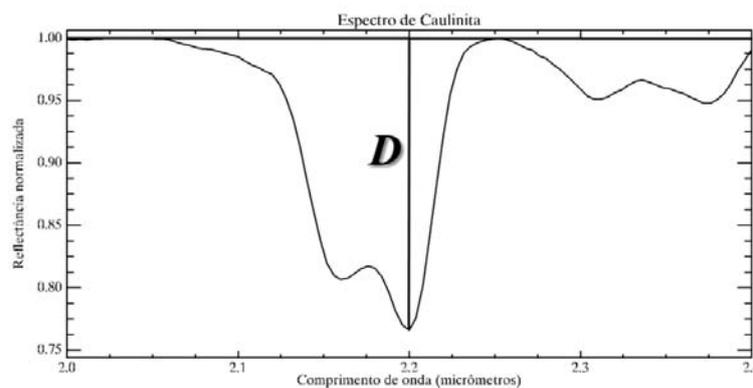


Fig. 14.18 Conceito de profundidade de absorção ou *band depth* a partir de espectro com remoção do contínuo.

No caso desse espectro em específico a intensidade da feição seria de 0,23422, lembrando que esse dado é adimensional, pois os espectros foram normalizados de 0 a 1. Pode-se supor que a feição apresenta 23,4 % de intensidade se comparada com uma feição que apresentasse intensidade variando de 0 a 1.

Porém, quando a banda de absorção é dupla, como é o caso da caulinita, o procedimento anterior considera a feição de maior intensidade. Mas ao se utilizar álgebra de

bandas é possível contemplar as duas feições, por meio de sua média. Ou seja, no caso da caulinita o procedimento para estimar a intensidade de sua feição pode ser obtido da seguinte forma:

$$\bar{D} = \left[\left(\frac{b1 + b2}{2} \right) - \left(\frac{b3 + b4}{2} \right) \right]$$

eq. 14.3

onde, \bar{D} = profundidade média da feição de absorção da caulinita;
 $b1$ = banda referente ao início da feição localizada a 2,05 μm ;
 $b2$ = banda referente ao final da feição localizada a 2,25 μm ;
 $b3$ = banda referente à primeira absorção centrada a 2,16 μm ;
 $b4$ = banda referente à segunda absorção centrada a 2,20 μm ;

A Figura 14.19 ilustra a lógica de determinação da profundidade média de feições que apresentam mais de um ponto de inflexão, como a da caulinita.

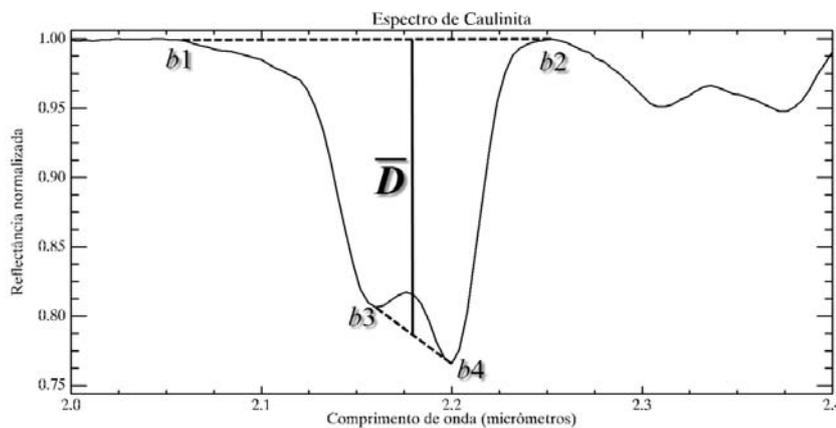


Fig. 14.19 Conceito de profundidade média de feição espectral dupla de acordo com a eq. 14.3.

Existe uma maneira mais elaborada para determinar a intensidade da feição espectral usando um algoritmo chamado *Spectral Feature Fitting* (SFF, Clark et al., 1990) ou Ajuste de Feição Espectral. Esse algoritmo realiza uma comparação dos *endmembers* com cada pixel da cena, por meio do ajuste por mínimos quadrados. Para tal, a imagem tem de ser submetida ao procedimento de remoção do contínuo espectral. O SFF gera dois resultados, sendo o primeiro chamado de imagem *scale* que deve ser entendida como a medida da intensidade da feição em cada pixel. Quanto maior o valor, maior é a intensidade da feição do *endmember* no pixel. O segundo produto do SFF é o erro médio quadrático do ajuste por mínimos quadrados, ou imagem RMS. A divisão do *scale* pelo RMS gera um terceiro produto chamado de *fit image*, que pode ser entendido como a probabilidade de o pixel conter o *endmember*.

Para exemplificar utilizaremos a imagem de Cuprite, Nevada. A Figura 14.20 apresenta a imagem *scale* de caulinita e seu respectivo RMS. Repare na área destacada com o quadrado vermelho, a mesma que foi selecionada quando explicamos como selecionar *endmembers* a partir das imagens. Como é uma área que apresenta uma quantidade alta de caulinita, na imagem *scale* (a da esquerda) ela aparece com um tom de cinza mais claro, o que indica elevado valor de intensidade de feição. Já na imagem RMS ele não se destaca, pois o erro médio quadrático do ajuste de seus pixels é baixo.

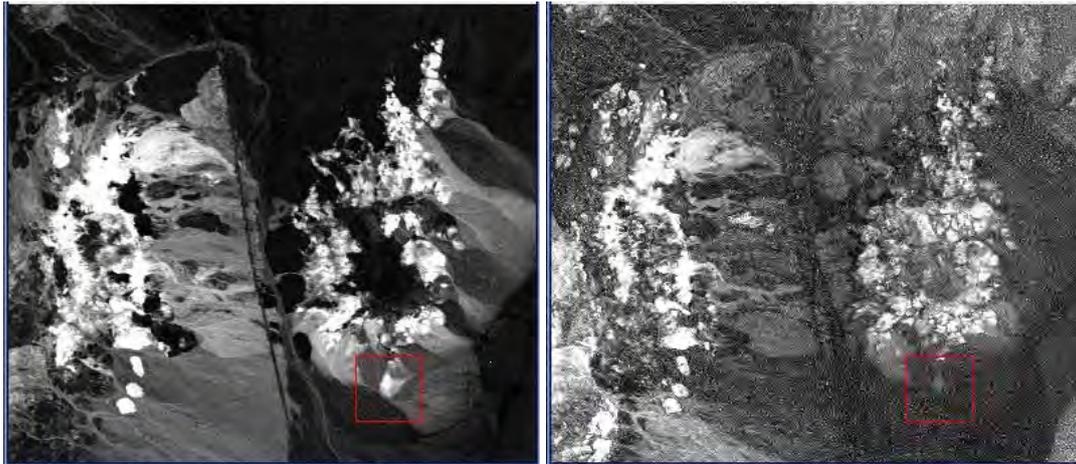


Fig. 14.20 – Resultados do algoritmo SFF: *scale* e RMS, respectivamente.

Outra possibilidade de investigação de intensidade de feições se dá pelos processos de decomposição espectral linear. O algoritmo mais usual para tal fim é o *Linear Spectral Unmixing* que determina a abundância relativa dos materiais (ou *endmembers*) na composição do pixel mistura. Existe uma restrição quanto ao seu uso, que não é problema para sensores hiperespectrais, pois não se pode adotar um número de *endmembers* maior que o número de bandas do sensor. Como resultado do *Linear Spectral Unmixing* tem-se para cada *endmember* uma imagem de abundância e uma referente ao erro médio quadrático da decomposição linear.

Para testar o algoritmo foram escolhidos os minerais illita e calcita para a área de Cuprite. A área investigada com o algoritmo SFF, apontada na Figura 14.21 pela seta, aparece em um tom mais azulado, o que indica que na decomposição linear espectral os pixels avaliados não apresentam nem as feições da illita, nem a da calcita. O resultado obtido mostra nesta figura a imagem de abundância de illita em vermelho, calcita em verde e o erro médio quadrático em azul, sobre uma composição colorida. Ou seja, as áreas mais vermelhas apresentam maior abundância de illita e as em verde de calcita. Isso pode ser verificado nas imagens isoladas. A Figura 14.22 apresenta a imagem *Unmixing* de illita e de calcita, respectivamente, e nos locais mais claros há uma maior abundância de feições espectrais correspondentes a esses dois minerais.

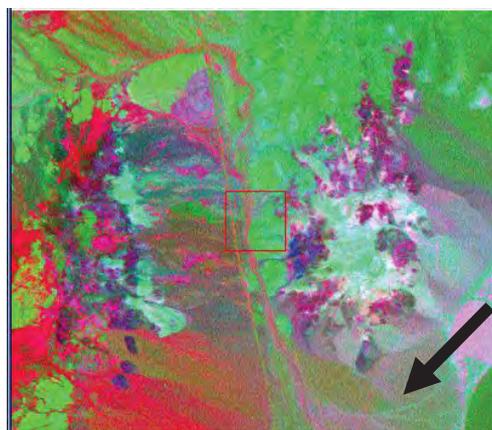


Fig. 14.21 Composição colorida com a imagem *linear spectrum unmixing* para os *endmembers* illita em vermelho, calcita em verde e RMS em azul.

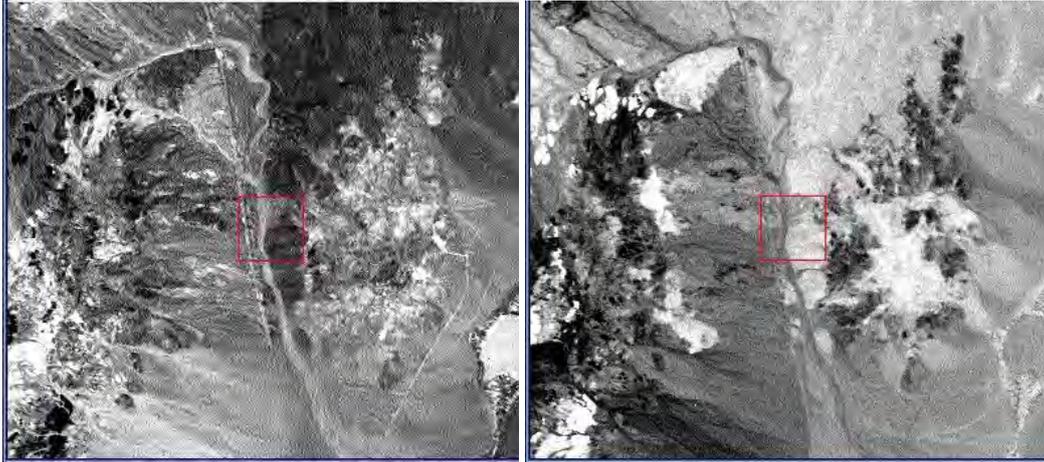


Fig. 14.22 Imagens *Unmixing* para os *endmembers* illita à esquerda e calcita à direita, os pontos mais claros indicando maior abundância dos minerais.

A área que investigamos no algoritmo SFF e destacada com uma seta aparece em um tom mais azulado, o que indica que na decomposição linear espectral os pixels avaliados não apresentam nem as feições da illita, nem a da calcita. As áreas mais vermelhas apresentam maior abundância de illita e as em verde, de calcita. Isso pode ser verificado nas imagens isoladas. A figura X.23 apresenta a imagem Unmix de illita e de calcita, respectivamente, e nos locais mais claros há uma maior abundância de feições espectrais correspondentes à illita e da calcita.

