

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO INSTITUTO DE GEOCIÊNCIAS DEPARTAMENTO DE GEOGRAFIA PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA ÁREA DE CONCENTRAÇÃO: PLANEJAMENTO E GESTÃO AMBIENTAL

CONSTRUÇÃO DE UM ÍNDICE DE INTERPRETABILIDADE PARA IMAGENS ORBITAIS: UM ESTUDO DE CASO NA BACIA HIDROGRÁFICA DO RIO SÃO JOÃO

ALEXANDRE JOSÉ ALMEIDA TEIXEIRA

Orientadores:

Prof. Dr. Rafael Silva de Barros Profa. Dra. Carla Bernadete Madureira Cruz

> Rio de Janeiro 2016

Alexandre José Almeida Teixeira

CONSTRUÇÃO DE UM ÍNDICE DE INTERPRETABILIDADE PARA IMAGENS ORBITAIS: UM ESTUDO DE CASO NA BACIA HIDROGRÁFICA DO RIO SÃO JOÃO

TESE DE DOUTORADO APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA, INSTITUTO DE GEOCIÊNCIAS, UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, COMO REQUISITO PARCIAL À OBTENÇÃO DO TÍTULO DE DOUTOR EM GEOGRAFIA

Orientadores: Rafael Silva de Barros Carla Bernadete Madureira Cruz

> Rio de Janeiro 2016

Ficha catalográfica

Teixeira, Alexandre José Almeida

Construção de um índice de Interpretabilidade para Imagens Orbitais: Um estudo de caso na bacia hidrográfica do rio São João / Alexandre José Almeida Teixeira. 2016. 358 f.: il.

Tese (Doutorado em Geografia) - Universidade Federal do Rio de Janeiro -UFRJ, Instituto de Geociências, Programa de Pós-Graduação em Geografia, 2016.

Orientadores: Prof. Dr. Rafael Silva de Barros e prof^a. Dra. Carla Bernadete Madureira Cruz

1 Interpretabilidade. 2. Extração de feição cartográfica.

3. Exatidão posicional. 4. Exatidão temática.

FOLHA DE APROVAÇÃO

Alexandre José Almeida Teixeira

CONSTRUÇÃO DE UM ÍNDICE DE INTERPRETABILIDADE PARA IMAGENS ORBITAIS: UM ESTUDO DE CASO NA BACIA HIDROGRÁFICA DO RIO SÃO

JOÃO

Tese submetida ao Corpo Docente do Departamento de Geografia do Instituto de Geociências da Universidade Federal do Rio de Janeiro - UFRJ, como parte dos requisitos necessários à obtenção do grau de Doutor.

Aprovada em: 22 de setembro de 2016.

Prof. Dr. Rafael Silva de Barros Departamento de Geografia / UFRJ

Profa. Dra. Carla B. Madureira Cruz Departamento de Geografia / UFRJ

Prof. Dr. Paulo Márcio L. de Menezes Departamento de Geografia / UFRJ

Prof. Dr. Cláudio João Barreto dos Santos Departamento de Cartografia / UERJ

famille

Dr. Antônio José Ferreira Machado e Silva AMS Keppler Engenharia de Sistemas

À minha família Aos meus amigos Aos meus mestres

AGRADECIMENTOS

Agradeço a Deus pela minha vida e pela força que me permitiu superar as dificuldades surgidas ao longo da criação da tese.

À minha mãe e meu pai *(in memorian*) pelo exemplo de vida e a pela dedicação que sempre tiveram para a minha formação educacional e do meu caráter.

Á minha esposa Natália pelo seu amor, companheirismo, compreensão e pela oportunidade de me permitir o dom da paternidade. Agradeço ao meu filho Flávio pela sua presença na minha vida e aos meus sogros, pela ajuda e apoio dedicados.

À Universidade Federal do Rio de Janeiro e ao Departamento de Geografia pela minha formação acadêmica e pela oportunidade do desenvolvimento da tese. Agradecimento extensivo ao Grupo de Sensoriamento Remoto Espaço, pela disponibilização de suas instalações e equipamentos de gabinete e campo.

Ao IBGE, através da Coordenação de Capacitação e Treinamento, da Diretoria de Geociências e a Coordenação de Cartografia, pela oportunidade na concessão da licença de afastamento do trabalho para a dedicação exclusiva à tese.

Ao Professor Rafael Barros, orientador e amigo, pelos ensinamentos, oportunidades e paciência durante a orientação.

À Professora. Carla Madureira, co-orientadora e amiga, por toda a ajuda no desenvolvimento da tese e pelo meu crescimento acadêmico e profissional durante vários anos de convívio.

Ao Professor Paulo Menezes pelos seus ensinamentos desde a minha formação acadêmica na época da graduação e participação na banca.

Aos membros da banca, Antônio Machado e Cláudio João, pela aceitação do convite e pelas dicas sugeridas para o aprimoramento do trabalho.

Ao Duarte e Aline, amigos de IBGE que me ajudaram na disponibilização de dados fundamentais para o estudo e nas dicas de sensoriamento remoto e cartografia.

vi

Aos alunos de graduação Hugo, Rafael Cardoso, Douglas Oliveira e Rômulo, pela ajuda no processamento dos dados no laboratório e apoio nas atividades de campo.

A todos que, direta ou indiretamente, contribuíram para o desenvolvimento deste trabalho.

RESUMO

A proposta desse trabalho é apresentar e discutir o conceito de interpretabilidade de imagens orbitais usadas para a produção de base cartográfica de referência. Nesse contexto, entende-se por interpretabilidade a adequação de uma imagem para finalidade de interpretação, de forma que seu conteúdo permita a detecção e identificação de objetos sobre a superfície terrestre. Apesar da evolução da automatização de processos para a extração de feições a partir de imagens, a análise visual de um intérprete ainda é necessária para se interpretar os elementos cartográficos e adequá-los às especificações técnicas. Em termos geométricos e de interpretação, busca-se detalhar mais o conhecimento sobre as questões que são determinantes para se definir que sensores são adequados para se atingir à exatidão geométrica e temática esperada para uma dada escala cartográfica. De forma geral, guando as imagens atendem a exigências de exatidão posicional para uma determinada escala, dificilmente oferecem condições satisfatórias para a extração de feições nessa mesma escala. Isto leva à reflexão de que as exatidões posicional e temática de imagens não indicam, necessariamente, uma mesma escala de análise. Além da avaliação da exatidão posicional de uma imagem, a possibilidade de gerar um índice de interpretabilidade pode auxiliar na escolha de insumos mais adequados para a produção cartográfica. Para finalizar, este trabalho esmiúça o conhecimento sobre questões centrais na definição de sensores mais apropriados para se alcançar a exatidão prevista para uma dada escala cartográfica.

Palavras chaves: Interpretabilidade. Extração de feição cartográfica. Exatidão posicional. Exatidão temática.

ABSTRACT

The purpose of this study is to present and discuss the concept of interpretability of orbital images used in the production of a reference cartographic base. In this context, interpretability means the suitability of an image for purposes of interpretation, in such a way that its content allows the detection and identification of objects on Earth's surface. Despite the evolution of automated feature extraction from images, an interpreter's visual analysis is still needed to interpret the cartographic elements and adapt them to technical specifications. In geometric and interpretation terms, it is important to detail the knowledge on issues that are crucial to define which sensors are suitable to reach the expected geometric and thematic accuracy for a given cartographic scale. In general, when the images meet the requirements for positional accuracy for a given scale, they rarely offer satisfactory conditions for feature extraction on the same scale. This suggests that the positional and thematic accuracies do not necessarily indicate the same analysis scale. Added to the assessment of an image positional accuracy, the possibility of generating an interpretability index can help in choosing the most appropriate inputs for cartographic production. Finally, this paper deeply analyzes the knowledge on key issues in the definition of the most appropriate sensors to reach the expected accuracy for a given cartographic scale.

Keywords: Interpretability. Cartographic Feature Extraction. Positional Accuracy. Thematic Accuracy.

SUMÁRIO

1 INTRODUÇÃO	1
1.1. OBJETIVOS	4
2 REVISÃO TEÓRICA	9
2.1 EXTRAÇÃO E CLASSIFICAÇÃO DE FEIÇÕES: BASES PARA	Ą
INTERPRETAÇÃO DE IMAGENS	9
2.1.1 Segmentadores	12
2.1.1.1 Segmentadores baseados por descontinuidades	13
2.1.1.2 Segmentadores baseados em similaridades	18
2.1.2 Classificação	21
2.1.2.1 Classificação supervisionada e não supervisionada	21
2.1.2.2 Algoritmos orientados a pixel, regiões e objetos	24
2.2 PANORAMA DA CARTOGRAFIA DE REFERÊNCIA	27
2.2.1 Estados Unidos	28
2.2.2 Canadá	30
2.2.3. Austrália	31
2.2.4 México	34
2.2.5 Brasil	36
2.3 SENSORES REMOTOS	39
2.3.1 OLI / LANDSAT-8	45
2.3.2 AVNIR-2 / ALOS	48
2.3.3 Rapideye	49
2.4 CONTROLE DE QUALIDADE DO DADO CARTOGRÁFICO	51
2.4.1 Consistência lógica	56
2.4.2 Completude	62
2.4.3 Exatidão posicional	63
2.4.4 Exatidão temática	66
2.4.5 Exatidão temporal	69
3 INTERPRETABILIDADE	71
3.1 DETECÇÃO E IDENTIFICAÇÃO	72
3.2 INTERPRETAÇÃO E INTERPRETABILIDADE	74
3.3 EXEMPLOS DE CRITÉRIOS DE INTERPRETABILIDADE	80
3.3.1 Classificação de uso e cobertura do solo da USGS	80

3.3.2 Escalas Nacionais de Valoração da Interpretação de Image	e ns 82
3.4 DETECÇÃO E IDENTIFICAÇÃO DE FEIÇÕES CARTOGRÁ	FICAS NA
BHRSJ	89
3.4.1 Caracterização da área de estudo	92
3.4.1.1 Caracterização geomorfológica	95
3.4.1.2 Caracterização hidrológica	98
3.4.1.3 Caracterização da cobertura vegetal	99
3.4.1.4 Caracterização socioeconômica	100
3.4.2 Processo de Inspeção para avaliação da interpretabilidade	101
3.4.2.1 Categorias e classes analisadas	102
3.4.2.2 Recortes espaciais e unidades de amostragem para a avalia	ção da
interpretabilidade	132
3.4.3 Levantamento de campo	136
4 AVALIAÇÃO GEOMÉTRICA E RADIOMÉTRICA DAS IMAGENS	139
4.1 AVALIAÇÃO GEOMÉTRICA	140
4.1.1 Levantamento dos pontos de avaliação	140
4.1.2 Seleção das imagens	141
4.1.3. Estimativa da exatidão posicional a partir do PEC	143
4.1.4 Análise de Tendência	144
4.1.5 Resultados da avaliação geométrica	148
4.2 AVALIAÇÃO RADIOMÉTRICA	149
4.2.1 Correção atmosférica	149
4.2.2 Características das cenas e parametrização	151
4.2.3 Resultados da avaliação radiométrica das imagens RapidE	i ye 153
4.2.4 Resultados da avaliação radiométrica das imagens AVNIR-	-2\ALOS 157
4.2.5 Resultados da avaliação radiométrica das imagens OLI\LA	NDSAT-8 161
4.2.6 Análise final dos resultados da correção radiométrica	165
5. INDICADOR DE DETECÇÃO	167
5.1 CONSTRUÇÃO DO INDICADOR DE DETECÇÃO	170
5.1.1 Qualidade da segmentação	170
5.1.2 Qualidade da Detecção das Extensões	175
5.1.3 Qualidade de Detecção dos Objetos	182
5.1.4 Qualidade da Forma	183

5.1.5 Qualidade Posicional	189
5.1.6 Indicador de Detecção	193
5.2 EXTRAÇÃO DAS FEIÇÕES CARTOGRÁFICAS NA BHRSJ	194
5.2.1 Extração do sistema de transporte	195
5.2.2 Extração da vegetação	201
5.2.3 Extração da hidrografia	213
5.3 GERAÇÃO DO INDICADOR DE DETECÇÃO NA BHRSJ	220
5.3.1 Avaliação da qualidade da segmentação	220
5.3.1.1 Qualidade da Homogenidade Interna	222
5.3.1.2 Qualidade da Separabilidade entre Segmentos Vizinhos	225
5.3.1.3 Qualidade da Segmentação	228
5.3.2 Avaliação da Qualidade da Detecção das Extensões	230
5.3.3 Avaliação da Qualidade de Detecção dos Objetos	238
5.3.4 Avaliação da Qualidade de Forma	241
5.3.5 Avaliação da Qualidade Posicional	244
5.3.6 Cálculo do Indicador de Detecção	251
5.3.7 Conclusões	254
6. INDICADOR DE IDENTIFICAÇÃO	257
6.1 CONSTRUÇÃO DO INDICADOR DE IDENTIFICAÇÃO	259
6.1.1 Qualidade de Identificação das Extensões	259
6.1.2 Qualidade de Identificação dos Objetos	262
6.1.3. Qualidade de Concordância	264
6.1.4 Indicador de Identificação	267
6.2 CLASSIFICAÇÃO DAS FEIÇÕES CARTOGRÁFICAS	268
6.2.1 Classificação do sistema de transporte	268
6.2.2 Classificação da hidrografia	274
6.2.3 Classificação da vegetação	280
6.2.4 Validação da classificação	291
6.3 GERAÇÃO DO INDICADOR DE IDENTIFICAÇÃO NA BHRSJ	294
6.3.1 Qualidade da Identificação das Extensões	294
6.3.2 Qualidade da Identificação dos Objetos	297
6.3.3 Qualidade de Concordância	300
6.3.4 Cálculo do Indicador de Identificação	304