Pelo que foi demonstrado podemos notar que a análise dos espectros é o aspecto mais importante a ser trabalhado no processamento de dados hiperespectrais. Normalmente vamos buscar nos espectros dos pixels da cena as feições que os *endmembers* apresentam, a fim de identificá-los espacialmente e, posteriormente, quantificá-los. Existem outros algoritmos que tem esse mesmo objetivo de identificar as feições espectrais, e a tendência é cada vez mais surgirem novos processamentos, pois já há suficientes pesquisas em várias áreas de aplicação que comprovam o alto poder de mapeamento dos pixels com imagens de sensores hiperespectrais.

IMAGENS DE ALTA RESOLUÇÃO ESPACIAL

Edilson de Souza Bias

Ricardo Seixas Brites

Antonio Nuno de Castro Santa Rosa



15

15.1

Introdução

Neste capítulo apresentaremos a utilização das imagens de alta resolução espacial para o mapeamento do uso da terra voltado ao planejamento urbano, e também na atualização de base cartográficas, com exemplos práticos que envolvem modelos de classificação para esses tipos de imagens.

Entre os aspectos que se pode relacionar para os estudos de planejamento urbano, o mapeamento do uso da terra é um dos mais fundamentais, uma vez que possibilita, de um lado, a espacialização das diversas ocupações numa visão intra-urbana, e de outro, a quantificação dos elementos funcionais existentes e os seus reflexos no equilíbrio ambiental da paisagem urbana.

Diversos estudos têm demonstrado que o acelerado processo de crescimento das cidades é um fenômeno constante na realidade hodierna, criando situações específicas que devem ser avaliadas por meio de uma monitoração permanente dos cenários em constante alteração. Neste particular, as técnicas de sensoriamento remoto são ferramentas que desempenham um importante papel no processo de planejamento e reestruturação do ambiente urbano, pois as imagens permitem identificar as características dos objetos e correlacioná-los às origens dos agentes modificadores do espaço. Além disso, permitem verificar a extensão e a intensidade das alterações provocadas pelas ações antrópicas.

As necessidades voltadas para os estudos do planejamento urbano, nos dias atuais, visam obter respostas cada vez mais rápidas, objetivando ações nos processos ligados à gestão municipal. Essas necessidades encontram-se vinculadas ao retorno político, que requer uma análise acurada dos cenários e, sobretudo, a possibilidade de prospecções futuras.

15.2

Implicações da Resolução Espacial nas Análises do Espaço Urbano

No que se refere ao mapeamento do uso da terra, muito tem sido feito desde o surgimento dos sensores remotos orbitais na década de 1970. Entretanto, devido à baixa resolução espacial das imagens, da ordem de 80 metros, como o MSS do Landsat 1, 2, e 3 não se tinha condições de se identificar e analisar as feições intra-urbanas, o que acarretava a necessidade de demorados trabalhos de campo e o envolvimento de uma grande equipe de profissionais. As conclusões obtidas por Niero *et al.* (1983) revelaram que as resoluções espacial e espectral dos satélites Landsat 1, 2 e 3, somente permitiam a classificação de amplos alvos de uso do solo urbano, como as áreas homogêneas de densa ocupação vertical. Já as classes que englobavam diferentes tipos de uso do solo urbano apresentavam problemas

de separabilidade. Da mesma forma, estudos da dinâmica urbana do Distrito Federal, realizados por Oliveira *et al.* (1984) com a utilização de imagens MSS do Landsat, mostraram também que somente era possível de se mapear nas áreas urbanas, grandes áreas abertas para novas construções, adensamento residencial, invasões (favelas), movimentos de terra (terraplenagem) e solo exposto.

No que se refere às limitações da resolução espacial das imagens do sensor MSS para estudos urbanos, Ceccato (1994) relacionou os seguintes aspectos:

1. Distância do sensor ao objeto reduz a informação do contexto do local, a qual é de grande importância no processo de classificação, quando se pretende inferir classes urbanas de uso e não somente classes de cobertura do solo;

2. As áreas urbanas são tipicamente heterogêneas, contendo vários tipos de materiais: telhados, asfalto, concreto, etc. Dessa forma, a radiação recebida de um único elemento do terreno inclui a radiação de cada um desses materiais, os quais, individualmente, possuem assinaturas espectrais distintas. Este fato passa a apresentar uma resposta de mistura desses alvos, que não é respectivamente o de nenhum deles, isso é, tem-se uma resposta mascarada da realidade espectral dos vários alvos existentes;

3. Entre as classes de uso do solo, particularmente a residencial, ocorrem outras subclasses que não são facilmente definidas em classes discretas, fato que dificulta a agregação eficaz para a discriminação das feições urbanas;

4. A função de espalhamento do sensor integra a resposta de um pixel observado e de seus circunvizinhos. Em áreas urbanas, isso pode afetar significativamente a assinatura de uma única classe de cobertura, se a cobertura dos pixels vizinhos for de classes diferentes; e

5. Em áreas heterogêneas, como as áreas urbanas, a degradação da resposta pelos efeitos atmosféricos é espacialmente variável, o que dificulta o processo de classificação.

Essas considerações foram confirmadas por Hamburger (1993), que fez uma abordagem analítica em relação aos produtos orbitais para a elaboração de mapas de classe do solo urbano e demonstrou que a resolução espacial aparece a todo o momento como uma das maiores e principais limitações. "*A resolução espacial interfere principalmente de duas formas na exatidão de classificação da imagem. A primeira, se a variação entre as características espectrais das classes no espaço de atributos não é grande, a resolução pode melhorar a exatidão de classificação e aumentar a precisão. A segunda, quando as classes não são bem diferenciadas no espaço de atributos, possuindo grande sobreposição, o aumento da resolução tende a melhorar as classificações*". Chamou ainda a atenção para as cenas urbanas, nas quais as áreas a serem classificadas não são extensas e onde a variância da assinatura espectral das classes é muito grande. Se a classificação for baseada unicamente em dados espectrais tornar-se-á bastante complexa, em virtude da mistura espectral que poderá ocorrer.

As imagens de sensoriamento remoto tornaram-se mais atrativas a partir da década de 1980, com o advento da segunda geração de satélites da série Landsat, portando um sensor de melhor resolução espacial (30 metros) e com o surgimento, em 1986, do satélite francês SPOT, com um módulo de imagens multiespectrais de resolução espacial de 20 metros e uma imagem pancromática com 10 metros. Mesmo sendo considerados sensores de média resolução espacial, a combinação com uma boa resolução espectral possibilitou de se fazer análises da complexidade do ambiente urbano, com maior fidelidade e identificação de um maior número de detalhes (Costa, 1996). Por sua vez, o uso de classificações supervisionadas com essas imagens mostrou ser um excelente método para estudos do planejamento urbano.

Uma interessante avaliação da resolução espacial na discretização de objetos do meio urbano com diferentes sensores foi realizada por Robin (1995) apud Freitas (1997), conforme pode ser visto na Figura 15.1. Observe que uma resolução no mínimo de 2 a 3 metros é

necessária para a identificação dos menores equipamentos urbanos, que são as construções residenciais.

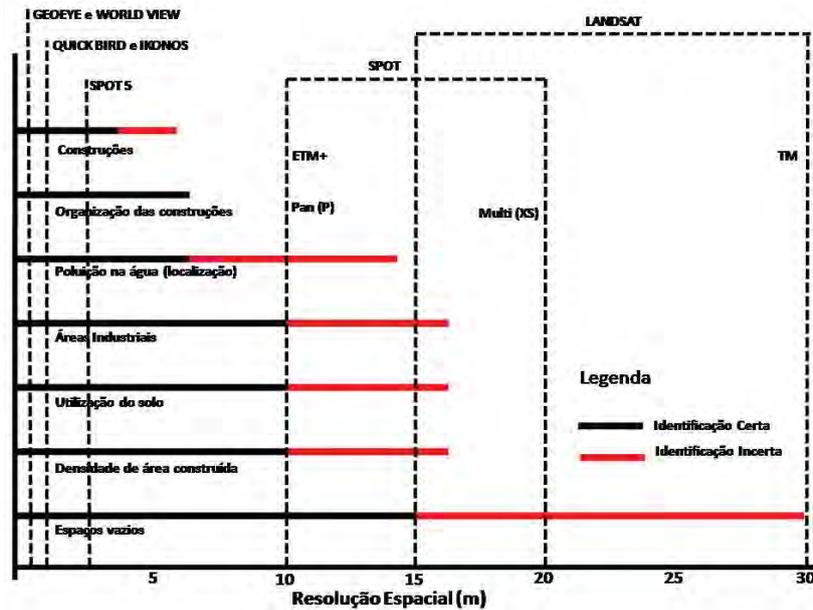


Fig. 15.1 Relação da resolução espacial de diversos sensores com os equipamentos urbanos. (Fonte: Freitas (1997, modificado por Bias 2002).

Por outro lado, conforme observou Freitas (1997), a resolução espectral das imagens é outro parâmetro importante na detecção e identificação dos objetos urbanos. O referido autor chamou a atenção para a diversidade da composição e do espaço intra-urbano, onde os alvos apresentam grande diversidade, como edifícios, shopping centre, loteamentos, praças, estacionamentos, gramados, asfalto, etc., cada um com uma assinatura espectral diferenciada. Os exemplos de reflectâncias na faixa espectral de 0,4 μm a 1,0 μm , de materiais normalmente encontrados em áreas urbanas, são apresentados nas Figuras 15.2, e demonstram que o uso de bandas espectrais no visível, combinadas com banda do infravermelho próximo aumenta o poder da detecção e identificação desses objetos.

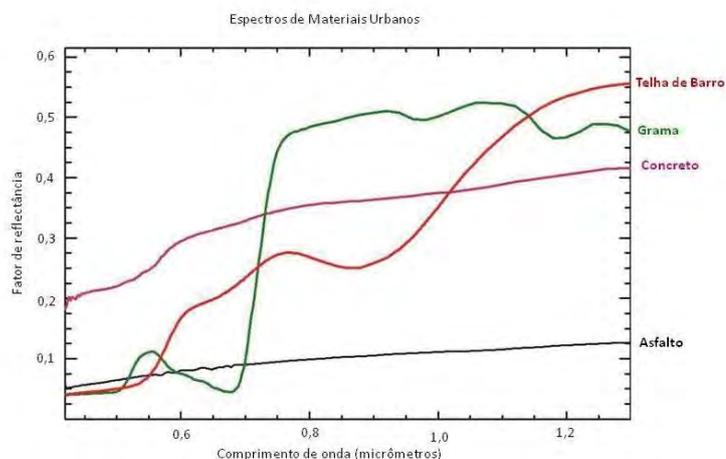


Fig. 15.2 Curvas espectrais de reflectância de algumas feições urbanas

É nesse sentido que vimos no início dos anos 2000 uma tendência de construção e lançamento, por diversos países, de sensores orbitais de alta resolução espacial e de curto período de revisita. Alguns desses sensores possuem dois módulos de imageamento: um multiespectral com no máximo quatro bandas e resolução espacial em torno de 4 metros, e um módulo pancromático (PAN) com resolução espacial igual ou maior que 1 metro, projetados para terem a capacidade de inventariar e mapear classes de alvos de detalhe, principalmente de áreas urbanas e áreas agrícolas. Outros sensores incluem apenas o módulo pancromático, com resolução espacial superior a 1 metro. Esses são denominados sensores cartográficos e seus propósitos são de gerar modelos numéricos de elevação (DEM) para fins de construção de mapas cartográficos. A Tabela 15.1 contém exemplos de alguns dos satélites com sensores de alta resolução espacial.

Tabela 15.1 Alguns dos principais satélites com sensores de alta resolução espacial.

SATÉLITES DE SENSORIAMENTO REMOTO DE ALTA RESOLUÇÃO ESPACIAL			
IKONOS-2	USA	1999	1 m
QUICKBIRD	USA	2001	60 cm
ALOS	JAPÃO	2006	2,4 m
CARTOSAT-2	INDIA	2007	2,5 m
FORMOSAT-2	TAIWAN	2006	2,5 m
GEOEYE-1	USA	2008	41 cm
KOMPASAT-2	KOREA	2006	1m
WORLDVIEW-2	USA	2009	50 cm
ORBVIEW-3	USA	2003	1 m

Sendo assim, os atuais sensores de alta resolução espacial empregados para a análise de áreas urbanas e de outros objetos que exigem imagens de detalhe, oferecem a solução para boa parte deste problema. A concepção de configuração desses dois módulos de imagens foi pensada com o fim de se usar as técnicas de fusão de imagens que vimos no capítulo 8, para obter imagens em composições coloridas do módulo multiespectral na resolução espacial da banda pancromática. Isso resolve as duas questões básicas para a identificação e classificação dos objetos urbanos: a necessidade de imagens com resoluções em torno de 1 metro e a necessidade de várias bandas espectrais para a discriminação dos tipos desses objetos.

O nível de resolução espacial dessas imagens corresponde às escalas de análise entre 1:5000 e 1:25000, que são muito mais adequadas à classificação da heterogeneidade dos objetos urbanos (Gonçalves *et al.* 2001). Imagens de resolução de 1 metro, como do IKONOS 2, possibilitam, segundo Balzereck (2002), se fazer análises de diferenças espectrais intra-urbanas a partir da avaliação da reflectância dos telhados das residências. Foram identificados telhados constituídos por material de ferro e metal, bem como inferida a idade deles. Essas diferenças são uma peculiaridade importante, pois permite avaliar a estrutura da cidade e monitorar o seu desenvolvimento, a partir de uma análise rápida do processo de urbanização, além de possibilitar a identificação da densidade de formação e os padrões temporais e espaciais existentes. A utilização das imagens IKONOS II auxilia o processo de análise e monitoramento da urbanização e, principalmente, da direção da expansão urbana. Demonstra também, a utilidade e potencialidade de ser usada, por exemplo, para descobrir mudanças na construção das estruturas, densidades, tamanhos e formas de diversos elementos urbanos. Balzerek (2002) concluiu que com os índices de homogeneidade de espaço avaliados a partir da imagem IKONOS II e a partir da avaliação dos tamanhos dos

polígonos dentro de uma determinada classe, pode-se tentar uma aproximação para o desenvolvimento de análises quantitativas do tipo e das características da ocupação urbana.

No Brasil, o número de trabalhos que utilizaram as imagens de alta resolução IKONOS II é ainda pequeno. Podem-se destacar as iniciativas realizadas por Bias & Baptista (2002) e Bias *et al.* (2003), referentes às relações entre o verde urbano e as ilhas de calor, e as avaliações realizadas por Gonçalves (2001) que considerou, que embora os sensores de alta resolução ofereçam benefícios em termos da possibilidade de identificação de elementos individuais em áreas urbanas, como casas, arruamentos e outros, os dados podem ainda apresentar informações indesejadas, decorrentes de alguns fatores que influenciam na resposta espectral dos alvos. Esses fatores seriam a relação geométrica entre a energia incidente e o ângulo de visada do sensor, os efeitos atmosféricos, as propriedades físicas dos materiais estudados e ainda, a reflectância das superfícies adjacentes.

15.3

A Título de Exemplo

Para demonstrar o uso prático das imagens de alta resolução espacial com a utilização de processos de classificação apresentados nos capítulos anteriores, são apresentados os resultados realizados de um estudo com imagens IKONOS II na área urbana da cidade satélite de Sobradinho, do Distrito Federal, que ocupa uma área de 569,37 km².

A proposta metodológica para a estruturação do mapa de uso da terra foi efetuado com o objetivo de identificar cinco classes funcionais a partir de análise espectral, utilizando-se métodos diferenciados. Foram investigadas as seguintes classes: asfalto, residências individuais, residências coletivas, solo exposto e cobertura vegetal (gramíneas). A diferenciação entre as residências individuais e coletivas foi efetuada a partir da cobertura (tipo de telhado – barro ou amianto). Na região de estudo, as residências coletivas não apresentam cobertura de material de barro, e sim de amianto.

Utilizou-se uma imagem IKONOS *Geo Ortho Kit color*, em formato GEOTIFF, com dados das efemérides do satélite para permitir a ortorretificação, 11 bits por pixel, resolução espacial 1 metro, tanto na banda pancromática como nas multiespectrais, ângulo de elevação 76,47°. Os métodos de classificação utilizados foram o SAM (*Spectral Angle Mapper*) e o PPI (*Pixel Purity Index*) e os métodos clássicos MAXVER (Máxima Verossimilhança) e ISODATA. Segundo Anderson *et al.* (1979), o uso de diferentes métodos de classificação justifica-se pelo fato de não existir uma classificação única e ideal, da mesma forma que cada classificação é feita com o objetivo de atender a uma determinada necessidade de um usuário específico. E mais, na maioria dos processos de classificação dificilmente se identificam as classes que se deseja, muitas vezes levando os usuários a tomarem decisões arbitrárias nas interpretações desenvolvidas.

O *Spectral Angle Mapper* (SAM) é um classificador espectral que realiza o mapeamento da similaridade entre o espectro de um pixel da imagem e os espectros de referência provenientes de bibliotecas espectrais que podem ser extraídas da própria imagem. Para isso, ele compara o ângulo entre o espectro de referência, considerado como um vetor n-dimensional, onde “n” é o número de bandas, com cada pixel da imagem. Ângulos pequenos representam bons ajustes entre os dois vetores. O procedimento gera dois tipos de arquivos: a imagem SAM e as “*rule images*”. A imagem SAM é o resultado da classificação com uma cor predeterminada para cada espectro de referência (*endmembers*). As *rule images* apresentam o ajuste dos ângulos para todos os pixels da imagem, sendo uma imagem para cada *endmember*.

O algoritmo Pixel *Purity Index* (PPI) (índice de pureza do pixel) baseia-se num processo iterativo que busca definir quais os pixels que se apresentam sem misturas espectrais. Neste trabalho, a imagem foi processada utilizando-se a composição dos componentes principais da imagem, com 10.000 iterações.

O método da classificação não supervisionada ISODATA é, provavelmente, o mais conhecido, realizando a classificação e identificação de padrões de agrupamentos de pixels, também conhecidos por *clusters*. Esses padrões são identificados por meio de um vetor de médias e a classificação ocorre de forma iterativa, baseando-se no critério de mínima distância. Por sua vez, o método Máxima Verossimilhança (MAXVER) é a classificação supervisionada mais utilizada e se baseia na probabilidade do pixel pertencer a uma determinada classe. A eficácia do método MAXVER depende, principalmente, da estimativa do vetor médio (m) e da matriz de covariância (S) de toda classe espectral. A quantidade de pixels incluídos para a amostra é fator determinante.

Para a realização desses testes de classificação para a elaboração do mapa de uso da terra foi selecionada uma área dentro do ambiente urbano de Sobradinho, que apresentasse a maior diversidade de feições espectrais. As áreas de treinamento foram as citadas anteriormente: asfalto (verde), residências individuais, telhas de barro (azul), residências coletivas, telhas de amianto (amarelo), solo exposto (vermelho), cobertura vegetal de gramíneas (ciano) (Figura 15.3). Os resultados são apresentados nas figuras que se seguem, com a finalidade de mostrar visualmente as diferenças que os classificadores apresentaram. As operações e procedimentos de cada um desses classificadores não serão discutidas, pois já foram apresentadas nos capítulos anteriores de classificações de imagens pixel a pixel (capítulo 12) e sobre processamento de imagens hiperespectrais (capítulo 14).



Fig. 15.3 Área da imagem IKLONOS II selecionada para testes e as amostras das classes selecionadas.

O cálculo dos pixels puros através do índice de pureza do pixel (Pixel *Purity Index*-PPI) foi computado por 10.000 iterações, com um limiar de 2,5. Como resultado a imagem mostra os pixels puros encontrados na imagem, o que é apresentado na Figura 15.4. Pode-se observar na geração da imagem PPI uma dominância da resposta espectral da malha viária.

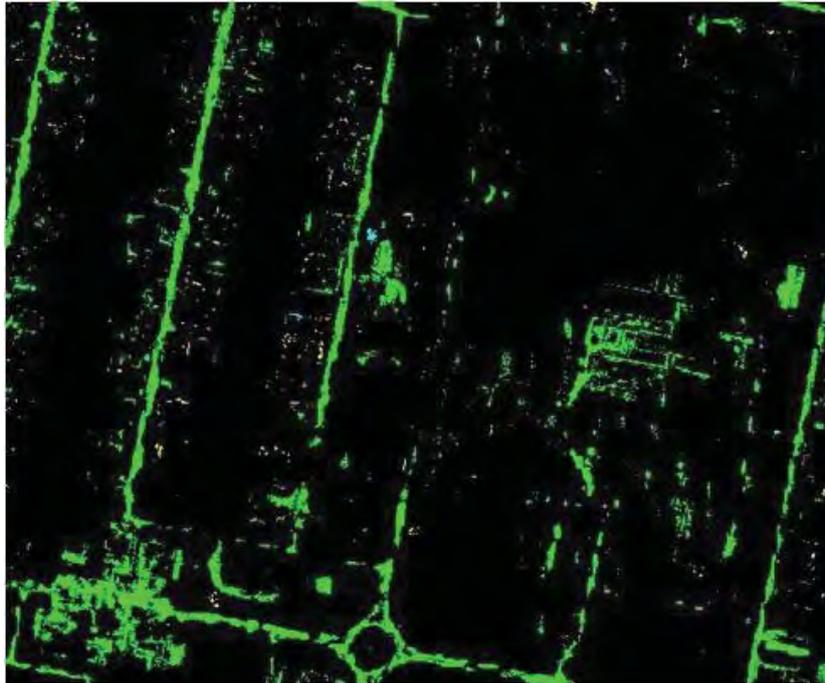


Fig. 15.4 Resultado da classificação por PPI – Índice de pixel puro da imagem IKONOS II de parte da área urbana da cidade satélite de Sobradinho, Brasília DF.

A visualização dos pixel *s* puros pode ser vista num espaço n-dimensional, permitindo nessa etapa a seleção dos *endmembers*. Os pixel *s* puros situam-se nas extremidades dos diagramas de dispersão (escaterograma) e são delimitados de forma interativa pelo usuário. Cada cor representa um grupo de pixel *s* puros que identifica um tipo de objeto (Figura 15.5). Nessa figura pode-se observar uma maior concentração nos pixels (*cluster*) referentes ao solo exposto (vermelho). A partir da rotação do modelo n-dimensional e posterior agrupamento das classes, foi possível selecionar os padrões de classes existentes na cena. Após a seleção dos *endmembers*, são mapeados ou classificados na imagem os materiais que representam os pixel *s* puros. Para o mapeamento espectral usou-se o método *Spectral Angle Mapper* – SAM, usando espectros de referência da própria imagem. Esse método mapeia os materiais que espectralmente predominam no pixel e apresenta como resultado um mapa de classes mostrando o melhor ajuste para cada pixel. O resultado da classificação SAM é mostrado na Figura 15.6.