6.3.5 Conclusões	307
7. ÍNDICE DE INTERPRETABILIDADE	308
7.1 CONSTRUÇÃO DO ÍNDICE DE INTERPRETABILIDADE	308
7.1.1 Interpretabilidade por feição cartográfica, categoria e sensor	311
7.2 GERAÇÃO DO ÍNDICE DE INTERPRETABILIDADE NA BHRSJ	316
7.2.1 Interpretabilidade por feição	316
7.2.2 Interpretabilidade por categoria	332
7.2.3 Interpretabilidade por sensor	337
7.2.4 Conclusões	339
8 CONSIDERAÇÕES FINAIS	341
9 REFERÊNCIAS BIBLIOGRÁFICAS	345

LISTA DE FIGURAS

Figura 2.1: Exemplo de aplicação de filtro passa-baixa	15
Figura 2.2: Exemplo de aplicação de filtro passa-alta	16
Figura 2.3: Exemplo de aplicação de filtro de Sobel	17
Figura 2.4: Probabilidade de um pixel pertencer a uma determinada classe,	
considerando uma distribuição normal.	24
Figura 2.5 Importância da classificação contextual. A adição de um garfo e	
uma faca imediatamente classifica o círculo como um prato	25
Figura 2.6 Ilustração de uma rede hierárquica de objetos de imagem	26
Figura 2.7: Folha topográfica 1:24.000 em GeoPDF	29
Figura 2.8: Mapeamento 1:20.000 (A) e 1:100.000 (B) em Quebec	31
Figura 2.9: Exemplo extração de ferrovias	33
Figura 2.10: Exemplo extração de canais de drenagem	34
Figura 2.11: Extração de elementos sobre uma ortofoto para mapeamento	
1:20.000	36
Figura 2.12: Portal de mapas do IBGE.	39
Figura 2.13: Exemplos de precisão e acurácia	55
Figura 2.14: Feições da categoria Hidrografia da EDGV.	61
Figura 3.1: Requisitos de Imagens para determinadas aplicações	79
Figura 3.2: Algumas tarefas possíveis em uma imagem QuickBird	86
Figura 3.3: Quadro comparativo entre as metodologias de interpretabilidade	
usada pela USGS e NIIRS	88
Figura 3.4: Fluxograma com as principais etapas de desenvolvimento do índice	
de interpretabilidade.	91
Figura 3.5: Mapa de localização da bacia hidrográfica do rio São João	94
Figura 3.6: Mapa geomorfológico da bacia do rio São João	97
Figura 3.7: Classes de hidrografia	103
Figura 3.8: Exemplo de massa d´água: Lagoa de Juturnaíba.	104
Figura 3.9: Localização da posição da foto na Lagoa de Jurtunaíba	106
Figura 3.10: Exemplo de trecho de massa d´água: rio São João	107
Figura 3.11: Localização da posição da foto no rio São João.	108
Figura 3.12: Massa d´água (A) e trecho de massa d´água (B)	109
Figura 3.13: Limite de Massa d'água separando dois trechos de massa dá	

água (A) e limite de massa d´água separando o canal do oceano (B)	110
Figura 3.14: Modelo de dados da categoria Vegetação	111
Figura 3.15: Exemplo de manguezal	113
Figura 3.16: Localização da foto na área de manguezal	114
Figura 3.17: Exemplo de floresta nas margens do rio São João	115
Figura 3.18: Localização da foto na área de floresta na imagem	117
Figura 3.19: Exemplo de canavial na bacia do São João	119
Figura 3.20: Localização da foto na área de canavial na imagem RapidEye	120
Figura 3.21: Paisagem de campo com a floresta ao fundo	121
Figura 3.22: Delimitação de Campo	122
Figura 3.23: Localização da foto na área de campo na imagem RapidEye	123
Figura 3.24: Modelo de dados da categoria Sistema de Transporte	124
Figura 3.25: Modelo de dados dos subsistemas Ferroviário e Rodoviário	125
Figura 3.26: Exemplos de trecho rodoviário pavimentado (A) e leito natural (B)	126
Figura 3.27: Localização da foto referente ao trecho rodoviário pavimentado	127
Figura 3.28: Localização da foto referente ao trecho rodoviário de leito natural	128
Figura 3.29: Exemplo de arruamento	130
Figura 3.30: Localização da foto referente ao arruamento	131
Figura 3.31: Localização dos recortes na área de estudo	133
Figura 3.32: Exemplos de lotes e unidades de amostragem	135
Figura. 4.1: Distribuição dos pontos para avaliação das imagens	141
Figura. 4.2: Comparação entre reflectâncias de floresta para as imagens	154
Rapideye	
Figura. 4.3: Comparação entre as reflectâncias de solo exposto para as	
imagens Rapideye.	155
Figura. 4.4: Comparação entre as reflectâncias de água em canais fluviais	
para as imagens Rapideye.	156
Figura 4.5: Comparação entre a imagem original (a) e a imagem corrigida (b).	157
Figura 4.6: Comparação entre reflectâncias de floresta para as imagens	
Rapideye.	158
Figura. 4.7: Comparação entre as reflectâncias de solo exposto para as	159
imagens Rapideye.	
Figura. 4.8: Comparação entre as reflectâncias de água em canais fluviais	

XV

para as imagens Rapideye	160
Figura 4.9: Comparação entre a imagem original (a) e a imagem corrigida (b).	161
Figura 4.10: Comparação entre as reflectâncias de floresta para as imagens	
OLI	162
Figura. 4.11: Comparação entre as reflectâncias de solo exposto para as	
imagens OLI	163
Figura. 4.12: Comparação entre as reflectâncias de água em canais fluviais	
para as imagens OLI	164
Figura 4.13: Comparação entre a imagem original (a) e a imagem corrigida (b).	165
Figura 5.1: Exemplo de regiões para o cálculo da QSSV	172
Figura 5.2: Continuidade de drenagem em uma imagem com 5 m de resolução	
espacial.	176
Figura 5.3: Descontinuidade da drenagem em uma imagem com 10 m de	
resolução espacial.	176
Figura 5.4: Extração de dois perímetros de massa d´água.	184
Figura 5.5: Amostra de uma feição linear representada nas bases	
cartográficas.	185
Figura 5.6: Método da Influência do Vértice	191
Figura 5.7: Atividades de extração das feições do sistema viário	197
Figura 5.8: Extração da hidrografia na imagens RapidEye	198
Figura 5.9: Extração do sistema de transporte na imagens AVNIR-2	199
Figura 5.10: Extração do sistema de transporte nas imagens OLI/LANDSAT-8	200
Figura 5.11: NDVI dos recortes das imagens RapidEye.	205
Figura 5.12: NDVI dos recortes das imagens AVNIR-2	206
Figura 5.13: NDVI dos recortes das imagens OLI	207
Figura: 5.14: Exemplo de três níveis de segmentação top-down.	209
Figura 5.15: Exemplo de saída gráfica do algoritmo ESP	211
Figura 5.16: Saída gráfica do algoritmo ESP para a imagem do recorte 1 do	
RapidEye	212
Figura 5.17: Segmentadores Multiresolução (A) e contrast Split (B).	215
Figura 5.18: Extração da hidrografia na imagens RapidEye.	216
Figura 5.19: Extração da hidrografia na imagens AVNIR-2.	217
Figura 5.20: Extração da hidrografia nas imagens OLI.	218

Figura 5.21: Foto da calha de um canal fluvial seco na área do recorte 3.	219
Figura 5.22: Atividades de extração das feições lineares de hidrografia	220
Figura 5.23 Exemplos de amostras de polígonos para avaliação de	
segmentação.	221
Figura: 5.24: Gráficos que comparam os valores da QHI usando ESP e o modo	
empírico.	223
Figura: 5.25: Gráficos que comparam os valores de QSSV usando ESP e o	
modo empírico.	226
Figura: 5.26: Gráficos que comparam os valores da QS usando ESP e o modo	0
empírico.	229
Figura 5.27: Exemplo de fusão entre polígonos.	236
Figura 5, 28: Valores das discrepâncias médias das amostras para as classes	
extraídas nos três sensores.	249
Figura 6.1: Comparação entre as bandas do vermelho (A) e a borda do	
Vermelho (B)	269
Figura 6.2: Classificação do sistema de transportes nas imagens RapidEye.	271
Figura 6.3: Classificação do sistema de transportes nas imagens AVNIR-2	272
Figura 6.4: Classificação do sistema de transportes nas imagens OLI.	273
Figura 6.5: Sobreposição entre a drenagem da base 1:25.000 trechos de	
massa d´água extraídas da imagem RapiEye	275
Figura 6.6: Tarefas para identificação dos trechos de massa d água e massa	
d´água	276
Figura 6.7: Classificação da hidrografia nas imagens RapidEye.	277
Figura 6.8: Classificação da hidrografia nas imagens AVNIR-2	278
Figura 6.9: Classificação da hidrografia nas imagens OLI.	279
Figura 6.10: NDVI como descritor usando lógica <i>fuzzy</i> .	283
Figura 6.11: Chaves de interpretação para análise visual.	286
Figura 6.12: Classificação da vegetação nas imagens RapidEye.	288
Figura 6.13: Classificação da vegetação nas imagens AVNIR-2	289
Figura 6.14: Classificação da vegetação nas imagens OLI.	290
Figura 6.15: Diferença de classificação entre a ortofoto (campo) e a imagem	
RapidEye (cultivo).	291
Figura 6.16 Diferença de classificação entre a ortofoto (campo) e a imagem	

RapidEye (cultivo).	292
Figura 6.17: Diferença de classificação entre a ortofoto (campo) e a imagem	
AVNIR-2 (cultivo).	293
Figura 6.18: Diferença de classificação entre a ortofoto (campo) e a imagem	
OLI (cultivo).	293
Figura 7.1: Esquema com a composição dos indicadores para a composição	
do índice de interpretabilidade	309

LISTA DE TABELAS E QUADROS

Quadro 2.1: Principais sensores óticos em operação.	42
Quadro 2.2: Principais características do LANDSAT-8	46
Quadro 2.3: Faixas espectrais e principais aplicações do OLI\LANDSAT-8	47
Quadro 2.4: Principais características do PRISM e AVNIR-2	49
Quadro 2.5: Bandas espectrais do RapidEye.	50
Quadro 2.6: Especificações da norma ISO que tratam de dados geográficos	52
Quadro 2.7: Critérios de avaliação da consistência lógica	57
Quadro 2.8: Categorias de informação da EDGV.	60
Quadro 2.9: Critérios de avaliação da completude.	62
Tabela 2.1: Completude por classe de feição, conforme ISO 19113	63
Quadro 2.10: Critérios de avaliação da exatidão posicional	64
Tabela 2.2: Precisão (EP) e acurácia (PEC) da Planimetria do Produto	
Cartográfico	65
Quadro 2.11: Critérios de avaliação da exatidão temática	67
Tabela 2.3: Representação de uma matriz de confusão	68
Quadro 2.12: Critérios de avaliação da exatidão temporal.	70
Quadro 3.1: Chaves de interpretação	75
Quadro 3.2: Chave de interpretação desenvolvida para imagens Radarsat	76
Quadro 3.3: Requisitos mínimos dos sensores para atender aos níveis do	
mapeamento.	81
Quadro 3.4: Categorias e níveis de Informação para o uso e cobertura do solo.	81
Quadro 3.5: Variações do NIIRS	82
Quadro 3.6: Tarefas do padrão NIIRS para aplicação civil nos Estados Unidos.	84
Quadro 3.7: Especificação de interpretabilidade e comprimentos espectrais	
necessários e desejáveis para imagens multiespectrais.	85
Tabela 3.1: Valores de NIIRS para seis imagens dos satélites IKONOS e	
Quickbird	88
Tabela 3.2: Municípios inseridos na bacia do rio São João	93
Quadro 3.8: Tipos de cobertura vegetal na área da bacia	99
Quadro 4.1: Características das cenas AVNIR-2\ ALOS.	142
Quadro 4.2: Características das cenas RapidEye.	142
Tabela 4.1: Valores de erro das imagens avaliadas, segundo o PEC.	144

Tabela 4.2: Fórmulas para a Estimativa do EMQ e análise de tendência.	146
Tabela 4.3: Inferências estatísticas das imagens avaliadas	147
Tabela 4.4: Comparação da avaliação posicional entre os métodos.	149
Tabela 4.5: Parâmetros dos sensores e de iluminação das cenas RapidEye.	152
Tabela 4.6: Parâmetros dos sensores e de iluminação das cenas AVNIR-2	152
Tabela 4.7: Parâmetros dos sensores e de iluminação da cena OLI	152
Tabela 4.8: Informações de localização.	153
Tabela 5.1: Matriz de vizinhança espacial e a média dos níveis de cinza (NC)	
de quatro áreas segmentadas.	172
Tabela 5.2: Matriz de vizinhança espacial e a média dos níveis de cinza (NC)	
de quatro áreas segmentadas.	173
Tabela 5.3: Exemplo de elementos extraídos por feições.	180
Tabela 5.4: Comprimentos mínimos para aquisição.	181
Tabela 5.5: Áreas mínimas para aquisição.	181
Tabela 5.6: Exemplo do cálculo da QOO.	183
Tabela 5.7: Distância média entre vértices na base 1:25.000.	186
Tabela 5.8: Distância média entre vértices na base 1:50.000.	187
Tabela 5.9: Projeção do número de vértices nas bases 1:100.000 e 1:250.000	188
Tabela 5.10: Valores da QP associados ao enquadramento do PEC.	193
Tabela 5.11: Valores de escala usando como referência o algoritmo Estimation	
Scale Parameter	213
Tabela 5.12: Valores da QHI das classes	224
Tabela 5.13: Valores da QHI normalizados	225
Tabela 5.14: Valores da QSSV por classe e sensor	227
Tabela 5.15: Valores da QSSV normalizados.	228
Tabela 5.16: Valores do QS por classe	230
Tabela 5.17: Percentual de elementos de massa d´água extraídos completos	
por dimensão de área.	231
Tabela 5.18: Percentual de elementos da classe vegetação extraídos	
completos por dimensão de área.	232
Tabela 5.19: Percentual de elementos de trecho de massa d´água extraídos	
completos por dimensão de área.	233
Tabela 5.20: Percentual de elementos de trecho de drenagem extraídos	

completos por comprimento mínimo extraído	234
Tabela 5.21: Percentual de elementos de rodovia de leito natural extraídos	
completos por extensão mínima	235
Tabela 5.22: Percentual de elementos de arruamento extraídos completos por	
extensão mínima.	235
Tabela: 5.23: Percentual de erros de omissão das classes por sensor.	237
Tabela 5.24: Valores da Qualidade de Detecção de Extensão	237
Tabela 5.25: Valores da Qualidade de Detecção dos Objetos das classes	
extraídas do sensor RapidEye.	239
Tabela 5.26: Valores da Qualidade de Detecção dos Objetos das classes	
extraídas do sensor AVNIR-2.	240
Tabela 5.27: Valores da Qualidade de Detecção dos Objetos das classes	
extraídas do sensor OLI.	241
Tabela 5.28: Valores de distância média dos vértices da base de referência	
(DMVR), da base extraída (DMVE) e a relação da forma (RE).	242
Tabela 5.29: Comparação entre distância média entre as bases de referência e	
projetadas	243
Tabela 5.30: Valores de Qualidade de Forma	244
Tabela 5.31: Discrepância média estre a base extraída com a base do IBGE e	
o tracking.	245
Tabela 5.32: valores de CE90 para as classes extraídas nos três sensores.	250
Tabela 5.33: Classificação por escala segundo o PEC.	250
Tabela 5.34: valores da Qualidade Posicional por classe para os três sensores.	251
Tabela 5.35: Indicador de detecção para as classes extraídas no RapiEye.	252
Tabela 5.36: Indicador de detecção para as classes extraídas no AVNIR-2	253
Tabela 5.37: Indicador de detecção para as classes extraídas no OLI.	254
Tabela 6.1: Exemplo da obtenção do QCE	261
Tabela 6.2: Exemplo da obtenção do QCO	263
Tabela 6.3: Matriz de confusão para avaliação temática de feições lineares.	266
Tabela 6.4: Matriz de confusão para avaliação temática de feições poligonais.	267
Quadro 6.1: Utilidade de alguns descritores	281
Quadro 6.2: Principais descritores para a classificação	285
Tabela: 6.5: Percentual de erros de comissão das classes por sensor.	294