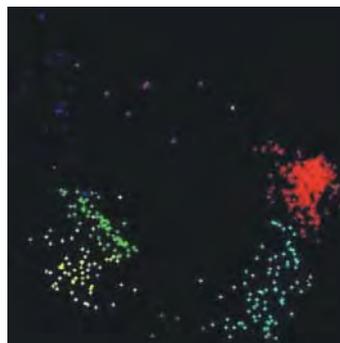


Figura 15.5 Visualizador n-dimensional de pixels puros da imagem IKONOS II.

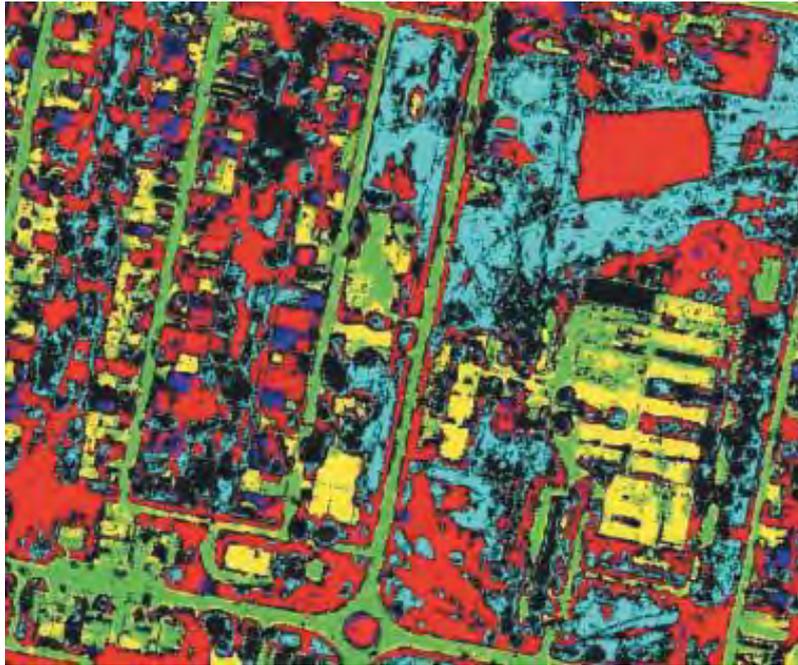


Fig. 15.6 Resultado da classificação SAM: asfalto (verde), residências com telhas de barro (azul), residências com telhas de amianto (amarelo), solo exposto (vermelho), gramíneas (ciano) da imagem IKONOS II de parte da área urbana da cidade satélite de Sobradinho, Brasília DF.

Os resultados dos classificadores ISODATA e MAXVER são apresentados, respectivamente, nas Figuras 15.7 e 15.8. No procedimento não supervisionado ISODATA, ocorreu uma mistura indiscriminada das respostas espectrais dos diferentes alvos, enquanto que o classificador supervisionado de Máxima Verossimilhança apresentou um melhor desempenho na identificação das classes amostradas.

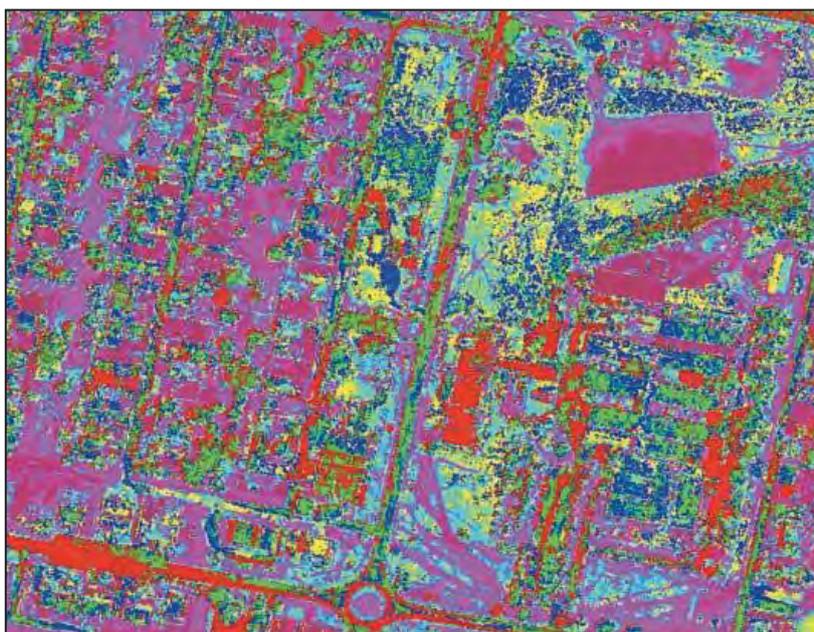


Fig. 15.7 Resultado da classificação ISODATA. da imagem IKONOS II de parte da área urbana da cidade satélite de Sobradinho, Brasília DF.

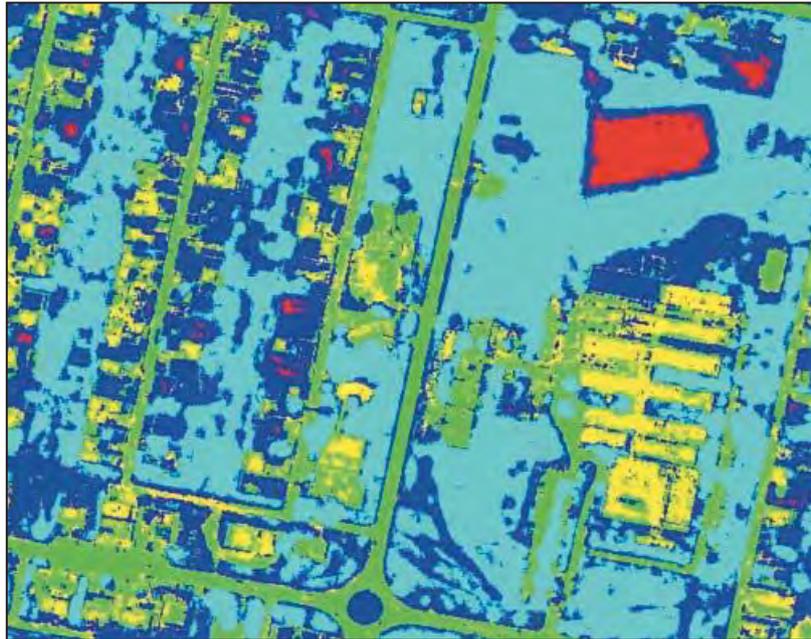


Fig. 15.8 Resultado da classificação MaxVer. da imagem IKONOS II de parte da área urbana da cidade satélite de Sobradinho, Brasília DF.

Apesar de a classificação MAXVER apresentar um melhor agrupamento de classes, foi com a classificação SAM que a diversidade de respostas espectrais apresentou-se mais eficiente, embora ocorra uma mistura das classes de solo exposto e telhas de barro. Essa confusão é normal devido à similaridade do comportamento espectral de reflectância desses dois alvos, como mostra a Figura 15.9.

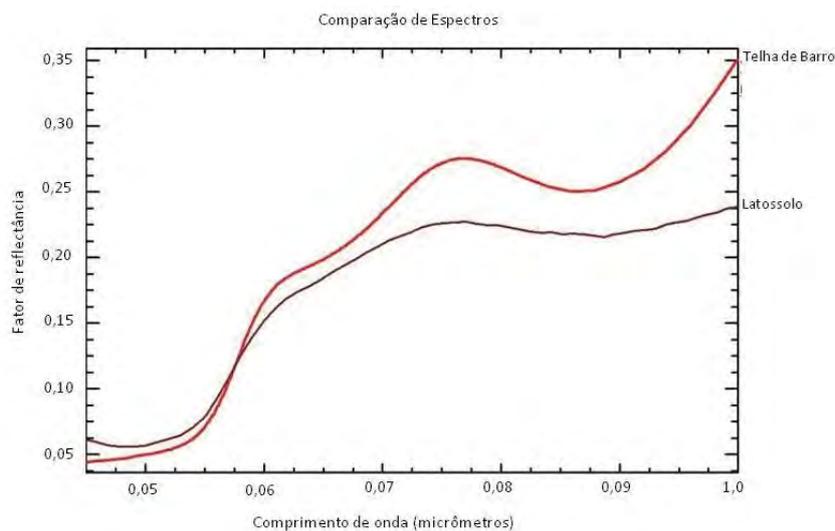


Fig. 15.9 Comparação dos espectros de refletância das classes solo (latossolo) e telhas de barro.

Fatos como esse fazem com que haja uma confusão para o classificador, mesmo que se tenha cuidadosamente selecionado as amostras das áreas de treinamento das classes. Se o usuário tiver interesse em determinar a exatidão dos resultados, é comum o uso de dois

métodos estatísticos de avaliação. O primeiro consiste na análise dos erros de comissão e omissão, e o segundo, na aplicação do Índice Kappa. Ambos os métodos utilizam uma matriz cruzada para integração e avaliação dos resultados.

15.4

Imagens de Alta Resolução e Possibilidades para o Mapeamento Cartográfico

O Brasil enfrenta, nos dias atuais, a desatualização de dados cartográficos (Tabela 15.2), em razão de dois fatos: *a*) a falta de investimentos nas áreas de cartografia e mapeamento; *b*) a crescente dinâmica do crescimento urbano, que impõe a necessidade de constantes atualizações e, em alguns casos, de um novo levantamento. Devido aos altos custos e longo tempo de execução, os trabalhos tornam-se inviáveis, particularmente, quando efetuados por processos convencionais de aerofotogrametria.

Tabela 15.2 Quadro sinótico da cartografia brasileira.

Escala	Folhas Existentes	Folhas Mapeadas	Ano Cobertura	Percentual de cobertura do território brasileiro
1:1.000.000	46	46	1980	100
1:500.000	154	68	1965	36,90
1:250.000	556	444	1985	80,72
1:100.000	3.049	2.289	1982	75,39
1:50.000	11.928	1.647	1977	13,90
1:25.000	47.712	492	1985	1,01

Ano de referência (aproximado) em que se completaram 2/3 do número de folhas mapeadas. (Fonte: Correia, 1997).

Nos últimos anos muito se tem discutido sobre as opções disponíveis para os processos de atualização cartográfica que minimizem os custos bem como reduzam o tempo de execução do mapeamento. A rapidez na coleta, tratamento e disponibilização dos dados, são fatores da maior relevância para os diversos usuários. O advento dos sensores remotos abriu uma possibilidade sem precedentes para a atualização cartográfica. A utilização de escalas de 1:100.000 a 1:25.000 já representa uma possibilidade concreta. Entretanto, o uso de imagens de alta resolução espacial para a cartografia, em escalas de detalhe de 1:10.000 até 1:2.000, existe ainda uma grande celeuma, tanto no meio científico, como por parte das empresas de aerolevantamento, devido à falta de dados consistentes que comprovem essa possibilidade.

Alguns estudos já demonstraram que a ortorretificação ou correção geométrica das imagens está diretamente relacionada com o que se pretende do produto final e com a configuração topográfica da região geográfica. Em regiões de pequena variabilidade vertical (pequeno gradiente topográfico), a aplicação de uma eficiente correção geométrica, com uma boa densidade de pontos, pode atender plenamente as necessidades. Entretanto, para regiões com grande gradiente e acentuada movimentação topográfica, torna-se necessário um processo de ortorretificação que, por não ser o mesmo para todas as regiões, exigirá adequações e ajustes em função das características do terreno e da extensão geográfica da área. Outro agravante relaciona-se à necessidade de uma boa amostragem altimétrica, sem a qual é impossível a geração do MDE (modelo digital de elevação) necessário à ortorretificação. São compreensíveis todas as preocupações. No entanto, busca-se vislumbrar

um horizonte de soluções, onde as imagens possam atender às necessidades financeiras, técnicas, de qualidade e de tempo para disponibilização dos produtos. Onde já existe uma base cartográfica, a imagem é útil na atualização e complementações de novas informações aproveitando o material já existente, e para áreas sem uma boa base de curvas de nível, já são encontradas no mercado imagens que possibilitam a geração de estereopares, justamente para criá-las. Nesses casos, torna-se necessário avaliar os custos do processo e sua precisão.

A outra discussão baseia-se na escala possível de ser atingida. Estudos desenvolvidos por Bias (2003), utilizando imagens IKONOS II, considerando as classes do PEC – Padrão de Exatidão Cartográfica, demonstraram a possibilidade de se trabalhar com essas imagens até a escala de 1:10.000, para a Classe A e até a escala de 1:2.500, para a Classe B.

Um último ponto a ser abordado diz respeito aos valores para a obtenção dos dois produtos. Aplicações e análises demonstraram que a utilização de imagens de alta resolução espacial pode representar uma redução de custo da ordem de 30% em relação aos processos convencionais, além de possibilitar a disponibilização do produto final em tempo bem menor.

15.4.1

O Mercado Atual de Imagens de Alta Resolução

Estudos realizados por Bias (2003), Ishikawa e da Silva (2005) e Tavares Júnior *et al.* (2006) mostraram que as imagens que vêm sendo mais utilizadas para a geração de produtos cadastrais são as dos satélites IKONOS II (lançado em 09/1999) e QuickBird 2 (lançado em 2010). Os estudos de Bias (2003) com imagens IKONOS ORTHO KIT, em duas localidades do Distrito Federal, a primeira no Plano Piloto e a outra na Região Administrativa de Sobradinho, produziram resultados bastante encorajadores. Para o Plano Piloto o erro médio quadrático (RMS) total dos pontos de controle utilizados no processo de ortorretificação das imagens foi de 0,73 m, sendo: RMS (x) de 0,41 m e RMS (y) de 0,60 m. Esses valores podem ser justificados pelo pequeno gradiente do terreno (± 100 metros), pela dimensão da área de estudo ($\pm 27 \text{ km}^2$) e pelo ângulo de elevação do satélite ($86,28^\circ$). Para a área de Sobradinho o RMS médio foi de 1,64 m (x) e 1,04 m (y). O RMS médio dos pontos de controle usados para verificação foi de 3,47 m em x e 2,10 m em y, justificado pelo gradiente do terreno (± 900 metros), pela dimensão da área de estudo ($\pm 100 \text{ km}^2$) e pelo ângulo de elevação ($76,47^\circ$).

Os dados técnicos referentes às imagens do satélite IKONOS II e QuickBird e os produtos oferecidos pelas empresas são mostrados nas Tabelas 15.3 a 15.6.

Tabela 15.3 Especificações técnicas do satélite IKONOS II

Altitude da órbita	681 km
Órbita	98,1° - Sol-síncrona
Sentido da órbita	Descendente 10h30 a.m.
Duração da órbita	98 min.
Tempo de revisita	1 a 3 dias (dependendo da latitude)
Largura da faixa imageada	11,3 km (nadir)
	13,8 km (26° off-nadir)
Resolução Espacial	0,82 m (nadir) Pancromática
	3,20 m (nadir) Multiespectral
	1 m (26° off-nadir) Pancromática
	4 m (26° off-nadir) Multiespectral
Bandas Espectrais	Azul: 0,45 – 0,52 μm
	Verde: 0,51 – 0,60 μm
	Vermelho: 0,63 – 0,70 μm
	Infravermelho próximo: 0,76–0,85 μm

Fonte: Adaptado de Space Imaging (2003).

Tabela 15.4 Produtos do sensor IKONOS II

Produtos	¹ CE 90% (m)	² RMS (m)	Descrição
<i>GEO</i>	15,00	X	Apenas georreferenciamento (Datum e projeção)
<i>Reference</i>	25,00	11,8	Para receber a imagem com as distorções corrigidas é necessário fornecer pontos de controle e um MDE
<i>PRO</i>	10,2	4,8	Maior exatidão sem auxílio de pontos de controle
<i>Precision</i>	4,1	1,9	Gerado com o auxílio de pontos de controle e MDE, a partir de pares estereoscópicos
<i>Precision Plus</i>	2,0	0,9	Gerado com o auxílio de pontos de controle e MDE, a partir de pares estereoscópicos. Resolução espacial 1m
<i>Stereo</i>	25,0	X	Produto gerado a partir de pares estereoscópicos sem pontos de controle
<i>Precision Stereo</i>	4,0	X	Produto gerado a partir de pares estereoscópicos com pontos de controle

]

Tabela 15.5 Especificações técnicas do satélite Quick Bird

Altitude da órbita	450 km
Órbita	97,2° - Sol-sincrona
Sentido da órbita	Descendente 10h30 a.m.
Duração da órbita	93,5 min.
Tempo de revisita	1 a 3,5 dias (dependendo da latitude)
Largura da faixa imageada	16,5 km (nadir) 20,8 km (26° off-nadir)
Resolução Espacial	0,61 m (nadir) Pancromática 2,44 m (nadir) Multiespectral 0,72 m (25° off-nadir) Pancromática 2,88 m (25° off-nadir) Multiespectral
Bandas Espectrais	Azul: 0,45 – 0,52 µm Verde: 0,52 – 0,60 µm Vermelho: 0,63 – 0,69 µm Infravermelho próximo: 0,76 – 0,90 µm

Fonte: <<http://www.digitalglobe.com/index.php/85/QuickBird>>, acesso realizado em 05 de julho de 2011.

Tabela 15.6 Produtos do sensor Quick Bird

Produtos	¹ CE 90% (m)	² RMS (m)	Descrição
<i>Basic</i>	23,0	14,0	Com correção radiométrica e relativa dos detectores, geometria interna do sensor. Possui o menor processamento
<i>Standard</i>	23,00	14,0	Disponível com uma projeção cartográfica e Datum
<i>Orthorectified (RCP)</i>	12,7	7,7	Imagem ortoretificada
<i>Orthorectified (Efemérides)</i>	10,2	6,2	Imagem ortoretificada
<i>Basic Stereo</i>	23,0	14,0	Imagem adquirida com 30° off-nadir, possui 90° de recobrimento

¹CE 90% – Erro Circular com 90% de confiança; ²RMS – Erro Médio Quadrado (Root Mean Square). * Excluídos os efeitos do relevo. Padrão de exatidão cartográfica dos EUA. Fonte: Adaptado de Space Imaging (2003).

Em 06 de setembro de 2008 foi lançado com sucesso o satélite GeoEye-1, que tem a maior resolução espacial no setor comercial de imageamento espacial da Terra. O satélite GeoEye-1 tem capacidade de imagear até 700.000 km² de imagens pancromáticas e 350.000

Km² de imagens pancromática + multispectral (PSM), por dia, possibilitando a revisita de qualquer área de interesse na Terra a cada três dias ou menos. São disponibilizados quatro produtos em diferentes níveis de processamento de imagens, BASIC, GEO, ORTHO e ESTEREO, bem como produtos e serviços derivados das imagens, incluindo Modelos Numéricos de Terreno, MNT/DEM, mosaicos de grandes extensões e mapas temáticos. A Tabela 15.7 apresenta as principais características do satélite GeoEye-1 e a Tabela 15.8 apresenta os valores em moeda de cada um dos produtos. Na Figura 15.10 é um exemplo de imagem GeoEye, em composição de cor natural, de uma parte da enseada de Botafogo no Rio de Janeiro.

Tabela 15.7 Características técnicas do satélite GeoEye

Resolução Espacial	0.41 m no Pancromático (P &B) 1.64 m no Multispectral (colorido)		
Pancromático	450-900 nm		
Multispectral	Azul: 450-520 nm Verde: 520-600 nm Vermelho: 625-695 nm Infravermelho: 760-900 nm		
Faixa imageada	15,2 km		
Capacidade de Visada Lateral	Até 60 Graus		
Altitude	684 km		
Hora de passagem	10:30 A.M. GMT		
Precisão de localização	Estereoscopia: 2 m de erro circular Estereoscopia : 3 m de erro linear Monoscopia: 2,5 m de erro circular Em 90% dos pontos erro circular na horizontal e erro linear na vertical, sem pontos de controle em campo		
Faixa de imageamento e áreas imageadas	Faixa nominal de imageamento de 15,2 km de largura no Nadir Cena individual: 225 km ² (15x15 km) Para grandes áreas contínuas, 15.000 km ² (300x50 km) Áreas contíguas de 1°, 10.000 km ² (100x100 km) Áreas contíguas em estereoscopia, 6.270 km ² (224x28 km) (Assumindo que seja no modo Pancromático em imageamento na maior velocidade)		
Capacidade de revisita com órbita de 684 km de altitude (e alvo de interesse a 40° de latitude)	Resolução no modo PAN resultante	Ângulo de visada (Graus)	Média de dias para revisita
	0,42	10	8.3
	0,50	28	2.8
	0,59	35	2.1

Fonte: < http://www.engesat.com.br/index.php?system=news&news_id=737&action=read>. Acesso em 05 de julho de 2011.

Tabela 15.8 Preços dos produtos GeoEye

Tipos de Imagem	Minimo	Valor (R\$/km ²)
Geo Ortho Kit (em catálogo)	49 km ²	50,00
Geo Ortho Kit (Programação)	100 km ²	95,00
Reference Stereo (catálogo ou programação)	49 km ² e 100 km ²	210,00

Fonte: < http://www.engesat.com.br/index.php?system=news&news_id=737&action=read>. Acesso em 05 de julho de 2011.

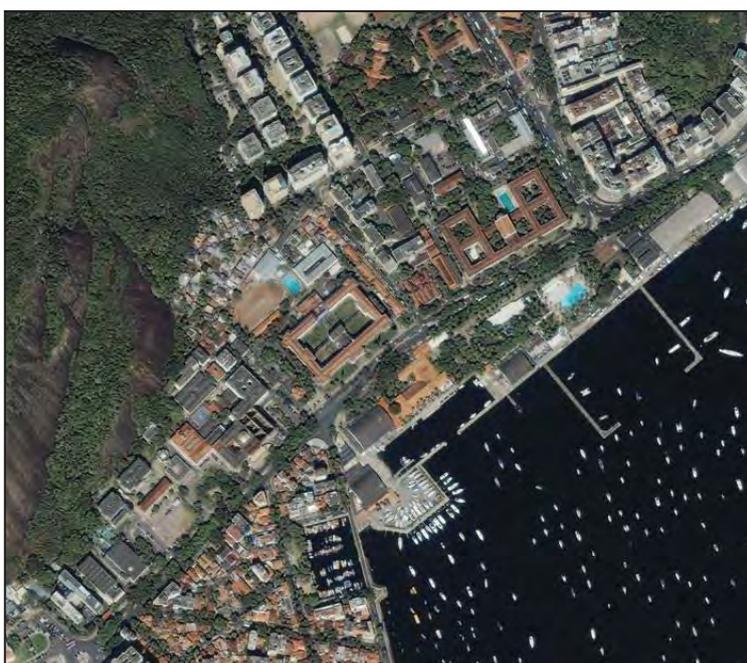


Fig. 15.10 Composição em cor natural de imagem GeoEye obtida em 03/03/2008 de uma parte da enseada de Botafogo, RJ. (Fonte: <<http://www.GeoEye.com>>. Acesso em 01/06/2011).