Tabela: 6.6: Valores de QIE das classes para o RapidEye	295
Tabela: 6.7: Valores de QIE das classes para o AVNIR-2	296
Tabela: 6.8: Valores de QIE das classes para o OLI	296
Tabela 6.9: Qualidade de Identificação de Objetos para o sensor RapiEye.	298
Tabela 6.10: Qualidade de Identificação de Objetos para o sensor AVNIR-2.	299
Tabela 6.11: Qualidade de Identificação de Objetos para o sensor OLI.	300
Tabela 6.12: Matriz de confusão entre as classes poligonais do sensor	
RapiEye.	300
Tabela 6.13: Matriz de confusão entre as classes lineares extraídas do sensor	
RapiEye.	301
Tabela 6.14: Matriz de confusão entre as classes poligonais extraídas do	
sensor AVNIR-2.	301
Tabela 6.15: Matriz de confusão entre as classes lineares extraídas do sensor	
AVNIR-2.	302
Tabela 6.16: Matriz de confusão entre as classes poligonais extraídas do	
sensor OLI	302
Tabela 6.17: Matriz de confusão entre as classes lineares extraídas do sensor	
OLI.	303
Tabela 6.18: Indicador de Identificação para as classes extraídas no RapiEye.	304
Tabela 6.19: Indicador de Identificação para as classes extraídas no AVNIR-2	305
Tabela 6.20: Indicador de Identificação para as classes extraídas no OLI.	306
Tabela 7.1: Índice do coeficiente Kappa e o correspondente conceito do	
desempenho da classificação	310
Tabela 7.2: Proposta do Índice de Interpretabilidade	311
Quadro 7.1: Exemplo de geração do índice de Interpretabilidade por feição.	313
Quadro 7.2: Exemplo de geração do índice de Interpretabilidade por categoria	314
Quadro 7.3: Exemplo de geração do índice de Interpretabilidade por sensor	316
Tabela 7.3: Escalas adequadas para cada classe extraída no RapidEye.	318
Tabela 7.4: Índice de interpretabilidade para as classes extraídas no	
RapidEye.	319
Tabela 7.5: Comparação entre o índice de Interpretabilidade das classes com	
os percentuais extraídos na RapidEye.	321
Tabela 7.6: Adequação do índice de Interpretabilidade das classes extraídas	

no RapidEye por escala.	322
Tabela 7.7: Escalas adequadas para cada classe extraída no AVNIR-2.	324
Tabela 7.8: Índice de interpretabilidade para as classes extraídas no AVNIR-2.	325
Tabela 7.9: Comparação entre o índice de Interpretabilidade das classes com	
os percentuais extraídos no sensor AVNIR-2.	327
Tabela 7.10: Adequação do índice de Interpretabilidade das classes extraídas	
no RapidEye por escala.	328
Tabela 7.11: Escalas adequadas para cada classe extraída no OLI.	329
Tabela 7.12: Índice de interpretabilidade para as classes extraídas no OLI.	330
Tabela 7.13: Comparação entre o índice de Interpretabilidade das classes com	
os percentuais extraídos do sensor OLI.	331
Tabela 7.14: Adequação do índice de Interpretabilidade das classes extraídas	
no OLI por escala	332
Tabela 7.15: Escalas adequadas para cada classe extraída no RapidEye.	333
Tabela: 7.16: Escalas adequadas para cada classe extraída no AVNIR-2	334
Tabela 7.17: Escalas adequadas para cada classe extraída no OLI	335
Tabela 7.18: Valores de ID das classes extraídas no RapidEye calculados para	
as categorias.	336
Tabela 7.19: Adequação do índice de Interpretabilidade das categorias.	337
Tabela 7.20: Escalas adequadas para as imagens de cada sensor.	338
Tabela 7.21: Valores do índice de interpretabilidade (IINT) para as imagens	
dos três sensores.	338
Tabela 7.22: Adequação do índice de Interpretabilidade das categorias.	339

LISTA DE SIGLAS

ALOS: Advanced Land Observation Satellite

APA: Área de Proteção Ambiental

ATCOR: Atmospheric and Topographic Correction for Satellite Imagery

AVNIR-2: Advanced Visible and Near Infrared Radiometer type 2

BCIM: Base Contínua do Brasil ao Milionésimo

CONCAR: Comissão Nacional de Cartografia

CPRM: Companhia de Pesquisa de Recursos Minerais

CEOS: Committee on Earth Observation Satellites

DER: Departamento de Estradas de Rodagem

DSG: Diretoria de Serviço Geográfico

DTED: Digital Terrain Elevation Data

EMPLASA: Empresa Paulista de Planejamento Metropolitano

ET-EDGV: Especificação Técnica para Estruturação de Dados Geoespaciais Vetoriais

ET-ADGV: Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais

ET-CQPCDG: Especificação Técnica do Controle de Qualidade dos Produtos

de Conjuntos de Dados Geoespaciais

FCA: Ferrovia Centro Atlântica

FLAASH: Fast Line-of-sight Atmospheric Analysis of Spectral Hypercube

GEOBIA: Geographic Object-Based Image Analysis,

GNSS: Sistema Global de Navegação por Satélite

GSD: Ground Sampled Distance

IBGE - Instituto Brasileiro de Geografia e Estatística

IDE: Infraestrutura de Dados Espaciais

IDET: Indicador de Detecção

IHI: Índice de Homogeneidade Interna

IIDE: Indicador de Identificação

INDE: Infraestrutura Nacional de Dados Espaciais

INCRA: Instituto Nacional de Colonização e Reforma Agrária INEGI: Instituto Nacional de Estadística y Geografía

INSPIRE: Infrastructure for Spatial Information in Europe ISO: International Organization for Standardization IRARS: Imagery Resolution Assessments and Reporting Standards Committee ISSV: Índice de Separabilidade entre Segmentos Vizinhos LCCS: Classification System. Land Cover Classification System LIDAR: Light Detection and Ranging MMA: Ministério do Meio Ambiente MND: Mapoteca Nacional Digital MOTRAN: Moderate Resolution Atmospheric Transmission MTD: Mapoteca Topográfica Digital NIIRS: National Image Interpretability Rating Scales NTDB: National Topographic Data Base NRCan: Natural Resources Canada OGC: Open GIS Consortium OLI: Operational Land Imager PALSAR: Phased Array type L-band Synthetic Aperture Radar PEC: Padrão de Exatidão Cartográfica PEC-PCD: Padrão de Exatidão Cartográfica dos Produtos Cartográficos Digitais PDC:Programa Especial de Dinamização da Cartografia Terrestre QC: Qualidade de Concordância QDE: Qualidade da Detecção das Extensões QDO: Qualidade da Detecção dos Objetos QIE: Qualidade da Identificação das Extensões QIO: Qualidade da Identificação dos Objetos QF: Qualidade da Forma **QP:** Qualidade Posicional QHI: Qualidade de Homogeneidade Interna QS: Qualidade da Segmentação QSSV: Qualidade de Separabilidade entre Segmentos Vizinhos REIS: RapidEye Earth Imaging System RER: Relative Edge Response RMSE: Root Mean Square Error SCN: Sistema Cartográfico Nacional

SIG: Sistema de Informações Geográficas *SRTM: Shuttle Radar Topography Mission* TBCD: Tabela da Base Cartográfica Digital *TIRS: Thermal Infrared Sensor* USGS: *United States Geological Survey*

1 INTRODUÇÃO

Atualmente, a sociedade possui acesso a uma grande quantidade de dados e informações geoespaciais gerados por instituições produtoras, seja na esfera governamental, nas ações da iniciativa privada e pela comunidade acadêmica. Além disso, a multiplicidade de ferramentas geotecnológicas amplia o acesso a este tipo de conteúdo por uma variedade de usuários, muitos dos quais despreparados para uma utilização consciente e crítica, que auxilie na avaliação e solução de problemas relacionados à qualidade do dado.

Ao manipular e integrar dados produzidos por diferentes produtores, o usuário pode encontrar sérias inconsistências, sendo alguns exemplos os erros de traçado (caráter geométrico) e de interpretação. Os erros de traçado podem estar associados a erros de posicionamento do dado, considerando os parâmetros cartográficos inerentes a essa propriedade, como os sistemas geodésicos e de coordenadas. Por outro lado, os erros de interpretação estão associados a imperfeições dos atributos qualitativos e à exatidão dos atributos quantitativos dos elementos presentes no mapa, ou seja, estão relacionados aos processos de extração de feições cartográficas e às suas respectivas classificações no contexto do mapeamento.

Além disso, mapeamentos relacionados à mesma temática podem apresentar legendas completamente diferentes, originando problemas de compatibilidade entre as classes de mapeamento. Esta situação é muito observada, por exemplo, em mapas de uso e cobertura do solo. Essa variedade de legendas e a necessidade na sistematização das avaliações de erros nos dados fazem refletir sobre a necessidade de adoção de padrões que sirvam de referência para a produção de dados.

Uma das principais características da ciência geográfica é a necessidade de representação e análise dos fenômenos distribuídos sobre a superfície terrestre, integrando e apresentando seus resultados através de representações cartográficas, como por exemplo, os atlas e mapas temáticos específicos de cada área. Para a elaboração desses produtos há a necessidade de um bom conhecimento sobre alguns conceitos cartográficos, como por exemplo, a escala cartográfica, projeção e sistemas geodésicos. Tais parâmetros são fundamentais para a preparação de documentos cartográficos

e, consequentemente, para o conhecimento geográfico, tendo em vista as diferentes formas de visualização das representações espaciais dos fenômenos.

O Decreto-Lei nº 243/67 aborda a representação do espaço territorial e estabelece que o território brasileiro seja representado através de cartas e outras formas afins. As cartas, quanto à representação dimensional, classificam-se em Planimétricas e Planialtimétricas; e, quanto ao caráter informativo, em Cartas Gerais ou de Referência, Especiais e Temáticas (CONCAR, 2010). As Cartas de Referência apresentam informações genéricas de uso não particularizado, como as folhas topográficas; já as Cartas Especiais registram informações específicas, destinadas a uma única classe de usuários, como as cartas náuticas e aeronáuticas; enquanto as Cartas Temáticas representam um ou mais fenômenos específicos, tal como a vegetação e o mapeamento de uso e cobertura do solo.

A produção da base cartográfica de referência constitui importante instrumento para estudos ambientais e socioeconômicos, tendo em vista que é usada como insumo para análises e consultas espaciais, através do seu caráter de representação das feições geográficas. Além disso, ela é usada como base para a elaboração de diversos mapeamentos temáticos voltados para identificação de recursos naturais, avaliações de riscos ambientais e estudos de urbanização. Diversos produtos cartográficos de referência podem ser citados, como por exemplo, as ortofotos aéreas, ortoimagens orbitais, cartas imagem, folhas topográficas e bases cartográficas, estruturadas, em diferentes escalas em um ambiente de sistema de informações geográficas (SIG).

Em diversas literaturas, é possível encontrar exemplos do uso cartográfico em várias aplicações. Guerra *In* Cunha & Guerra (2008) descreve o uso de folhas topográficas para a identificação de encostas côncavas, convexas e retilíneas, assim como suas respectivas combinações. Além disso, as curvas de nível presentes no mapeamento topográfico possibilitam a criação de mapas de declividades, fundamentais para avaliação de riscos de inundações e movimentos de massa.

Cruz & Menezes *In* Almeida & Soares (2009) tratam da contribuição da cartografia no ordenamento territorial do espaço geográfico brasileiro, cuja

abordagem é essencialmente geográfica, mas que busca, na cartografia, uma contribuição significativa. Esse auxílio é realizado através do uso de instrumentos para o planejamento nas formas de ocupação e valorização do espaço geográfico, a partir dos eixos de penetração do povoamento e da direção prioritária dos fluxos, assim como a partir da identificação de áreas de interesse estratégico e usos especiais como, por exemplo, as zonas de fronteiras, unidades de conservação e reservas indígenas. Dessa forma, a construção da representação espacial dos elementos e o tratamento das suas respectivas escalas de análise encontram, na cartografia, um subsídio fundamental.