A missão WorldView teve seu primeiro satélite lançado em 2007 com o WorldView-1 e o segundo, em 2009. Ambos possuem um sensor pancromático de alta resolução, além das bandas multiespectrais inseridas no WorldView-2. Esses satélites são os primeiros de uso comercial a utilizarem a tecnologia *Control Moment Gyroscopes* (CMGs), que fornece aceleração num nível 10x acima dos outros sensores e melhora tanto a capacidade de manobra como a de segmentação. Com o CMGs, para se realizar uma cobertura de uma faixa de 300 km, o tempo é reduzido de 60 segundos para apenas 9 segundos. Isso significa que o satélite WorldView2 pode mover-se de um alvo para outro com precisão e rapidez, permitindo a observação de múltiplos alvos em uma única passagem orbital. As Tabelas 15.9 e 15.10 apresentam as características técnicas e preços da imagem WorldView2 e a Figura 15.11 um extrato de uma imagem do WorldView.

Outro aspecto que diferencia os sensores de alta resolução espacial dos sensores de baixa resolução espacial é a alta resolução radiométrica, de 11 bits ou 2048 níveis de cinza, permitindo aumentar consideravelmente o poder de distinção e discriminação dos objetos.

Tabela 15.9 Características técnicas da imagem WorldView 2

Resolução Espacial	Pancromático – 50 cm Multiespectral - 2,0 m
Pancromático	450-800 μm
Multiespectral	Tradicionais Azul (450–510nm) Verde (510 – 580 nm) Vermelho (630-690 nm)

	Infravermelho próximo 1 (770-895 nm) Novas Costal (400-450 nm) Amarela (585 – 625 nm) Red Edge (705-745 nm) Infravermelho próximo 2 (860 – 1040 nm)
Faixa imageada	16,4 km (nadir)
Altitude	770 km
Hora de passagem	10:30am passagem descendente Sol-síncrona Período: 100 minutos
Resolução Espacial	Pancromático 0,46 m (nadir) / 0,52 m a 20° <i>off-nadir</i> Multiespectral 1,84 m (nadir) / 2,08 m GSD a 20° <i>off-nadir</i>
Acurácia posicional	Especificação de 6,5m CE90, com desempenho previsto de 4,6 a 10,7m CE90, excluindo efeitos de terreno.Utilizando pontos de controle na imagem: 2,0 metros

Tabela 15.10 Preços dos produtos WorldView

Tipos de Imagem	Mínimo	Valor (R\$/km ²)
Pan e MS - até 4 bandas (Catálogo)	25 Km ²	63,00
Pan e MS - até 4 bandas (A programar)	90 Km ²	90,00
Stereo – Pan (Catálogo)	210 Km ²	126,00
Stereo – MS 8 bandas (Catálogo)		153,00
Stereo – Pan (A programar)		180,00
Stereo – MS 8 bandas (A programar)		207,00

Fonte: Engesat (2010).



Fig. 15.11 Composição em cor natural de imagem WorldView 2, obtida em 09/03/2010, da cidade de São Paulo. (Fonte: <<http://www.digitalglobe.com>>. Acesso em 01/06/2011).

15.5

Erro Gráfico e Escala

Com a finalidade de se examinar a possibilidade da utilização cartográfica das imagens de alta resolução, torna-se necessária uma pequena digressão para tornar claros os conceitos de erro gráfico e suas implicações relacionadas à escala dos produtos.

O erro gráfico está relacionado com a exatidão planimétrica do produto cartográfico, sendo intimamente relacionada com a sua escala. Ele é o menor comprimento gráfico que se pode obter em uma representação cartográfica e corresponde a 0,2 mm, além de ser também o erro máximo admissível ao efetuar uma medição sob representação gráfica. Como a escala é uma relação de proporção entre uma representação gráfica e a superfície terrestre representada, a exatidão dessa representação é função da relação entre o erro gráfico e a escala do documento cartográfico:

$$E_g = 0,0002 \times F_e \quad \text{eq. 15.1}$$

$$E = 1/F_e \quad \text{eq.15.2}$$

sendo, E_g = erro tolerável em metros

E = escala do documento cartográfico

F_e = fator de escala do documento cartográfico

Os cálculos decorrentes das equações 15.1 e 15.2 devem ser realizados antes do início do levantamento topográfico, para que se possa fazer uma seleção das feições que serão cadastradas.

Tendo por base a equação 15.1, a Tabela 15.11 apresenta a precisão das feições gráficas em função das escalas adotadas.

Tabela 15.11 Precisão em função da escala adotada

Escala	Precisão (m)	Menor Objeto (m ²)
1:500	0,1	0,01
1:1.000	0,2	0,04
1:2.500	0,5	0,25
1:5.000	1	1
1:10.000	2	4
1:25.000	5	25
1:50.000	10	100

15.6

Relação entre Resolução Espacial e Erro Gráfico

Kasser (2002) afirmou não ser possível distinguir em uma imagem digital detalhes menores que o tamanho do pixel, porque a forma do alvo não poderá ser discernida da forma do pixel. Como a resolução espacial é a mínima separação entre dois objetos representados distintamente e separados, a forma não é o tamanho do menor objeto possível de se ver numa imagem (SABINS, 1987).

A frequência máxima de uma cena que pode ser representada através de uma imagem é dada pela frequência de Nyquist (Wolf, 2000), que equivale à metade da frequência de

amostragem. A frequência de amostragem é dada pelo tamanho do pixel quando a PSF (*Point Spread Function* ou função de espalhamento do ponto) é menor do que o espaçamento entre linha e colunas. Assim, somente alvos com tamanho de pelo menos dois pixels podem ser representados pela imagem em questão.

Na Tabela 15.12 são apresentadas as frequências de amostragem das imagens IKONOS, QUICK BIRD, GEOEYE e WORLDVIEW2.

Tabela 15.12 Frequência de amostragem

Sensor	Frequência de amostragem	Frequência Nyquist	Equivalência em pixel
IKONOS II	1/m	0,5/m	2 m
QUICK BIRD	1,64/m	0,82/m	1,22 m
WORLDVIEW	2/m	1/m	0,5 m
GEOEYE	2,20/m	1,11/m	0,90 m

15.7 Custo da Geração de uma Base Cartográfica

Após esse conjunto de análises, é necessária a avaliação do custo de uma base cartográfica, pelos processos convencionais de aerofotogrametria e por imagens de alta resolução espacial. A Tabela 15.13 apresenta os valores em moeda referentes às diversas etapas da geração de uma base cartográfica.

Tabela 15.13 Valores referentes à geração de mapeamento aerofotogramétrico.

Etapas	Custo km ²	Área Estimada km ²	Valor Total (R\$)
Cobertura aerofotogramétrica	80	5.802	464.160,00
Apoio de campo básico e suplementar	60	5.802	348.120,00
Aerotriangulação	200	5.802	116.040,00
Restituição digital	280	5.802	1.624.560,00
Ortofoto Digital	80	5.802	464.160,00
Reambulação	40	5.802	232.080,00
Edição	80	5.802	464.160,00
Relatório técnico final	50	5.802	290.100,00
Total			4.003.380,00
Média por km ²			690,00

Fonte: TERRACAP (2010).

Para a geração de uma base cartográfica utilizando-se imagens de alta resolução, deve-se levar em consideração duas situações: a existência de curvas de nível que permitam a geração do MDE ou a aquisição de imagens estereoscópicas que permitam a geração desse dado. As Tabelas 15.14 e 15.15 apresentam as duas situações.

Tabela 15.14 Valores de custos com imagem de alta resolução e outros serviços (GeoEye e WorldView2).

Etapa	n° de Profissionais	Custo/Hora		Custo (R\$/km ²)
		Profissional	Equipamento	
Composição colorida	01	10,00	4,40	14,40
Seleção de GCPs	01	15,00	4,40	19,40
Levantamento de GCPs	03	36,80	8,00	44,80
Correção diferencial	02	24,50	4,40	24,90
Geração do DEM	01	15,00	4,40	19,40
Coleta de Pontos do DEM	01	15,00	4,40	19,40
Ortorretificação	01	15,00	4,40	19,40
Restituição (Digitalização Heads-up)	01	10,00	4,40	14,40
Edições e correções	02	36,80	4,40	41,20
Reambulação	02	30,00	4,40	34,40
Avaliação da precisão/exatidão	03	36,80	8,00	44,80
Edições finais	01	10,00	4,40	14,40
Transporte	01	0,00	65,00	65,00
Coordenação técnica	01	30,00	-	30,00
Total dos serviços ²				405,90

¹Imagem comercializada com efemérides, permitindo a ortorretificação

²Valor sem considerar o custo das imagens

Fonte: Adaptada de Bias (2003)

Tabela 15.15 Custos do produto por km² (GeoEye e WorldView2)

Característica da Imagem	Custo (R\$/km ²)	Total dos Serviços Tabela 12	Custo Total
Valor por km ² GeoEye Reference	210,00	405,90	615,90
Valor por km ² GeoEye Ortho Kit	95,00		500,90
Valor por km ² WorldView Stereo	207,00		612,90
Valor por km ² WorldView Básico	63,00		468,90

Com base nos dados analisados pode-se afirmar que as imagens de alta resolução GeoEye e WorldView2 têm a capacidade de atenderem à geração de bases cartográficas na escala 1:10.000. De acordo com a avaliação do erro gráfico, ficou demonstrado na Tabela 15.11 que para uma escala de 1:10.000, o erro gráfico deve ser igual ou inferior a 4 m². Assim, as imagens em questão estão dentro da faixa: 1,68m² nas imagens GeoEye, equivalente a 42% da área do pixel limite; e 2,5 m² nas imagens WorldView2, representando 62,5% da área do pixel limite. Como vimos, a frequência Nyquist estabelece que somente alvos com tamanho de pelo menos dois pixels podem ser representados pela imagem, com base no erro gráfico apresentado. Verifica-se então, que essas imagens apresentam possibilidade de representação dos alvos, uma vez que estão dentro dos limites do erro gráfico.

Relacionando-se o erro gráfico com o número de pixels definido pela frequência Nyquist, é possível obter a escala máxima de representação dos produtos cartográficos, gerados com base nessa fonte de dados. O erro gráfico (Eg) é equivalente a duas vezes a resolução espacial (Re), obtendo as escalas apresentadas na Tabela 15.11.

$$Eg = 0,0002 \times Fe \quad \text{eq. 15.3}$$

$$Eg = 2 \times Re \quad \text{eq.15.4}$$

Igualando as equações 15.3 e 15.4, tem-se

$$Fe = 10.000 \times Re$$

eq.15.5

sendo, Fe = Fator de escala
Re = Resolução espacial

Aplicando-se a equação 15.5 obtém-se a escala máxima de representação para produtos cartográficos, conforme mostra a Tabela 15.16.

Tabela 15.16 Valores de escala em relação à resolução espacial

Sensor	Banda espectral	Resolução espacial	Fe = 10.000 x Re	Escala Máxima
IKONOS II	Pancromática	1 metro	10.000	1/10.000
QuickBird 2		0,61 metros	6.100	1/6.100
GeoEye		0,41 metros	4.100	1/4.100
World View		0,50 metros	5.000	1/5.000

Finalmente, relacionando-se os dados da Tabela 15.1, que apresenta a cobertura de apenas 1% do território nacional na escala 1:25.000, com o custo demonstrado na Tabela 15.13 (R\$ 690,00 km²), chega-se à conclusão de que seria necessário um investimento em torno de R\$ 6 bilhões para a cobertura de todo o território nacional (8.514.876 km²).

No que se refere à construção de base cartográfica na escala de 1:10.000, alguns estudos também apontam para um percentual de cobertura de aproximadamente 1% em função de diversos investimentos realizados pelos municípios brasileiros. Assim, com base nos custos da mesma Tabela 15.13, podemos verificar pela Tabela 15.17 que o custo das imagens sofrerá uma redução bastante considerável.