Vale destacar também que, nos últimos anos, a cartografia apresentou mudanças na forma de preparação e divulgação de seus produtos. Aliado às novas tecnologias de aquisição, armazenamento e disseminação de mapas e cartas, os mapeamentos topográficos e temáticos se multiplicaram, atingindo os mais simples usuários até organizações governamentais e empresas privadas. Muitas análises sobre o espaço geográfico podem ser obtidas através da contribuição dos meios modernos que se dispõem para a construção de uma base cartográfica, como o sensoriamento remoto, os bancos de dados geográficos, os modelos digitais de elevação (MDE) e os sistemas globais de navegação por satélite (GNSS).

Por apresentar uma grande extensão territorial, o Brasil possui demandas complexas quanto à produção cartográfica, tendo que investir bastante em metodologias que resultem na melhoria da quantidade e qualidade de sua cartografia. Por mais de vinte anos, o país ficou estagnado na execução do mapeamento sistemático terrestre. O último período de grandes investimentos por parte do Governo Federal na atividade de mapeamento de referência ocorreu nas décadas de 1970 a 1980, por meio do Programa Especial de Dinamização da Cartografia Terrestre (PDC) (IBGE, 1978).

O papel centralizador do Governo Federal terminou com a Constituição de 1988, que reforço e delegou funções aos estados e municípios, descentralizando as ações de mapeamento. Além disso, a partir da década de 1980, a situação econômica nacional vigente levou o Governo a tomar uma série de medidas de contenção de despesas, ocasionando na interrupção do PDC. Desde então, poucos recursos foram destinados para a área cartográfica,

a fim de realizar novos mapeamentos ou realizar a atualização dos mapeamentos existentes.

A Coordenação de Cartografia do Instituto Brasileiro de Geografia e Estatística (IBGE) possui um importante papel na produção e disseminação da base cartográfica de referência. Em 2003, O IBGE disponibilizou a primeira base cartográfica digital atualizada na escala 1:1.000.000 que, até então era a única escala com abrangência para todo o território brasileiro. No ano de 2012 foi disponibilizado o mapeamento de todo o território brasileiro na escala 1:250.000. Atualmente, vem-se investindo nos mapeamentos, pelo menos parciais, nas escalas 1:100.000 e 1:25.000 de alguns estados, com expectativa de disseminação para os próximos anos. Tais critérios se baseiam em convênios entre o IBGE e as secretarias responsáveis pelo mapeamento de cada unidade da federação. Para isso, estão sendo usadas imagens de satélites como insumos para a produção.

O satélite ALOS, cujas imagens foram usadas para a elaboração da base cartográfica para o CENSO 2010, apresentou problemas no sistema de geração de energia, sendo desligado em abril de 2011. Dessa forma, considerando-se o problema com esse satélite e as limitações envolvidas com a vida útil dos equipamentos, torna-se relevante uma análise sobre a potencialidade de outros sensores, para que sirvam como alternativas de imageamento e suprir as necessidades da produção cartográfica. Em virtude das opções de sensores atualmente existentes, torna-se importante uma avaliação da relação entre os custos e os benefícios obtidos pelo uso de determinado tipo de sensor. Além de atender às especificações técnicas da produção cartográfica, há a necessidade, por exemplo, de considerar o aspecto financeiro para a obtenção das imagens. Além disso, há a possibilidade de integração de imagens provenientes de sensores diferentes, em virtude de características que reduzam a possibilidade de uso de apenas um sensor, como por exemplo, a cobertura de nuvens.

1.1 OBJETIVOS

Contribuir para os procedimentos de produção cartográfica, a partir da criação de um índice de interpretabilidade em imagens orbitais, de forma que seja possível estabelecer um grau de avaliação quantitativa de algumas feições

do Sistema Cartográfico Nacional que podem ser delimitadas e identificadas utilizando diferentes imagens. Sendo assim, a proposta é avaliar imagens geradas por sensores com resoluções espacais, espectrais e radiométricas distintas, em termos do potencial de interpretação de diferentes elementos cartográficos.

Especificamente, objetiva-se:

- Discutir conceitualmente os principais parâmetros envolvidos sobre a qualidade do dado geoespacial, relacionando-os com as questões que envolvem o processo de interpretação.
- Apresentar o conceito de interpretabilidade, suas premissas e os parâmetros estabelecidos no ambiente acadêmico para sua aplicação.
- Elaborar, através do estudo de caso proposto, indicadores de detecção e identificação de feições cartográficas do mapeamento de referência, considerando a diversidade de parâmetros espaciais e de classificação que refletem formas de medida do processo de interpretação.
- Construir um índice de interpretabilidade em imagens, no qual serão analisados os diferentes potenciais de interpretação para cada feição, para cada categoria e por sensor.

A principal motivação deste estudo é trabalho desenvolvido pela equipe da Gerência de Imageamento da Coordenação de Cartografia do IBGE no ano de 2009, cujo resultado final foi o relatório do projeto BR250, projeto de mapeamento na escala 1:250.000 a partir de duas áreas de estudo. O desenvolvimento deste trabalho possibilitou identificar as principais limitações e potencialidades em termos de extração de feições cartográficas.

Sendo assim, a questão central desse trabalho é apresentar e discutir o conceito de interpretabilidade de imagens orbitais usadas para a produção de base cartográfica de referência. Nesse contexto, entende-se por interpretabilidade a adequação de uma imagem para finalidade de interpretação, de forma que seu conteúdo permita a detecção e identificação de objetos sobre a superfície terrestre, seja utilizando métodos aumoáticos ou não. Isso vale ser destacado porque, apesar da evolução da automatização de processos para a extração de feições a partir de imagens, a análise visual de

um intérprete ainda é necessária para se interpretar os elementos cartográficos e adequá-los às especificações técnicas.

Em termos geométricos e de interpretação, busca-se detalhar mais conhecimento sobre as questões que são determinantes para se definir que sensores são adequados para se atingir a exatidão esperada para uma escala cartográfica. De forma geral, quando as imagens atendem a exigências de exatidão posicional para uma determinada escala, dificilmente oferecem condições satisfatórias para a extração de feições na mesma escala, em virtude do detalhamento dos dados a serem extraídos. Isto leva à reflexão de que as exatidões posicional e temática de imagens não indicam, necessariamente, uma mesma escala de aplicação. Este trabalho, assim, esmiúça o conhecimento sobre questões centrais na definição de sensores mais apropriados para se alcançar as exatidões desejadas para uma dada escala cartográfica.

Dessa forma, a ideia central para a criação de um índice de interpretabilidade é permitir um entendimento sobre o grau de interpretação que uma imagem pode oferecer, propondo-se o estabelecimento de uma forma de medida quantitativa, variando de zero até um.

Vale destacar que, para atingir essas medidas, será discutida a relação do valor da interpretabilidade obtido para cada sensor com a escala. Uma determinada feição cartográfica, por exemplo, pode apresentar um excelente índice de interpretabilidade para um sensor, porém é necessário informar a escala na qual existe a adequação. Sendo assim, os parâmetros propostos nesse estudo para a obtenção do índice de interpretabilidade serão sempre relativizados de acordo com a escala.

Para o processo de geração do índice de interpretabilidade, esse estudo se adequou às especificidades dos alvos representativos no mapeamento topográfico, usando como referências as feições e especificações de aquisição contempladas no modelo de Especificação Técnica para Estruturação de Dados Geoespaciais Vetoriais (ET-EDGV) e na Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais (ET-ADGV).

O principal material de insumo para o estudo da geração do índice de interpretabilidade correspondeu à seleção de imagens de três sensores: OLI/LANDSAT-8 (imagem fusionada), AVNIR-2/ALOS e o *RapidEye*, de forma

que para cada sensor é proposto o cálculo do Índice de Interpretabilidade. Serão utilizadas imagens das respectivas bandas espectrais e diferentes combinações de composição colorida a fim de estabelecer os melhores cenários para interpretação. Os principais materiais para validação dos dados são os dados obtidos através de levantamento de campo na área de estudo para obtenção de pontos de controle/ verificação de coordenadas e refinamento do processo de extração e classificação. Além disso, serão usadas as ortofotos digitais e a base cartográfica na escala 1:25.000 do projeto RJ25, produtos gerados pelo IBGE.

Dessa forma, pretende-se detalhar os aspectos metodológicos que visem à preparação das imagens para os processos de extração e classificação, destacando-se a:

 Avaliação geométrica das imagens através da estimativa da exatidão posicional usada oficialmente e também através de novas propostas de avaliação posicional usando inferências estatísticas.

 Avaliação radiométrica das imagens através de testes na parametrização de valores de correção atmosférica.

Após a etapa de avaliação posicional e radiométrica, foram elaborados procedimentos relativos à segmentação, à extração de elementos lineares e às respectivas classificações de feições das categorias: Hidrografia, Sistema de Transporte e Vegetação. Vale ser ressaltado que os dados de hidrografia foram extraídos utilizando-se apenas as imagens dos três sensores mencionados, não sendo utilizados modelos digitais (elevação ou superfície), para atender ao propósito da interpretabilidade. A justificatica para a ausência dos modelos digitais é para condicionar os processos de extração e classificação às especificidades das imagens óticas, cuja finalidade é gerar o seu respectivo Índice de Interpretabilidade. Porém tais dados foram selecionados como referência de descritores no processo de classificação. Além disso, destaca-se que as feições de relevo não fizeram parte do escopo desse estudo.

Conforme será mencionado mais adiante, esse estudo foca dois aspectos importantes para uma boa interpretabilidade de uma imagem: a detecção e a identificação de objetos. O primeiro se refere à capacidade de delimitação bem clara da feição desejada, enquanto a segunda abordagem está associada ao potencial de qualificar esse objeto a partir somente do uso

da imagem. Por isso, este texto propõe a geração de índices que se propõem a mensurar a capacidade de detecção e identificação das feições para se chegar ao índice de interpretabilidade.

No segundo capítulo da tese, pretende-se realizar uma breve revisão teórica geral sobre os principais conceitos discutidos em termos de produção e controle de qualidade de dados cartográficos; além de apresentar um panorama da cartografia de referência em alguns países; e uma visão detalhada dos sensores remotos cujas imagens são utilizadas neste estudo.

O terceiro capítulo aborda a revisão teórica específica, sendo apresentadas algumas definições, exemplos e princípios norteadores de interpretabilidade; além de uma apresentação de estudo de caso para avaliação da interpretabilidade.

Já no quarto capítulo estão descritas as etapas de preparação das imagens para a extração e classificação das feições, correspondendo às correções geométricas e radiométricas.

A construção do primeiro indicador para avaliar a interpretabilidade está descrito no quinto capítulo, onde é detalhado o procedimento metodológico para a geração do Indicador de Detecção e aplicação através do estudo de caso na Bacia hidrográfica do rio São João.

O segundo indicador de avaliação da interpretabilidade se refere ao potencial de identificação, descrito no capítulo seis. Assim como no capítulo cinco, são estabelecidos os procedimentos de construção deste indicador e os resultados do estudo de caso.

Os resultados finais deste estudo são apresentados no capítulo sete, com a construção e geração do índice de interpretabilidade, cujas análises são feitas por feição, categoria e sensor.

2. REVISÃO TEÓRICA

2.1 EXTRAÇÃO E CLASSIFICAÇÃO DE FEIÇÕES: BASES PARA A INTERPRETAÇÃO DE IMAGENS

Um dos principais motivos para o uso cada vez maior do sensoriamento remoto é a necessidade de interpretar elementos distribuídos sobre a superfície terrestre, ou seja, cada vez mais as pessoas tendem a utilizar as imagens para conhecer o espaço geográfico. Para Florenzano (2007) a interpretação de fotografias ou imagens corresponde à tarefa de identificar objetos nelas representados, além de dar um significado a esses objetos. Dessa forma, pode-se vincular o processo de interpretação aos processos de extração e classificação, cujos conceitos são descritos na literatura específica, mas não são detalhadas as diferenças entre eles.

Schowengerdt (1997) ressalta o uso do sensoriamento remoto como instrumento para a extração de informações, cujas análises podem ser entendidas através de duas formas: *Image-centered* e *data-centered*.

Na primeira forma, o interesse principal do uso de imagens é a relação espacial existente entre os elementos presentes na superfície terrestre, ou seja, o enfoque é a criação de um mapa com a delimitação de feições a partir de imagens orbitais ou aéreas. Um exemplo seria o processo de fotointerpretação, através da identificação e criação de feições hidrográficas, geológicas e de cobertura vegetal com o uso de fotos aéreas, por exemplo. Dessa forma, a análise através das imagens possui duas características principais: a definição de geometrias que contenham coordenadas geográficas e a identificação de atributos associados às geometrias criadas. Essa análise pode ser automatizada, através de softwares de classificação para a geração de mapas temáticos e de processos fotogramétricos como, por exemplo, a extração altimétrica. Porém, segundo a visão do autor, em muitos casos, a análise visual ainda não pode ser suplantada totalmente pelas técnicas automáticas.

A segunda forma de entender a extração de informações em sensoriamento remoto é denominada de *data-centered*. Nesse caso, o interesse principal está na dimensão interna dos dados (características radiométricas e espectrais), ao invés das relações espaciais envolvidas.

Enquanto no primeiro caso, a resolução espacial é vista como fundamental para a extração das informações, na segunda abordagem a acurácia radiométrica e espectral é fundamental para a interpretação e geração de análises. Um exemplo seria o uso de técnicas estatísticas e comportamento espectral dos alvos para estimar dados de superfície.

Na verdade, as duas formas de entender o dado de sensoriamento remoto não são antagônicas, e sim, convergentes. Schowengerdt (1997) ressalta que a própria ciência, particularmente os ramos específicos que tratam de estudos de monitoramento de mudanças globais, precisa tanto do relacionamento espacial entre as feições quanto da acurácia radiométrica e espectral para entender o comportamento de um determinado alvo para melhor identificá-lo.

Para Jensen (2009), a ciência obteve muitos benefícios a partir dessa necessidade de interpretação de imagens orbitais e aéreas, como o aprimoramento da perspectiva vista de cima que permita visualizar áreas mais abrangentes comparadas com a observação lateral dos objetos. Além disso, os dados de sensoriamento remoto ampliaram a percepção de profundidade tridimensional a partir de imagens estereoscópicas, identificando, além do tamanho e forma, a altura e declividade do terreno.

O mais primitivo processo de análise e avaliação de imagens corresponde à interpretação visual, ainda mencionada na bibliografia de sensoriamento remoto como um poderoso recurso, apesar dos inúmeros avanços tecnológicos para a automatização deste processo observados nas últimas décadas. Não há como desprezar o raciocínio e a lógica humana quando se trata da percepção de elementos presentes em uma imagem. Desde a infância, os seres humanos aperfeiçoam os mecanismos de leitura de imagens no seu cotidiano, percebendo não apenas os contornos físicos dos objetos, mas também trazendo uma carga de significados que esses carregam.

Mesmo com a utilização de procedimentos automáticos, muitos processos de validação e reconhecimento dos dados produzidos acabam passando pela subjetividade, mesmo que forma indireta, da inspeção visual. Ou seja, mesmo com o reconhecimento de métodos estatísticos para a obtenção de resultados acurados, de certa forma há a necessidade de um olhar e interpretação visual para uma validação do contexto.
Os aspectos positivos da interpretação visual geralmente estão associados à capacidade do intérprete no conhecimento da área de estudo. Ainda mais quando se trata de analistas experientes que possuem um conhecimento prévio das características do lugar através de suas experiências empíricas. Não é um conhecimento do rigor científico, mas é a percepção subjetiva ao longo dos anos de trabalho que permitiram acumular essa sabedoria. Mesmo que o interprete não conheça detalhadamente o local, uma visitação *in loco já* contribui para uma análise da imagem com menos dúvidas.

No entanto, não há como deixar de ressaltar o problema do tempo gasto no uso exclusivo da interpretação visual. Em ambientes de produção de dados em larga escala, a demora no processo de extração e classificação pode inviabilizar projetos. Dessa forma, o cenário ideal seria um método que concilie a rapidez dos processos automáticos com essa percepção da visão humana para interpretar as feições, além de ser usado também como recurso de validação de dados.

É comum no contexto da cartografia de referência o uso da expressão "*extração de feições*" para a aquisição dos dados, termo abrangente e que talvez, possa ser confundido com o conceito de classificação, associado, na maioria das vezes, apenas ao mapeamento temático. Talvez o limite conceitual entre extração de feições e as propriedades de classificação seja um pouco confuso.

Segundo Duda *et al.* (2001) a fase de extração de feições auxilia na medição de propriedades de objetos que serão úteis para a fase de classificação. Para os autores, a fase de extração de feições tem como objetivo principal caracterizar um objeto a ser reconhecido por medições, cujos valores são muito semelhantes em relação a objetos da mesma categoria e muito diferentes de outras categorias. Já o processo de classificação atenderia à diferenciação interna dos objetos inseridos na mesma categoria de informação. Um exemplo seria a identificação de massas d'águas em uma imagem, cujo processo de extração envolveria a diferenciação espectral e radiométrica entre essa classe das demais. Para individualizar cada tipo de massa d'água (rios, lagoas, oceano) é necessário que o processo de classificação utilize vários tipos de descritores para definir as suas classes, com a forma e contexto. No campo prático, uma extração de feições ideal renderia uma representação que

produza um trabalho de classificação trivial. De qualquer forma, os próprios conceitos de classes e feições não são abordados de forma detalhada na literatura específica.

Uma primeira percepção sobre qualquer tipo de imagem permite enxergar limites entre áreas, como por exemplo, diferentes coberturas do terreno (solo, vegetação, rocha etc.). Do ponto de vista radiométrico, esses limites representam mudanças no intervalo de nível de cinza. Além disso, as imagens correspondentes à cada banda espectral também terão valores diferenciados.

Considerando a interpretação visual, o intérprete tentará extrair esses limites manualmente, enquanto na interpretação automática, existem algoritmos computacionais que tentam criar essa delimitação a partir da definição de parâmetros que estabelecem o grau de descontinuidade (detecção de contornos) ou similaridade (crescimento de regiões) entre os pixels.

2.1.1 Segmentadores

Antes de realizar a classificação de imagens, é comum os usuários realizarem o processo automático de segmentação, sendo uma das ferramentas de extração mais utilizada, tendo em vista que seu propósito é delimitar áreas através de análise entre pixels vizinhos, de forma que se criem áreas homogêneas de acordo com diversos atributos, como por exemplo a característica radiométrica e textura. (Borsotti *et al.*, 1998) (Xu *et al*,1998).

Sendo assim, o processo de extração está mais associado às técnicas de caráter geométrico, como por exemplo as ferramentas de detecção de bordas e segmentação de polígonos, cujas operações baseiam-se nas questões topológicas entre os pixels. Ao final do processo, pode-se avaliar a qualidade da segmentação através da aderência geométrica entre a imagem original e o dado produzido, de maneira que os pixels inseridos em uma determinada região segmentada apresentem homogeneidade ideal para a classificação.

Outro exemplo de feição que pode ser extraída automaticamente é a rede de drenagem, através do uso de modelos digitais de elevação adequados à escala de trabalho, podendo ser usado desde dados fotogramétricos até

imagens do SRTM. Porém, conforme mencionado na Introdução, esse estudo não contempla esse cenário.

Em algumas situações, a extração automática só é utilizada em casos restritos, como na elaboração de base cartográfica de referência. O uso de ferramentas para aquisição automática de feições, só é adotado para obtenção de curvas de nível, utilizando um modelo digital de elevação e, mesmo assim, é necessária uma fase de edição manual para corrigir erros e realizar o ajuste topológico. Para a extração dos demais elementos da cartografia de base, como drenagem e rodovias, o processo ainda é feito através da análise visual dos elementos.

Dentre os processos de extração de traçados mais comuns visando uma interpretação automatizada, destacam-se o uso de segmentadores baseados por descontinuidades e similaridades nos níveis de cinza. Em ambos, são necessários um conjunto de testes com definições de limiares diferentes de forma a tentar se alcançar um resultado de boa qualidade. De qualquer forma, para se avaliar a qualidade de segmentação, é comum uma análises subjetiva do resultado gerado. Antunes (2003) destaca que não existe um modelo formal para avaliar a segmentação, de maneira que se torna um processo essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagens, com limiares definidos conforme a complexidade dos alvos investigados.

2.1.1.1 Segmentadores baseados em descontinuidades

Crosta (2002) afirma que todas as imagens possuem limites entre áreas com diferentes respostas em relação à energia eletromagnética. Esses limites podem ser, por exemplo, entre diferentes coberturas do terreno (solo, vegetação, rocha), ou podem representar o contato entre áreas com diferente condições de iluminação, devido à sombreamento topográfico. Em uma imagem monocromática, esses limites representam portanto mudanças de um intervalo de nível de cinza para outro. Limites deste tipo são conhecidos como bordas e ocupam geralmente áreas pequenas na imagem, sendo mais estreitos do que largos. Exemplos desse tipo de feição são limites entre diferentes tipos de plantações, entre áreas sombreadas e iluminadas, redes de transporte (malha urbana, rodovias, ferrovias), redes de drenagem, estruturas geológicas (falhas, fraturas) e outras.

Segundo Gonzalez & Woods (1987) as descontinuidades presentes em uma imagem podem ser visualizadas pontualmente, em formas de linhas ou bordas de um objeto. A detecção de bordas e linhas são as abordagem mais comuns para detecção de descontinuidades. Em uma imagem a borda é definida como sendo o limite entre duas regiões com diferentes propriedades (GONZALES & WOODS, 1987). Essas feições sobressaem principalmente por apresentarem tons de cinza distintos à região nas quais estão inseridas ou por assinalarem mudanças bruscas de tons de cinza entre regiões.

Segundo Crosta (2002), as técnicas de filtragens espaciais podem ser úteis em processamento de imagens para realçar bordas e feições lineares de determinadas direções e padrões de textura. Os algoritmos desenvolvidos para detectar essas descontinuidades usualmente usam análise através de análise de Fourier, quando se trabalha no domínio das frequências, ou por convolução, quando são utilizadas operações de características espaciais, através de uso de máscaras ou também chamadas janelas. A convolução é o processo de calcular a intensidade de um determinado pixel em função da intensidade de seus vizinhos,

As máscaras são pequenas matrizes quadradas, normalmente de tamanho 3x3, 5x5, 7x7, aplicadas em cada pixel da imagem, centrado na máscara. Quando se aplica uma máscara em uma imagem, realiza-se uma operação matemática sobre um determinado pixel da imagem, que é o elemento central dessa matriz ou máscara. A operação se baseia na definição de limiares que utilizam dados de nível de cinza dos pixels vizinhos. Ou seja, o novo valor de cada pixel da imagem será a aplicação da máscara centrada neste pixel.

Segundo Crosta (2002) os filtros espaciais podem classificados em três tipos: passa-baixa, passa-alta e direcionais. Segundo o autor ainda existira um quarto tipo, denominando passa-banda, pouco usado entre os usuários de sensoriamento remoto por ser de difícil implementação.

O efeito visual de um filtro passa-baixa é o de suavização ("smoothing") da imagem e a redução do número de níveis de cinza da cena. As baixas frequências são preservadas e as altas frequências, que correspondem às

transições abruptas, são atenuadas. A suavização tende a minimizar ruídos e apresenta o efeito de borramento da imagem. A figura 2.1 compara duas imagens OLI\LANDSAT-8. A imagem da esquerda ilustra antes do processamento e a da direita após a aplicação do filtro de passa-baixa. Nesse tipo de filtro a soma dos pesos usados na máscara é sempre igual a 1 e o efeito de suavização (desfocagem) aumenta proporcionalmente à dimensão da máscara usada.

Esse tipo de filtro geralmente é usado para atenuar o efeito de ruídos existentes em um cena, como por exemplo os ruídos devido à diferenças de sensibilidade dos detectores do sensor e erros de transmissão de sinal (NOVO, 2010).



Figura 2.1: Exemplo de aplicação de filtro passa-baixa.

Já a filtragem passa-alta, também chamado de realce de bordas, atua de forma inversa quando comparada com o filtro passa-baixa, ou seja, há a remoção dos componentes de baixa frequência e mantem as altas frequências. Dessa forma, tende-se a realçar os detalhes, produzindo uma "agudização" (*"sharpering"*) da imagem, isto é, as transições entre regiões diferentes tornam-se mais nítidas, como por exemplo os limites de um campo de cultivo e um lineamento geológico. Nesse tipo de filtro, a máscara possui um valor alto no centro do pixel, cercado por valores negativos.

Segundo Crosta (2002), assim como nos filtros de suavização, a dimensão da máscara de convolução influencia no resultado final. Neste caso,

porém, quanto menor a máscara, menores serão os detalhes a serem realçados na imagem. Portanto, no caso de se desejar realçar feições lineares extensas, como por exemplo falhas geológicas, máscaras de grandes dimensões são as mais indicadas. Como regra geral, um filtro passa-alta normalmente vai realçar feições de dimensões menores do que a dimensão da máscara usada. O autor cita como exemplo a necessidade de realçar lineamentos geológicos com cerca de 3 quilômetros de extensão em uma imagem TM\LANDSAT-5 (pixel com 30 metros), no qual o ideal é usar uma máscara de dimensões 31x31 pixels.

O efeito indesejado desse tipo de filtragem é o de enfatizar um ruído, porventura existente na imagem. De qualquer forma, os casos das extrações automáticas podem funcionar de forma satisfatória em casos para obtenção de trechos de sistemas viários, como estradas ou rodovias, em virtude da diferença de contraste entre esses elementos e o seu entorno.

A figura 2.2 compara duas imagens OLI\LANDSAT-8. A imagem da esquerda ilustra antes do processamento e a da direita após a aplicação do filtro de passa-alta.



Figura 2.2: Exemplo de aplicação de filtro passa-alta.

O último tipo de filtro espacial, segundo Crosta (2002) é o denominado filtro direcional. Para o autor, estes filtros são um tipo especial de filtro passaalta, possuindo a característica de realçar bordas em direções prédeterminadas. Eles são uma combinação de filtragem passa-alta e limiarização de níveis de cinza. Os filtros direcionais podem ter apenas uma dimensão (horizontal ou vertical). O problema com este tipo de filtro é que muitas vezes eles produzem bordas artificiais, também chamadas de artefatos, que podem confundir o intérprete, fazendo-o pensar que se trata de uma feição verdadeira. Existem vários tipos desse tipo de filtragem, sendo os mais comuns os filtros de Sobel, Roberts e de Prewitt.

A figura 2.3 compara duas imagens OLI\LANDSAT-8. A imagem da esquerda ilustra antes do processamento e a da direita após a aplicação do filtro de Sobel, usando uma máscara 3 x 3.





O problema desses métodos de detecção de descontinuidades, mais particularmente os de detecção de linhas e de bordas, é a forte possibilidade de serem apresentados nos resultados alguns ruídos de detecção. Portanto, esses métodos devem ser seguidos de processamentos, como realce de contrastes e/ou outros filtros radiométricos que visem sanar essas falhas, conforme destaca Gonzalez & Woods (1987).

Além dos filtros espaciais, existem também os filtros morfológicos, que exploram as propriedades geométricas dos sinais (níveis de cinza da imagem). Para filtros morfológicos, as máscaras são denominadas elementos estruturantes. Estes elementos devem apresentar valores "0" ou "1", de modo a considerar ou não o pixel correspondente à posição da matriz.

Dentre os principais tipos de filtros morfológicos estão os operadores de erosão e dilatação. O primeiro provoca efeitos de remoção das partes claras da imagem, ou seja, com altos níveis de cinza, gerando imagens mais escuras.

Segundo Solie (1999) os efeitos desejados para a erosão são: escurecer a imagem, alargar padrões escuros, conectar padrões escuros próximos, reduzir ou eliminar padrões claros e separar padrões claros próximos.

Já a dilatação provoca efeitos de ampliação das partes escuras da imagem, com baixos níveis de cinza, gerando imagens mais claras. Segundo Soile (1999) os efeitos desejados para a dilatação são: clarear a imagem, alargar os padrões claros, conectar padrões claros próximos, reduzir padrões escuros e separar padrões escuros próximos.