Tabela 15.17 Avaliação do valor percentual entre o mapeamento aerofotogramétrico e com o uso de imagens de alta resolução.

Valor base para comparação – R\$ 690,00 ¹		Diferença Percentual
Valor por km ² GeoEye Reference (R\$)	615,90	- 10,75%
Valor por km ² GeoEye Ortho Kit (R\$)	500,90	- 27,74%
Valor por km ² WorldView Stereo (R\$)	612,90	- 11,20%
Valor por km ² WorldView Básico (R\$)	468,90	- 32,04%

¹ Mapeamento aerofotogramétrico

Do exposto, verifica-se que a utilização de imagens orbitais de alta resolução representa uma real possibilidade para o mapeamento cartográfico. Do ponto de vista da economicidade, as vantagens aumentam se considerarmos que para trabalhos envolvendo grandes áreas o número de imagens a serem adquiridas será bastante grande e a possibilidade de descontos implicará em uma maior redução de custos. Convém lembrar que nas discussões anteriores consideraram-se, para a definição dos preços, os limites mínimos para a aquisição das imagens.

REFERÊNCIAS BIBLIOGRÁFICAS

Balzerek, H. Applicability of IKONOS – Satellite scenes monitoring, classification and evaluation of urbanisation processes in Africa. Case Study of Gombe/Nigéria. Disponível em: <<http://www.rzuser.uni-heidelberg.de/~bu1/sfb/d1/regensb/balzerek.htm> > Acesso em: 20 abr. 2002.

Bartleson, C.J. Colorimetry. Editor Macbeth Color and Photometry Divison Kollmorgem Corporation. Section 16, p.880-922. 1995.

Bias, E. S. Vantagens e limitações das imagens de alta resolução como suporte ao planejamento urbano: o exemplo de Sobradinho-DF. Tese (Doutorado). Instituto de Geociências e Ciências Exatas, UNESP, Rio Claro, SP, 2002. 280p.

Bias, E. S.; Baptista, G. M. M. Utilização de imagens de alta resolução espacial na análise do verde urbano como ferramenta ao planejamento. In: CONGRESSO INTERNACIONAL SOBRE PLANEJAMENTO E GESTÃO AMBIENTAL EM CENTROS URBANOS, 4. Florianópolis, 2002. ECOURBS 2002. CENTROSUL. p.52 - 53.

Bias, E. S.; Baptista, G. M. M.; Lombardo, M.A. Análise do fenômeno de ilhas de calor urbanas por meio da combinação de dados LANDSAT e IKONOS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XI. Belo Horizonte, 2003. Anais XI SBSR. UFG: 2003. p.1741 – 1748.

Brites, R.S.; Soares, V.P.; Ribeiro, C.A.A.S. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, 1996, Salvador, BA. Anais... São José dos Campos: INPE, 1996. p.813-821.

Câmara G; Souza R.C.M.; Freitas U.M.; Garrido J. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. *Computers & Graphics*, 20: (3) 395-403, 1996.

Ceccato, V.A. Proposta metodológica para avaliação da qualidade de vida urbana a partir de dados convencionais e de sensoriamento remoto, sistema de informações geográficas e banco de dados relacional. 1994. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, 1994.

Chavez, P.S. Jr. An improve dark-subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*, 24:459-479, 1988.

Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1): 35-46, 1991.

Correia, J. D. Atualização cartográfica na escala 1:50.000 utilizando imagens SPOT. 1997. Dissertação (Mestrado em Engenharia Cartográfica) – Instituto Militar de Engenharia, Rio de Janeiro, 1997.

Corte, A.P.D.; Dlugosz, F.L.; Centeno, J.A.S. Testes de limiares para a segmentação de imagens SPOT-5 visando a detecção de plantios florestais. *Revista Acadêmica Ciências Agrárias e Ambientais*, v.6, (2) 249-257, 2008.

Costa, S.M.F. Metodologia alternativa para o estudo do espaço metropolitano, integrando as tecnologias de SIG e sensoriamento remoto: aplicação à área metropolitana de Belo Horizonte. 1996. 177 f. Tese (Doutorado em Engenharia de Transportes) - Universidade de São Paulo, São Paulo, 1996.

Crósta, A.P. ; Moore, J. M.. Geological mapping using Landsat Thematic Mapper Imagery in Almeria Province, Se Spain. *International Journal of Remote Sensing*. V.10 n.3, pp.1147-1160, 1989

Crósta, A.P. *Processamento Digital de Imagens de Sensoriamento Remoto*. 3 ed. IG-UNICAMP. 170 p. 1992.

Cudahy, T.; Souza Filho, C.R. Spectral sensing solutions to mineral exploration challenges. 4 Simp. Bras. Exploração Mineral Simesmin, 2006, Ouro Preto, MG.

Darwish, A.; Leukert K.; Reinhardt W., 2003. Image segmentation for the purpose of object-based classification. In: *Geoscience and Remote Sensing Symposium*, Neubiberg:2003. Disponível em <http://www.definiens.com/pdf/publications/FR07_1420.PDF>. Acesso em: outubro 2006.

Davis, C. J. *Statistic and data analysis in geology*. Third Edition. IE Wiley, 2002.

Drury, S.A. *Image interpretation in Geology*. Allen & Unwin, 135-140. 1987.

Dutra , L.V.; Meneses, P.R. Aplicação da transformação IHS para realce de cores em imagens Landsat. In: SIMPÓSIO LATINO AMERICANO DE SENSORIAMENTO REMOTO, I, 1986, Gramado, RS. Anais, p.675-681, 1986.

Dutra , L.V., Meneses, P.R. Realce de cores em imagens de sensoriamento remoto utilizando rotação de matiz no espaço IHS. In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES, 5, 1987, Campinas, SP. Anais, p.209-212, 1987.

Elachi, C.; Zyl van, J. *Introduction to the physics and techniques of Remote Sensing*. 2nd edition. John Wiley & Sons Inc. Publication, 2006. 552p.

Engesat: <http://www.engesat.com.br/?system=news&eid=433>, acesso realizado em 14 de setembro de 2010.

ENVI Manual Guide: Introduction to ENVI 2006.

Florenzano, T.C.; Tavares Jr. S.S.; Lorena, R.B.; Melo, D.H.T.B. Multiplicação e adição de imagens Landsat no realce de feições da paisagem. In SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10, 2001, Foz do Iguaçu, PR. Anais (cd-rom). São José dos Campos, SP: INPE, 2001.

Freitas, M.A. O uso de imagens de satélite na análise dos padrões de verticalização em áreas metropolitanas: estudo de caso: São Paulo. 1997. Dissertação (Mestrado em Geografia) - FFCL – Universidade de São Paulo, São Paulo, 1997.

Gao, J. Digital analysis of remotely sensed imagery. New York, NY, USA: McGraw-Hill Professional Publishing, 2009. 439 p.

Gonçalves, R.M; Cortes, J.B.R.; Schimidt M.A.R.; Schimalski, M.B. Classificação hierárquica e *fuzzy* de imagens de alta resolução. IN: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. Anais (cd-rom). São José dos Campos, SP: INPE, p.547 - 554.

Gonçalves, L.; Fonseca, A.M.; Caetano, M.: Exploração de imagens de alta resolução do Satélite IKONOS. Disponível em papers/esig41.pdf. Acesso em: 10 abr. 2002.

Gonzalez, R. C., Woods, R.E. *Digital Image Processing*. Second Edition. Upper Saddle River NJ: Prentice Hall, 2002.

Haralick, R.M.; Shanmugam, K.S; Dinstein, I. Textural features for image classification. In: *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3, 610-622, 1973.

Hamburger, D.S. Utilização de informações derivadas de características texturais de imagens orbitais na definição de classes de uso do solo urbano. 1993. 122 f. Dissertação (Mestrado em Sensoriamento Remoto) - INPE, São José dos Campos, 1993.

<http://fisica.ufpr.br/grimm/aposmeteo/cap2/Image119.jpg> acesso em 30 de setembro de

Huet, A.R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25: 295-309, 1988.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) - Manuais: tutorial de geoprocessamento SPRING. 2008.

Ishikawa, M. I; Da Silva, E. Determinação da escala máxima de uso de imagem IKONOS-GEO para aplicação em áreas urbanas: estudo de caso – Araçoiaba da Serra-SP. *Sociedade & Natureza*, 17 (32) 77-85, 2005.

Jacob, E.; François, P.; Schmugge, T.; Vermote E.; French, A.; Oawa, K.. Comparasion of land surface emissivity and radiometric temperature derived from MODIS and ASTER. *Remote Sensing of Environment*, 90:137-152, 2004.

Jensen, J.R. *Introductory Digital Image Processing: A Remote Sensing Perspective*. Upper Saddle River: Pearson Prentice Hall, Third Edition, 2004.

Jensen, J.R. *Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres*. Tradução português 2 Ed. Parentese Editora. São José dos Campos SP, 2009. 598p.

Kasser, M., Y, Egels. *Digital Photogrammetry*. Taylor & Francis, London and New York, 2002.

Kury, E. B. & Vieira, C. A. O. Classificação automática de imagens de alta resolução. In UFVGEO (2001). Acessado em: 18 jan. 2011.

Landis, J.R.; Koch, G.G. The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159-174, 1977.

Leite, N.J. Introdução ao processamento e análise de imagens. IC-UNICAMP 2010. <http://www.ic.unicamp.br/~afalcao/sensremoto/processamento.ppt> Acesso em Julho 2011.

Lillesand, M.T. & Kiefer, F.W. *Remote Sensing and Image Interpretation*. John Wiley & Sons, Inc. 3^a ed. 1994.

Lillesand, T. M.; Kiefer, R.W.; Chipman, J.W *Remote Sensing and Image Interpretation*. NY.: John Wiley & Sons Inc., 5^a ed., 2004.

Lillesand, T.M.; Kiefer, R.W.; Chipman, J.W. *Remote Sensing and Image Interpretation*. Hoboken: John Wiley & Sons Inc., 6^a ed., 2008.

Ma, Z.; Redmond, R.L.. Tau coefficients for accuracy assessment of classification of remote sensing data. *Photogrammetric Engineering and Remote Sensing*, 61(4):453-439, 1995.

Mather, P.M. *Computer Processing of Remotely Sensed Images: an Introduction*. St Edmundsburi Press Ltd, 1987.

Meneses, P.R.; Madeira Netto, J.S. *Sensoriamento Remoto: Reflectância dos Alvos Naturais* (org.). Brasília: Editoras UnB- Embrapa Cerrados. 2001. 262p.

Moran, M.S.; Peters-Lidard, C.D.; Watts, J.M.; McElroy, S. Estimating soil moisture at the watershed scale with satellite-based radar and land surface models. *Canadian Journal of Remote Sensing*, 30(5):805-826, 2004.

Moreira, A .M. *Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação*. Ed Editora UFV, 2^a Ed., Viçosa MG, 2003.

Nascimento, J.P.R.; Madeira, H.M.F.; Pedrini, H. Classificação de imagens usando descritores estatísticos de textura . In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2009, Belo Horizonte, MG. Anais (CDROM)...São José dos Campos, SP: INPE, 2003.

Neubert, M.; Herold, H.; Meinel, G. Evaluation of remote sensing image segmentation quality – further results and concepts. 2006. http://www2.ioer.de/recherche/pdf/2006_neubert_obia.pdf. Acesso em 20/04/2011.

Niero, M.; Foresti, C. Uso do solo urbano da área metropolitana de São Paulo através da análise automática de dados LANDSAT. São José dos Campos: INPE, 1983. 34 p.