Os filtros espaciais e morfológicos correspondem a métodos de análise de imagens baseados no conhecimento denominado de Morfologia Matemática. Para Gomes & Velho (2002), a Morfologia Matemática compreende a área que estuda propriedades topológicas e estruturais dos objetos a partir de uma imagem tendo como objetivo descrever quantitativamente as estruturas geométricas e funciona como uma técnica na concepção de algoritmos de processamento digital de imagens, contendo ferramentas básicas como detectores de bordas e filtros morfológicos. Dessa forma, o princípio da Morfologia Matemática consiste em extrair informações geométricas e topológicas de um conjunto de pixels usando como referência estruturas que servem como moldes para esse processo, definidas como máscaras, no caso dos filtros espaciais, ou elemento estruturante, no caso dos filtros morfológicos

2.1.1.2 Segmentadores baseados em similaridades

A detecção de similaridade tem como principal característica a observação do interior dos objetos e não apenas das fronteiras que os delimitam. Para tanto, parte-se da idealização que os pixels que compõe um objeto possuem propriedades semelhantes, enquanto que os pixels de objetos distintos têm propriedades distintas.

O uso de segmentadores baseados por similaridades geralmente é usado como um processo anterior o de classificação, esse sendo o procedimento convencional mais utilizado para análise digital de imagens. Para Soh e Tsatsoulis (1999), a obtenção de resultados satisfatórios na etapa de classificação é diretamente dependente da existência de algoritmos eficientes na etapa de segmentação.

Segundo Meinel & Neubert (2004), segmentar uma imagem significa agrupar pixels vizinhos em regiões com base em critérios de similaridade. Essa definição retrata um pouco o contexto do termo segmentação em sensoriamento remoto, que representa a etapa preparatória para a geração de polígonos que representem, por exemplo, uso e cobertura da terra, vegetação.

No critério de similaridade, divide-se a imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por regiões, um conjunto de pixels contíguos, que se espalham bidirecionalmente e que apresentam uniformidade.

A divisão em porções consiste basicamente em um processo de crescimento de regiões, de detecção de bordas ou de detecção de bacias. Seguem as descrições.

Por meio do processo de segmentação por similaridade, é possível obter-se, de maneira rápida, a discriminação e a delimitação de fragmentos. Adicionalmente, os polígonos gerados pela segmentação, convertidos para vetor, podem ser usados como amostras de treinamento em futuras classificações digitais e, ainda, em classificações visuais, por meio de simples atribuição de classes aos polígonos.

De acordo com Gonzáles & Woods (2000), a seleção de critérios de similaridade é dependente do problema em consideração e também do tipo de dados (imagens) disponíveis. Considerando-se os segmentadores baseados por similaridades, pode-se destacar duas abordagens: o método de crescimento de regiões e por detecção de bacias.

Tilton & Lawrence (2000) sustentam que o método de crescimento de regiões é preferível, visto que considera a característica espacial dos dados e garante a formação de segmentos fechados. Outrossim, salienta-se que alguns dos softwares de segmentação de imagem de aplicação em sensoriamento remoto implementam o método de crescimento de regiões em suas rotinas, podendo-se citar o SPRING (CÂMARA *et al.*, 1996) e o e-Cognition® (BAATZ & SCHAPE, 2000).

O princípio do funcionamento da técnica de crescimento por regiões é agrupar pixels ou sub-regiões em regiões maiores (GONZALES & WOODS, 1987). Seu início se dá com a adoção de um conjunto de pixels "sementes", a partir das quais é realizado o crescimento das regiões por meio da inclusão, de

pixels vizinhos que tenham atributos similares, tais como, intensidade, textura, cor, etc. O crescimento ocorre iterativamente até que cada pixel seja processado e sejam formadas diferentes regiões cujas fronteiras possam ser definidas por polígonos fechados e os pixels internos a essas compartilhem de certa similaridade. Por trás de seu funcionamento simples o crescimento de regiões esconde algumas dificuldades relacionadas à sua fundamentação. Uma dessas, diz respeito justamente ao início do processo, que é a escolha de sementes. Outra dificuldade está ligada à natureza da aplicação e ao tipo de imagem disponível, e diz respeito à definição do critério de similaridade a ser usado.

É uma técnica de agrupamento de dados, na qual somente as regiões adjacentes, espacialmente, podem ser agrupadas. Inicialmente, este processo de segmentação rotula cada "pixel" como uma região distinta. Calcula-se um critério de similaridade para cada par de regiões adjacente espacialmente. O critério de similaridade baseia-se em um teste de hipótese estatístico que testa a média entre as regiões. A seguir, a imagem é dividida em diferentes partes e, segundo um limiar de agregação definido, então é realizado a união entre essas partes.

Baatz & Schäpe (2000) propõe uma extensão do algoritmo de crescimento de regiões denominado de segmentação multirresolução, desenvolvido no software e-Cogntion.

Nessa abordagem de segmentação, cada pixel da imagem constitui uma semente e representa um segmento. Ao executar o algoritmo, cada segmento é analisado e calculado um índice que representa o aumento de heterogeneidade que resultaria na agregação com cada um de seus vizinhos. Após analisar vários segmentos vizinhos, é determinado o vizinho cuja agregação resulte no menor acréscimo de heterogeneidade em relação a cada segmento considerado separadamente.

O algoritmo estabelece uma entre duas heurísticas de decisão. No modo conhecido como *Best Fitting*, realiza-se a fusão do segmento visitado com seu vizinho mais similar. Já o segundo modo, denominado de *Mutual Fitting*, a fusão somente se consuma, se a relação de maior similaridade for mútua entre o segmento e seu vizinho. Em ambos os modos, a agregação está condicionada à um fator de escala que determina o máximo aumento de

heterogeneidade permitido, resultante da fusão entre dois segmentos, e que influencia indiretamente no tamanho médio dos segmentos finais. A segmentação é finalizada quando mais nenhuma agregação puder ser realizada.

Outro tipo de segmentador baseado em similaridades é segmentação por detecção de bacias, que é feita sobre uma imagem resultante da extração de bordas. A extração de bordas é realizada por um algoritmo baseado por descontinuidade, geralmente o filtro de Sobel.

Após a aplicação desse filtro espacial, gera-se uma imagem com valores de gradiente entre os pixels. O procedimento de segmentação por detecção de bacias pressupõe uma representação topográfica dessa imagem, ou seja, para uma dada imagem gradiente, o valor de nível digital de cada "pixel" equivale a um valor de elevação naquele ponto. A imagem equivaleria a uma superfície topográfica com feições de relevo ou uma região com bacias de diferentes profundidades.

O termo "detecção de bacia" se refere à uma analogia com uma bacia de drenagem, no qual se compara a imagem com uma superfície topográfica. Define-se uma altura inicial (nível digital) para o preenchimento das bacias (limiar). A "água" preencherá progressivamente as diferentes bacias da imagem até um limiar definido pela topografia (valor de nível digital). Ao alcançar o limite, define-se uma barreira entre duas regiões. O processo de preenchimento continua em outra direção até atingir um novo limite topográfico, definindo-se mais uma barreira, e assim sucessivamente até que todas as barreiras tenham sido definidas. O resultado é uma imagem rotulada no qual cada região apresenta um valor de nível digital, posteriormente classificadas por algoritmos próprios.

2.1.2 Classificação

2.1.2.1 Classificação supervisionada e não supervisionada

Assim como a extração, a classificação pode ser considerada uma técnica de processamento digital de imagens, além do fato de estarem dependentes dos comportamentos espacial, espectral e radiométrico específicos dos materiais da superfície terrestre. Ou seja, o seu o conceito também está baseado nos atributos quantitativos de cada pixel, porém a

diferença está em atribui-lo um rótulo de identificação associado a uma classe particular (RICHARDS & JIA, 2006). A classificação consiste em associar cada pixel da imagem a uma determinada "classe" de informações temáticas que descreve um objeto real como vegetação, áreas urbanas, dentre outros objetos (CROSTA, 2002). Ao final do processo, verifica-se a exatidão temática entre as classes e amostras coletadas.

Os métodos de classificação se dividem basicamente em duas categorias em termos de treinamento: a classificação supervisionada e a nãosupervisionada (CROSTA, 2002). Ambos possuem regras de decisão para que o classificador associe um determinado *pixel* a uma determinada classe ou regiões de similaridade de níveis de cinza. Tais regiões são baseadas nas características espectrais do *pixel*, ou do *pixel* e seus vizinhos. Quando a regra toma como base as características somente do *pixel*, a classificação é dita *pixel* a *pixel*. Caso contrário, a classificação é dita por região.

A classificação não-supervisionada é indicada quando o analista não possui um conhecimento, a priori, da área de estudo. O objetivo é eliminar a subjetividade no processo de obtenção das amostras de áreas para criar as áreas de treinamento, caso se deseja realizar a classificação supervisionada posteriormente. Existem vários tipos de classificadores não-supervisionados, sendo o ISOSEG, do software SPRING, um dos mais utilizados atualmente. Este classificador não requer nenhum parâmetro inicial para começar o agrupamento de *pixels* em regiões. A princípio, ele assume que todos os *pixels* da cena pertencem a uma classe. Posteriormente, começa a dividir a imagem em diferentes classes, segundo as diferenças espectrais observadas nos pixels. Segundo Novo (2010), a classificação não-supervisionada pode ser executada antes da classificação supervisionada, visto que permite ao analista conhecer o número de classes existentes. Geralmente, esse número é maior que o número de classes no terreno, havendo a necessidade de agrupar determinadas classes. Porém, pode acontecer do número de classes gerado pelo algoritmo ser menor que o número de classes do terreno, em função das características espectrais dos alvos serem muito semelhantes. Nesse caso, para que sejam discriminados, há a necessidade de realizar outros procedimentos de classificação. No capítulo referente à interpretabilidade, será

tratado de alguns desses procedimentos, utilizando-se das chaves de interpretação.

O processo de classificação supervisionada parte do conhecimento do usuário sobre a área a ser classificada. Normalmente as idas à campo se fazem necessárias para comparação de *pixels* da imagem com a área estudada da imagem. Esse tipo de observação é chamado de verdade terrestre (*"ground truth"*) e o outro importante processo de análise é a seleção de áreas de treinamentos (*"training areas"*) da imagem que representam as amostras que ajudam a entender o comportamento médio das classes que deverão ser mapeadas (NOVO, 2010).

Nessa forma de classificação, são utilizados algoritmos cujo reconhecimento dos padrões espectrais na imagem se faz com base em uma amostra de área de treinamento, que é fornecida ao sistema de classificação pelo analista. Dentre os algoritmos supervisionados mais empregados estão: máxima verossimilhança (MAXVER), o método de paralelepípedo e a distância euclidiana.

Segundo Richards & Xia (2006) a classificação supervisionada pode ser determinista, ou seja, os limites das classes são definidos com base em um critério de corte estabelecido em função do desvio padrão em relação à média de cada classe. O método de classificação também pode ser probabilístico , ou seja, as amostras de cada classe são descritas em função da probabilidade no espaço multi ou hiperespectral. Tal função descreve a probabilidade de um dado pixel pertencer a uma classe em função de sua localização nesse espaço n-dimensional. A figura 2.4 ilustra a distribuição de probabilidade de duas classes a serem mapeadas. As setas A e B indicam as regiões nas quais o pixel tem maior probabilidade de pertencer , enquanto a seta X indica uma área de incerteza em que os valores dos pixels podem ser atribuídos em qualquer uma das classes.

A análise dessa distribuição ajuda a avaliar os erros decorrentes do processo de classificação. Os pixels localizados nas áreas de maior probabilidade tendem a ser classificados com maior índice de acerto comparados com os pixels localizados na área de incerteza.



Figura 2.4: Probabilidade de um pixel pertencer a uma determinada classe, considerando uma distribuição normal.

Para resolver situações que envolvem a incerteza da classificação, o conceito de conjuntos difusos, nebulosos ou *fuzzy*, proposto por Zadeh *apud*. Antunes (2003) tem sido bastante aplicado em estudos de sensoriamento remoto. A lógica *fuzzy* é uma generalização do conceito da teoria clássica dos conjuntos e se refere a conceitos inexatos para uma metodologia de caracterização de classes, que por diversas razões não se tem ou não se pode estabelecer limites rígidos (bordas) entre classes. A utilização de um conjunto *fuzzy* é em geral aplicada sempre que se tiver que lidar com ambiguidade, abstração e ambivalência em modelos matemáticos. O conjunto *fuzzy* expressa o grau para o qual um elemento pertence a um conjunto utilizando uma função de pertinência. Então, esta função característica de um conjunto *fuzzy* apresenta valores variáveis entre 0 e 1, os quais denotam o grau de pertinência de um elemento em um dado conjunto (AZEVEDO et. al 2000). Ou seja, Um pixel pode pertencer a uma determinada classe com um grau de pertinência, e a uma outra classe com outro grau de pertinência.

2.1.2.2 Algoritmos orientados a pixel, regiões e objetos

Os chamados classificadores "pixel a pixel" representam as técnicas de classificação mais antigas e utilizam, apenas, a informação espectral, isoladamente, de cada pixel para achar a classe mais provável para o pixel.

Já os algoritmos que classificam por regiões utilizam, além de informação espectral de cada "pixel", a informação espacial que envolve a relação com seus vizinhos. Procuram simular o comportamento de um fotointérprete, reconhecendo áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens. A informação de borda é utilizada inicialmente para separar regiões e as propriedades espaciais e espectrais irão unir áreas com mesma textura

Atualmente, o método de classificação baseada em objetos, denominado *Geographic Object-Based Image Analysis*, conhecido como GEOBIA, tem sido bastante utilizado. Tal abordagem difere dos métodos orientados ao pixel ou por regiões, por dividir a imagem em entidades discretas, ou segmentos, conhecidos como objetos, onde a informação semântica contida dentro dele e as relações estabelecidas entre eles, conduzirá a interpretação de uma imagem (SOUZA, 2012).

O processo de classificação orientada a objeto utiliza os polígonos gerados na segmentação para definição dos objetos de imagem a partir de um conjunto de dados, no caso, as bandas. As características espectrais de forma e relações de vizinhança são as informações utilizadas na descrição destes objetos. A partir destes descritores os objetos podem ser agrupados em categorias com significado ou em classes temáticas (DEFINIENS, 2010).

Cruz *et. al.* (2009) apontam que a classificação orientada a objeto busca simular técnicas de interpretação visual através da modelagem do conhecimento para identificação de feições, baseada na descrição de padrões identificadores, tais como textura, cor, métrica, contexto. A figura 2.5 mostra um exemplo simples da importância do contexto, por exemplo, para o processo de interpretação.



Figura 2.5 Importância da classificação contextual. A adição de um garfo e uma faca imediatamente classifica o círculo como um prato. Fonte: Definiens (2010)

A classificação orientada a objeto ainda se diferencia das demais por apresentar a possibilidade de se realizar multissegmentações, gerando níveis hierarquizados, incluindo ainda aspectos de multirresolução. A figura 2.6 ilustra uma rede hierárquica de objetos de imagem, no qual cada um reconhece a sua vizinhança, seus sub-objetos (nível abaixo) e super-objetos (nível acima).

A classificação orientada a objetos considera muitos tipos de descritores, tratando-os como parâmetros caracterizadores dos objetos, tais como: cor, textura, tamanho, forma, padrão, localização, contexto, etc. Portanto, a inserção destes elementos, ou seja, do conhecimento do intérprete no processo, consiste em uma alternativa para a distinção de alvos que espectralmente apresentam dificuldades de serem mapeados. A caracterização dos objetos da imagem não pode limitar-se apenas a atributos espectrais, pois estes muitas vezes não conseguem delimitar objetos complexos.



Figura 2.6 Ilustração de uma rede hierárquica de objetos de imagem. Fonte: Definiens (2010)

Blaschke (2010) faz uma revisão sobre as técnicas de análise baseadas em objeto (OBIA), de forma que o autor considera que o "paradigma do pixel" está ultrapassado e que os métodos de GEOBIA mostram-se mais eficientes para a elaboração de um fluxo de trabalho que permitam uma extração explícita da informação

De certa forma, a classificação orientada a objetos é um desenvolvimento da própria classificação por regiões e o seu uso atende a uma necessidade da comunidade científica nos processos de classificação, em razão da grande melhoria na qualidade espacial e radiométrica das imagens de satélite, tendo em vista que os modelos de classificação pixel-a-pixel, não resolvem questões específicas, como por exemplo, a mistura espectral.

Atualmente há uma diversidade de trabalhos voltados para a classificação orientada a objetos aplicada às imagens de alta resolução (em sua maioria em áreas urbanas), como os trabalhos de Pinho (2005), Alves & Vergara (2005). Para imagens de média resolução, destaca-se o trabalho de Cruz *et al.* (2009), abordando o mapeamento de uso e cobertura do Estado do Rio de Janeiro para a escala de 1:100.000. de gerado a partir de imagens TM\LANDSAT-5. Reis *et al.* (2009) faz uso desta mesma metodologia com o mapeamento da APA de São João em escala de 1:50.000.

2.2 PANORAMA DA CARTOGRAFIA DE REFERÊNCIA

Segundo Menezes & Fernandes (2013), com as diferentes finalidades dos documentos cartográficos, surge a necessidade de se dividir a Cartografia em áreas de aplicação, sendo possível caracterizar em duas classes de operações: uma classe voltada para a preparação de mapas gerais e outra para uso geral. Os mapas gerais são utilizados como referência e para a sua preparação são levados em conta aspectos teóricos e operacionais que garantam a exatidão posicional, como por exemplo, as folhas topográficas. Além dos mapas gerais, também existe a produção e uso de mapas com propósitos educacionais ou pesquisas relacionadas à uma determinada temática, cujo interesse principal está vinculada à delineação gráfica dos fenômenos representados.

Além das folhas topográficas, existem outros tipos de dados considerados de referência, como os de controle geodésico, cadastro fundiário e os mapeamentos cadastrais. Segundo o documento que trata do Plano de Ação da Infraestrutura Geoespaciais no Brasil (CONCAR, 2010) os dados de

referência correspondem a um conjunto de dados que proporcionam informações genéricas de uso não particularizado. São produzidos como apoio fundamental para o referenciamento geográfico de informações sobre a superfície do território nacional. Por isso, devem ser utilizados como insumos básicos para o georreferenciamento e contextualização geográfica de mapeamentos temáticos. Dessa forma, são considerados dados de referência àqueles nos quais se constrói ou se referencia qualquer outro dado de referência ou temática.

Evidentemente cada país possui fatores que facilitam ou dificultam o processo dos mapeamentos de referência em seu território. Países com extensões territoriais menores possuirão mais facilidade nessa atividade, assim como as nações mais ricas, que tendem a possuir mais recursos para o investimento na área cartográfica. De qualquer forma, é interessante conhecer algumas questões que envolvem o uso de insumos, as técnicas utilizadas e as escalas de mapeamento em diversos lugares. Por isso, a fim de se ter uma ideia sobre a elaboração de mapeamentos topográficos, foi realizado um breve levantamento sobre algumas instituições produtoras de cartografia de referência no mundo, como nos Estados Unidos, Canadá, Austrália e México. Ao final desse capítulo será descrito um panorama sobre a situação da produção cartográfica de referência no Brasil.

2.2.1 Estados Unidos

Nos Estados Unidos, a produção do mapeamento de referência está concentrada na instituição denominada *United States Geological Survey* (USGS), referência no âmbito das geociências no mundo, tendo em vista que se dedica à várias aplicações, desde estudos de topografia até mapeamento de recursos e desastres naturais. Seus objetivos concentram-se em várias áreas de conhecimento como a biologia, geografia, geologia, geoprocessamento e recursos hídricos.

Alguns produtos disponibilizados são derivados de plataformas aéreas como as ortofotos e modelos envolvendo as técnicas *Light Detection and Ranging* (LIDAR), e tecnologias orbitais, como o LANDSAT e os modelos derivados do SRTM (*Shuttle Radar Topography Mission*). Além disso, podem ser obtidos os dados restituídos das imagens. Até o ano de 2009, a USGS

disponibilizava os seus produtos em meio impresso, através da impressão litográfica. A partir de então, os produtos são disponibilizados em formato GeoPDF [®] com as informações vetoriais e matriciais organizadas através de camadas para que o usuário possa controlar a visualização, conforme mostra a figura 2.7. As camadas disponibilizadas correspondem à elementos de hidrografia, relevo, sistema de transporte, limites, além das ortofotos, cujas resoluções podem variar de 15 cm até 1 metro (disponíveis para download). Esse tipo de produto está disponível no site <u>http://nationalmap.gov/ustopo/</u> e permite o acesso à mapeamentos novos e mapas considerados de valor histórico. Segundo o planejamento da USGS os dados topográficos devem ser revisados a cada 3 anos.



Figura 2.7: Folha topográfica 1:24.000 em GeoPDF

A USGS desenvolve o projeto US TOPO, cujos produtos são similares ao mapeamento topográfico feito pelo Exército e IBGE no Brasil. As escala de mapeamento são 1:24.000, 1:62.500, 1:100.00 e 1:250.000, sendo que apenas no primeiro caso, os mapas são derivados a partir da interpretação de imagens. Para as escalas cartográficas menores, o mapeamento é feito através de compilação cartográfica. Como existem recursos para mapear todo o território em 1:25.000, esse dado é usado como referência para se gerar outros mapas através de processos de generalização.

O uso de imagens orbitais, principalmente os sensores da missão LANDSAT, é mais voltado para aplicações temáticas, como por exemplo, mapeamento de uso e cobertura da terra, além de estudos específicos sobre estudos oceanográficos e características geológicas.

2.2.2 Canadá

A instituição denominada *Natural Resources Canada* (NRCan) é responsável pela aquisição, gestão e disseminação da informação topográfica. Todos os dados topográficos, assim como os outros tipos de dados geoespaciais, são armazenados em um banco de dados geográficos denominado *National Topographic Data Base* (NTDB), cujo objetivo é concentrar dados e informações em diferentes formatos e escalas.

Em relação aos dados topográficos, os usuários podem acessar os dados em formato *shapefile*, através do seu site (<u>http://www.nrcan.gc.ca/earth-sciences/geography/topographic-information</u>) ou irem até um dos 900 pontos de venda do material impresso. Existe um incentivo para que a população utilize essa base cartográfica para diferentes finalidades, principalmente o turismo, sendo disponibilizada nas escalas 1:50.000 e 1:250.00. Segundo a NRCAN, os mapas na escala 1:50.000 são ideais para atividades de lazer, como ciclismo, canoagem, pesca, *camping* e caminhadas por apresentarem uma diversidade de informações sobre hidrografia e relevo. Além disso, esses mesmos mapas são usados por diferentes esferas governamentais para controle de enchentes, preservação de áreas naturais, planejamento de vias de transporte e monitoramente de áreas agríciolas. Já os mapas na escala 1:250.000 podem ser usados para planejamento de viagens pelos turistas.

Para a elaboração dessas bases cartográficas, a NRCan utiliza ortofotos e imagens SPOT-5 como principais insumos.

Em algumas áreas específicas, como na província de Quebec, por exemplo, podem ser encontrados mapas topográficos gerados na escala

1:100.000, elaborados através de duas formas (CARIGNAM & DUMOULIN, 2002):

- Onde existem áreas com mapeamento 1:20.000, o mapeamento é feito através de generalização cartográfica.
- Nas áreas onde não existem mapeamentos 1:20.000, é feito um mapeamento novo ou atualização através de SPOT-5.

A figura 2.8 mostra um exemplo do processo de generalização feito para a elaboração de mapeamento 1:100.000 em Quebec. Nota-se uma diferença significativa na densidade de informações.



Figura 2.8: Mapeamento 1:20.000 (A) e 1:100.000 (B) em Quebec.

2.2.3. Austrália

Na Austrália, o mapeamento topográfico é feito através da instituição governamental *Geoscience Australia*, responsável pelo mapeamento na escala 1:100.000 e menores, enquanto o mapeamento na escala 1:50.000 é realizado

em conjunto com o Departamento de Defesa da Austrália. Nessas duas escalas, *a c*obertura de mapeamento é parcial, predominando no norte da país, ao longo das principais vias de transporte e outras áreas selecionadas pelo governo. A única base de dados cujo território está totalmente mapeado é na escala 1:250.000, mesmo assim existem folhas com mais de 40 anos de edição.

Em termos de acesso aos dados, ainda é possível adquirir mapas impressos através de pedidos, porém muitos mapas ainda correspondem à cópias digitalizadas de mapeamentos das décadas de 1970 e 1980. De qualquer forma, a inciativas de atualização, tem em vista que a *Geoscience Australia* elabora um produto denominado *GEODATA*, a fim de armazenar e disponibilizar dados digitais atualizados através de imagens e outras formas de levantamento, possibilitando ao usuário editar e utilizar dos dados para diferentes tipos de análises espaciais. Para a elaboração e atualização dos mapeamentos 1:100.000 e 1:250.000, o principal insumo corresponde à imagens SPOT-5.

Um aspecto interessante é a disponibilização, na página principal da instituição (http://www.ga.gov.au/mapspecs/topographic/v5/index.html), de vários documentos técnicos que tratam das etapas de mapeamento. Um deles trata do processo de interpretação de imagens, estabelecido através de um guia voltado para operadores que trabalham com interpretação visual. Segundo a Geoscience Australia, o objetivo do Guia de Interpretação é padronizar a forma de captura e interpretação das feições cartográficas. A proposta é auxiliar nas dúvidas e dificuldades encontradas no que se refere à questão de interpretação. As figuras 2.9 e 2.10 mostram exemplos extraídos desse documento, cuja organização é dividida de acordo com as categorias de informação usadas na Austrália: Habitação, Transporte, Hidrografia, Infraestrutura, Vegetação, Agricultura e Estrutura Portuárias.



Figura 2.9: Exemplo extração de ferrovias (Geoscience Australia, 2007)

No caso da figura 2.11, que mostra a indicação de ferrovia (*Railway*), ao lado das imagens, são descritas algumas observações, como por exemplo:

"1- Ferrovias são geralmente mais finas do que as estradas e com menos cruzamentos. Possuem curvas suaves e sem mudanças bruscas de direção."
2- Geralmente não há pontos de acesso, edifícios e infraestrutura ao

2- Geralmente nao ha pontos de acesso, edificios e infraestrutura ao longo da linha ferroviária". (GEOSCIENCE AUSTRALIA, 2007)

Para cada feição a ser interpretada são mostradas duas figuras: uma ortofoto, com 60 cm de resolução em composição colorida verdadeira, além de uma imagem SPOT, com 2,5 metros e composição falsa-cor, conforme mostra a figura 2.12, que tenta identificar canais de drenagem e fonte d´água.



Figura 2.10: Exemplo extração de canais de drenagem (Geoscience Australia, 2007)

2.2.3 México

Apesar de não possuir um território extenso a ser mapeado em relação aos outros países citados, a realidade do México talvez seja a mais próxima do Brasil em virtude de suas características socioeconômicas, ou seja, não está no grupo de países que, teoricamente, dispõe de mais recursos para investimentos. Assim como no Brasil, existe no México uma instituição que concentra a produção de dados estatísticos e cartográficos denominado *Instituto Nacional de Estadística y Geografía* (INEGI).

A produção de mapeamento topográfico envolve as escalas 1:20.000, 1:50.000, 1:250.000 e 1:1.000.000. O mapeamento 1:20.000 (figura 2.11) é um produto cartográfico que integra informação de infraestrutura, relevo, hidrografia e dados socioeconômicos, compilada mediante restituição fotogramétrica, dados de informação geodésica e reambulação. Os principais insumos são as ortofotos digitais, na escala 1:10.000, com resolução de 1 metro, derivadas de fotografias aéreas nas escalas 1:40.000 e 1:50 000. (INEGI, 2013). O principal propósito dos mapas nessa escala é apoiar projetos de planejamento de caráter local ou municipal, sendo utilizado principalmente como suporte para estudos urbanos. São 1997 folhas disponibilizadas aos usuários, sendo as mais antigas produzidas no ano de 2004.