Novo, E.M.L. M. Comportamento espectral da água. In: Paulo Roberto Meneses, José da Silva Madeira Netto. (org.) *Sensoriamento Remoto: Reflectância dos Alvos Naturais*. - Editora UNB, EMBRAPA Cerrados, Brasília, 2001.

Novo, E.M.L.M. *Sensoriamento Remoto: Princípios e Aplicações*.. Ed. Edgard Blucher Ltda, 3^a Edição, São Paulo, 2008. 363 p.

Oliveira, M.L.N.; Foresti, C.; Niero, M.; Parreiras, E.M.M.F. Estudo da evolução urbana de Brasília através do uso de dados LANDSAT. São José dos Campos: INPE, 1984. 26 p.

Paradella, W.R.; Santos, A.R.; Veneziani, P.; Cunha, E.S.P. Radars imageadores nas Geociências: estado da arte e perspectivas. *Revista Brasileira de Cartografia*, 57(01): 56-62, 2005.

Penteado, A.H.D.G.; Crósta, A.P.; Souza Filho, C.R. Filtragem de ruídos periódicos por transformadas de Fourier e realce por decorrelação em imagens termais do sensor Geoscan Amss Mk-li no greenstone belt do rio Itapicuru, Ba. In SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9, 1998. Anais (CDROM)...São José dos Campos, SP: INPE, 1998.

Polidorio, A. M.; Franco, C.; Imai N. N.; Tommaselli, A. M. G.; Galo, M. T. Correção radiométrica de imagens multiespectrais CBERS e Landsat ETM usando atributos de reflectância e de cor. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, GO. Anais. São José dos Campos, SP: INPE, 2005.

Ramos, O. T. H. Análise Comparativa entre os principais formatos de armazenamento de imagens. Dissertação de Mestrado - Universidade Presbiteriana Mackenzie. São Paulo. 2000.

Reed, T.E.; Dubuf, J.M.H. A review of recent texture segmentation and feature extraction techniques. *CVGIP: Image Understanding*, v.57, n.3, p.355-372, 1993.

Richards, J. A.; Jia X. *Remote Sensing Digital Image Analysis. An Introduction*. 4^a ed., Springer 2006.

Schowengerdt, R. A. *Remote Sensing Models and Methods for Image Processing*. 3^a ed., Elsevier, 2007.

Sabino, N.O.; Ushizima. D.M.; Costa, L.F.; Rizzati, E.G.; Zago, M. A. *A texture approach to Leukocyte recognition*. In: Real-Time Imaging, Volume 10. Elsevier, 2004, Disponível online 25 setembro de 2004.

Sabins F. F. Jr. *Remote Sensing Principles and Interpretation*. NY: Freeman, 1997.

Sano, E.E.; Rosa, R.; Brito, J.L.S.; Ferreira, L.G. Land cover mapping of the tropical savanna region in Brazil. *Environmental Monitoring and Assessment*, 166:113-124, 2010.

Santos, A.R.; Peluzio, T.M.O; Saito, N.S. *SPRING 5.1.2 passo a passo – aplicações práticas*. Alegre, ES: Gráfica F&M, 2010. 153p. Disponível em: <http://www.mundogeomatica.com.br/spring5x.htm> , acesso em 23/05/2011.

Souto, R.P. Segmentação de imagem multiespectral utilizando-se o atributo matiz. São José dos Campos: INPE, 2000. Disponível em www.obt.inpe.br/pgsere/Souto-R-P-2000/publicacao.pdf. Acesso em: 21 jan. 2011.

Tavares Júnior, J. B.; Ouverney, M. I. M.; Uberti, M. S.; Antunes, M. A. H.: Avaliação de imagens Ikonos II e Quickbird para obtenção de bases cartográficas para o cadastro técnico

municipal. In: COBRAC 2006 Congresso Brasileiro de Cadastro Técnico Multifinalitário. Anais COBRAC. UFSC Florianópolis, Outubro 2006.

Vasconcelos, R. M. GeoTiff - uma abordagem resumida do formato. CPRM - Serviço Geológico do Brasil, Rio de Janeiro. 2002. Disponível em www.cprm.gov.br/publique/media/geotiff.pdf. Acesso em: 10 fev. 2011.

Vaughn, R. C.; Calvin, W. M.; Taranik, J. V. SEBASS Hyperspectral thermal infrared data: surface emissivity measurement and mineral mapping. *Remote Sensing of Environment*, 85:48-63, 2003.

Veronese, V. F; Gonçalves, R. N.; Marques, N. M. G.; Da Silva, M. L. P.; Sokolonski, H. H. Utilização de segmentação e edições pós-classificatórias na solução de confusões de classificação. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2003, Belo Horizonte, MG. Anais, São José dos Campos, SP: INPE, p. 2151 - 2153. 2003

Vrabel, J. Multispectral Imagery Band Sharpening Study. *Photogrammetric Engineering & Remote Sensing*, 62: 9, p. 1075-1083. 1996.

Welch, R. and W. Ahlers. Merging Multiresolution SPOT HRV and Landsat TM Data. *Photogrammetric Engineering & Remote Sensing*, 53:3, p. 301-303. 1987.

Schwartz, W.R., Hélio Pedrini, H. Segmentação de imagens de terrenos baseada na associação de características de texturas com dependência espacial modelada por campo aleatório de Markov. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, GO. Anais, São José dos Campos, SP: INPE, p. 4311-4318, 2005.

Wolf, P. R., Dewitt, B. A.: *Elements of Photogrammetry with Applications in GIS*. McGraw-Hill, 2000.

ÍNDICE ALFABÉTICO

A

Absorção atmosférica, 15
Alta frequência, 172
Along-track, 38
Ambiguidade, radar, 59
Amostragem, 26, 37, 186, 255
Ângulos
 depressão, 62
 incidência local, 74
 sólido, 22
 visada, 62
Arquivo descritor, 80
Atenuação atmosférica, 15
Autocorrelação, 25
ASCII, 81
ASTER, 27, 56
AVNIR2, 229
AVIRIS, 222

B

Baixa frequência, 119, 185
Bandas de radar, 50
Bhattacharyya distância, 216
BIL, 79
Bimodal, 106
BIP, 79
BMP, 805
BSQ, 79

C

Calor, 48
 latente, 49
 sensível, 49
CCD, 38, 39
Clusters, 193, 244, 251
Coeficiente de espalhamento, 16
Comprimento de onda, 4

Compressão, 94
Condução, 48
Constante de Stephan-Boltzman, 12, 50
Convexão, 48
Conversor analógico/digital, 38
Convolução, 101, 187
Coordenadas espaciais, 77
Cor, definição, 121, 122
Cor RGB, 125, 127
Cores primárias, 125

Corpo negro, 12, 49
Correção geométrica, 94
Correlação
 espectral, 154, 221
Cross-track, 36
Cubo de cor, 121, 126

D

Dark subtraction, 89
Detectores termais, 56
Deslocamento de linhas, 91
Deslocamento de pixels, 93
Detecção de bordas, 176, 179
Dilatação, 171, 181
Direção de azimute, 62
Direção de visada, 62
Distorções geométricas, 90, 96
Distorções geométricas sistemáticas, 91
Domínio espacial, 83, 103
Domínio da frequência, 186

E

Emissividade espectral, 51
Emissividade, materiais, 52
Emitância radiante, 12
Endmembers, 231
Energia radiante, 21
Energia cinética, 47
ERTS-1, 2
Erosão, 171, 182
Erro médio quadrático, 236
Erros radiométricos, 82
Escala, para visualização de imagens, 27
Escala, 256
Escatergrama, 239
Espalhamento atmosférico, 87
 Rayleigh, 16
 Mie, 16
 Não-seletivo, 17
Espectrorradiômetro, 45
Espectro, divisão, 19
Espectros de reflectância, 45-46
Esterradiano, 23

F

Far range, 63
Fatiamento, 123

- Fase da onda, 60
 Feições de absorção, 20, 46
 Frequência, 5
 FLAASH, 223
 Filtros
 - banda-passante, 169
 - natureza, 168
 - peso, 172, 178
 - classes, 171
 - mediana, 175
 - bordas, 176, 177
 - lineares, 177
 - primeira derivada, 179
 - segunda derivada, 179
 - gradiente, 184
 - morfológico, 178 179
 Floating point, 79
 Fluxo radiante, 21
 Fluxo de processamento, 82
 Fonte artificial, 57
 Fontes de distorções geométricas, 91, 93
 Formato nativo, 80
 Forshortening, 67, 68
 Fóton, 8, 47
 FOV, 25
 Função polinomial, 96
- G**
 Georreferenciamento, 94
 GeoEye, 242, 251
 Grade de pixels, 91
- H**
 Hexacone, 122, 132
 Hue, 124, 130
- I**
 IFOV, 25, 26
 IHS, 134, 137
 IKONOS II, 250
 Imageador, conceito, 35
 Imagem digital, 77
 Imageadores multiespectrais, 34
 INPE, 1
 Interação macroscópica, 5, 6
 Interação microscópica, 9
 Interferência: construtiva e destrutiva, 69
 Interpolação, 95, 101
 Intervalos espectrais, 20
 Irradiância, 22
- J**
 JPEG, 80
- K**
 Kernel, 176
 k-média, 197
- L**
 Layover, 67, 67
 Lei de Planck, 12
 Lei de Stephan-Boltzman, 54
 Lei de Wien, 50
 Linha ruidosa, 85
 Lóbulo, radar, 67
 Looks, 64
 LUT, 110
 Luz coerente, 69
- M**
 Mapeamento do uso da terra, 239
 Moda, 169
 Máscara, 170
 Matriz
 - co-ocorrência, 183
 - de dados, 77
 Mecanismos de interação, 41
 Medidas de textura, 184
 Missão GT-4, 2
 Modelo corpuscular, 8
 Modelo ondulatório, 4
 Modelo quântico, 43
- N**
 Near range, 63
 Níveis de energia, 8, 9
 Nyquist, 186, 2563
- O**
 Órbita heliossíncrona, 32
 Ordem de transformação, 96,99
 Ortoretificação, 2242
- P**
 Passa-baixa, 174
 Passa-alta, 172
 Pixels ruidosos, 85
 PNG, 80
 Polarização cruzada, 61
 Polarização plano-paralela, 61

Polinômios, 95
Pontos de controle, 95, 96
Pré-processamento, 84
Pseudocores, 123

Q

Quantização, 30
QuickBird, 250

R

Radiação eletromagnética
 onda, 4
 energia, 8
Radiação termal, 49, 52
Radiador seletivo, 54
Radiância, 21
Radiância aditiva, 16, 145
RAR, 58
Razão de contraste, 17
Reamostragem, interpolação, 102
Reflectância, 24
Reflectância, especular, difusora, 6
Registro, 99
Resoluções
 espacial, 25
 espectral, 27
 radiométrica, 30
 temporal, 32
RMS, 97
Ruído coerente, 86
Ruídos espúrios, 82, 85

S

SAR, 58
Saturação, 108
Sensor fotográfico, 34
Sensoriamento remoto, definições, 3
Sinal elétrico, 35
Speckle, 69, 176
Striping, 86
Superfícies lisa, rugosa, 6

T

Taxa, 178
Tempertura
 Aparente, 54
 Cinética, 54
TIFF, 80
TIROS-1, 1
Transformação afim no plano, 96

Transformada de Fourier, 168
Transição eletrônica, 43
Transopaco, 43
Triângulo de cor, 121

U

Unimodal, 110

V

Varredura mecânica, 36
Varredura eletrônica, 38
Variância, 105
Vizinho mais próximo, 101

W

WorldView 2, 252
Wien, lei, 50