O mapeamento na escala 1:50.000 é realizado através de compilação fotogramétrica. Além de auxiliar no planejamento local e municipal, uma de suas principais aplicações é servir de apoio para mapeamentos temáticos em escalas menores. Uma das diferenças em relação ao mapeamento 1:20.000 está na atualização das folhas, sendo que apenas 46% das folhas foram produzidas do ano 2000 em diante e cerca de 23 % do mapeamento ainda são da década de 1970.

Já o mapeamento na escala 250.000 é realizado através da interpretação de imagens do TM\LANDSAT 5 (INEGI, 2013). O uso de imagens SPOT-5 é realizado para eventuais atualizações nessa escala. Os dados do mapeamento 1:250.000 correspondem ao principal insumo para o mapeamento na escala 1.000.000.

Todos os dados disponibilizados pela INEGI são realizados através de seu portal, no qual o usuário pode realizar buscas através de vários critérios, como escala, ano de edição do mapa, índice de nomenclatura e título. A maioria dos dados são gratuitos e oferecidos em formatos como shapefile, geotiff (no caso de mapas escaneados) e GeoPDF[®].



Figura 2.11: Extração de elementos sobre uma ortofoto para mapeamento 1:20.000. Fonte: INEG (2013)

2.2.4 Brasil

Em termos de produção cartográfica em âmbito nacional, os mapeamentos se concentram em duas instituições: a Diretoria de Serviços Geográficos (DSG) e o Instituto Brasileiro de Geografia e Estatística (IBGE). Os dois principais órgãos produtores da cartografia de referência adotam, em suas linhas de produção, técnicas computacionais para a elaboração de seus produtos. Segundo a CONCAR (2007), cabe à DSG o estabelecimento de Normas Técnicas para a Cartografia Nacional, no que concerne às escalas de 1:250.000 e maiores, enquanto o IBGE fica responsável pela definição de Normas Técnicas para escalas menores que 1:250.000. Porém, apesar de haver uma divisão de atividades em termos de definição de normas, não há impedimento para que os dois órgãos produzam mapas e cartas em escalas cujas normas foram estabelecidas pelo outro órgão. Os principais produtos cartográficos disponibilizados pelas duas instituições são: folhas topográficas,

bases cartográficas contínuas, ortoimagens e modelos digitais de elevação (IBGE, 2011a); (DSG, 2010).

Em 1978 foi criado o Plano de Dinamização da Cartografia (PDC), para intensificar o mapeamento sistemático brasileiro, visando a cobertura plena do território na escala de 1:250.000; o incremento da cobertura na escala 1:100.000, nas regiões Centro-Oeste e Nordeste e em parte das regiões Sudeste e Norte; e o incremento na escala 1:50.000 nas regiões Sul e parte do Sudeste e Nordeste; além de serem produzidas bases cartográficas na escala 1:25.000 nas capitais estaduais.

Porém, atualmente se observa uma carência de mapeamento no Brasil, principalmente em escalas maiores que 1:100.000, agravada pelo fato de grande parte estar desatualizado. Em grande parte do território há a disponibilização de dados cartográficos gerados há 30 ou 40 anos, fazendo com que muitos usuários desse tipo dado optem por outras fontes alternativas ou façam, mesmo sem conhecimento especializado para tal, as próprias atualizações. Quaisquer destas escolhas complicam o estabelecimento de uma base única de referência nacional.

A elaboração de bases cartográficas em escalas maiores que 1:25.000, consideradas como mapeamento cadastral, é de responsabilidade dos municípios, embora não haja, ainda, uma normatização definida através de leis.

Para auxiliar no planejamento cartográfico e no acompanhamento das necessidades que envolvem esse cenário, existe a Comissão Nacional de Cartografia (CONCAR), constituindo-se de colegiado composto por membros de diversas instituições, em sua maioria da esfera pública. Dessa forma, a CONCAR cria comitês técnicos que discutem os problemas inerentes ao contexto cartográfico, a fim de criar especificações que orientem a produção cartográfica. Ao final desse processo tais normas são aprovadas e homologadas em plenárias.

De uma forma geral, o IBGE é responsável pelo que se denomina de mapeamento geográfico, produtos que representam escalas menores que 1:250.000. Nesse grupo está incluído o projeto de base contínua do Brasil ao milionésimo (BCIM), assim como os mapas políticos e físicos das unidades de federação e do Brasil. Nesses casos, todos os mapeamentos são elaborados através de generalização cartográfica da escala 1:250.000

Além disso, a instituição gerencia o projeto de base contínua na escala 1:250.000, cujo insumo principal corresponde à imagens do satélite TM\LANDSAT 5, mas há uma grande perspectiva de iniciar os trabalhos de atualização usando o sensor RapidEye.

Além disso, o IBGE participou, através de um convênio com a Secretaria Estadual de Meio Ambiente do Rio de Janeiro, da elaboração do mapeamento 1:25.000 para todo estado, dividindo a produção cartográfica com uma empresa privada. Além disso, eventualmente, participa de análise de dados cartográficos produzidos pelas unidades de federação para mapeamentos na escala 1:25.000, como por exemplo, na parceria com a Empresa Paulista de Planejamento Metropolitano (EMPLASA) para realizar sistemático controle sobre as etapas de Levantamento Aerofotogramétrico.

Em termos de disponibilização, o IBGE não fornece material impresso ao usuário, sendo necessário acessar o seu site (<u>www.ibge.gov.br</u>) para obter dados em formato shapefile, geotiff e DGN (formato CAD do *software MicroStation*). No ano de 2015, a instituição criou um portal de mapas (figura 2.12) que possibilita um novo acesso à diferentes dados geográficos. No portal (<u>www.portaldemapas.ibge.gov.br</u>) são disponibilizados os mapas dos Atlas publicados, as bases cartográficas, folhas topográficas, mapas do mundo, do Brasil, regionais e municipais, mapas de recursos naturais, sociedade e economia e do território, além de imagens de satélite e ortofotos aéreas de algumas áreas do Brasil. Há ainda informações sobre análises do território, malhas territoriais, informações de posicionamento geodésico.

Historicamente a DSG constitui o principal produtor de dados cartográficos para mapeamentos entre 1:25.000 e 1:100.000 e atualmente os principais trabalhos correspondem aos projetos de Radiografia da Amazônia; o mapeamento 1:50.000 da Bahia; o mapeamento 1:25.000 e 50.000 do Amapá; e a Certificação de Propriedades Rurais, através de convênio com o Instituto Nacional de Colonização e Reforma Agrária (INCRA). O Projeto Radiografia da Amazônia tem como objetivo a elaboração de aproximadamente 20.000 produtos cartográficos (cartas topográficas, ortoimagens SAR, Modelos Digitais de Elevação, etc.) e de estratificação vegetal, nas escalas de 1:100.000 e de 1:50.000, da região do vazio cartográfico da Amazônia Legal (CORREIA, 2011). Já o projeto Estado da Bahia tem como objetivos a elaboração de 1552

folhas na escala 1:25.000 e 432 folhas na escala 1:100.000, além da avaliação técnica de imagens. Além disso, a DSG está coordenando normas e procedimentos técnicos, como a Especificação Técnica para a Aquisição dos Dados Geoespaciais Vetoriais (ET-ADGV), Especificação Técnica de Produtos de Conjuntos de Dados Geoespaciais (ET-PCDG) e a Especificação Técnica do Controle de Qualidade dos Produtos de Conjuntos de Dados Geoespaciais (ET-CQPCDG).



Figura 2.12: Portal de mapas do IBGE.

A disponibilização de dados da DSG é através de seu portal (<u>www.geoportal.eb.mil.br</u>), onde é permitido o acesso ao banco de dados geográficos do Exército, incluindo, por exemplo, as folhas do mapeamento sistemático em diferentes escalas. É disponibilizado, também, um *plugin* desenvolvido para o software livre Quantum Gis, que permite aos usuários a criação de bases cartográficas de acordo com as especificações técnicas atuais do Sistema Cartográfico Nacional. No capítulo seguinte são descritos alguns detalhes dessas normas vigentes.

2.3 SENSORES REMOTOS

Nas últimas décadas, as tecnologias e métodos associados ao uso do sensoriamento remoto estão evoluindo quantitativamente e qualitativamente. Em termos numéricos, se observa um aumento do número de plataformas

orbitais gerando imagens da paisagem terrestre. Segundo a *International Society for Photogrammtery and Remote Sensing* (2008), enquanto no período entre 1984 e 1997 foram lançados seis satélites de observação da Terra com resolução espacial melhor que 60 metros, o período entre 1998 e 2007 foi marcado pelo lançamento de cinquenta satélites.

Além dos países com bastante tradição no desenvolvimento de sensores orbitais, como Estados Unidos e França, outros países começaram a desenvolver, a partir da década de 1990, novas tecnologias associadas à plataformas de sensoriamento remoto, como Brasil, Nigéria, Emirados Árabes e Tailândia. Porém, apesar de existirem mais sensores, isso não significa necessariamente mais opções de imagens para os usuários. Isso porque, na maioria das vezes, um determinado satélite apenas tem suas imagens disponibilizadas para uma região específica, de acordo com o país onde está localizado o programa espacial que o desenvolveu. Alguns exemplos são o RazakSat (lançado em 2008 pela Malásia, com uma banda pancromática de 2.5 e bandas multiespectrais de 5 metros) e o Alsat-2B (lançado em 2009 pela Argélia, com banda pancromática de 2.5 multiespectrais de 10 metros). De qualquer forma, o crescimento quantitativo no número de satélites demostra a necessidade do uso desse tipo de tecnologia para estudar o espaço terrestre, assim como analisar mudanças que ocorrem ao longo do tempo.

Vale destacar que existem satélites com cobertura global e que ganharam uma importância significativa perante a comunidade científica internacional, sendo o exemplo mais significativo o programa LANDSAT, que desde a década de 1970 disponibiliza imagens de todo o mundo. Durante alguns anos, entre o problema operacional com o TM\LANDSAT-5, e o fornecimento de imagens do OLI\LANDSAT-8, muitos usuários sentiram falta de imagens orbitais com as mesmas características desses sensores. Ainda mais porque esse satélite atendia a um grande número de aplicações, como por exemplo, estudos ambientais, socioeconômicos e geração de bases cartográficas em pequenas e médias escalas. Outra importante questão é a possibilidade de se ter uma longa série temporal de imagens globais, que possibilita estudos de detecção de mudanças de diferentes fenômenos. Talvez, esse aspecto seja contraditório, porque ao mesmo tempo em que temos mais sensores sendo lançados, continua-se dependendo de determinadas

plataformas para a continuação de estudos sobre a superfície terrestre. Essa contradição é explicada pelas restrições de cobertura, conforme explicado acima.

Em termos qualitativos, verifica-se a existência de uma maior diversidade de sensores em termos de resolução e, talvez, o principal avanço seja em termos espaciais. Em 2001, por exemplo, existiam dois sensores de alta resolução espacial: o IKONOS-2 e *Quickbird*, cujas bandas pancromáticas possuem o tamanho do pixel na ordem de centímetro. Atualmente, existem mais sete sensores com cobertura global com essa característica: Pleaides 1 e 2; KOMPSAT-3; Geoeye; WorldView 1 e 2; e Cartosat-2.

Além disso, nos últimos dez anos, apareceram novos sensores com resoluções entre 1 e 10 metros. Até 2003, a plataforma SPOT dominava a distribuição de imagens nessa faixa de resolução. Dentre os mais recentes, pode-se destacar o THEOS e RapidEye, além do SPOT-6. Os sensores AVNIR-2 e PRISM localizados no satélite ALOS, cujas resoluções eram de 10 e 2.5 metros respectivamente, não estão mais em operação. O quadro 2.1 mostra os principais satélites em operação atualmente, ressaltando-se que não aparecem os sensores com baixa resolução espacial, atendendo geralmente a estudos oceanográficos e meteorológicos.

De uma forma geral, os sensores de alta e média resolução espacial (entre 0.5 a 30 metros) possuem uma ampla diversidade de aplicações, como por exemplo, na produção e delimitação de áreas agrícolas; no mapeamento cadastral; monitoramento da cobertura vegetal; mapeamento de risco e sensibilidade ambiental; e mapeamentos normatizados pelo Sistema Cartográfico Nacional (SCN).

Plataforma	Sensor	Início de	GSD	Cobertura	Radiometria
		imageamento	(m)	espectral	(bits)
		-		(μm)	
Eros A	CCD	2000	1.9	0.5 – 0.9	11
Eros B	CCD/TDI	2006	0.7	0.5 – 0.9	10
Googly 1	MULTI	2008	1.65	0.450 - 0.920	11
Geoeye-1	PAN	2008	0.41	0.45 – 0.8	11
Sentinel-2	2A / 2B	2015	10 /20 /60	0.443-2.190	12
Resourcesat-	LISS-III		23.5	0.52 – 1.70	
1	LISS-IV	2004	5.8	0.52 – 0.86	7
·	AWIFS		56	0.52 – 1.70	
Resourcesat-	LISS-III	2012	23.5	0.52 – 1.70	10
2	LISS-IV		5.8	0.52 – 0.86	10
_	AWIFS		56	0.52 – 1.70	12
Cartosat-2	PAN	2008	0.8	0.5- 0.85	10
Cartosat-2A	PAN	2009	0.8	0.5 – 0.85	10
Cartosat-2B	PAN	2011	0.8	0.5 – 0.75	10
Kompost 2	PAN	2007	1	0.5 – 0.9	40
Kompsal-2	MULTI	2007	4	0.45 – 0.9	10
Kompeat-3	PAN	2013	1	0.5 – 0.9	10
Rompsat-5	MULTI	2013	4	0.45 – 0.9	10
Landsat 8	OLI	2013	15 (pan) 30 (multi)	0.433-2.3	12
Pleaides	HiRI		0.5 (pan)		
(1A\1B)	(pan e	2012	2 (multi)	0.430-0.940	12
	multi)		_ ()		
Rapid Eye	DEIO	0000	6.5 (nadır)	0.440.0.050	40
	REIS	2009	5	0.440-0.850	12
	ПРС		(onoimagens)		
			10 ou 5	0.48 – 0.70	
	(pan) HRG				
5-015	(pap)	2003	5 ou 2.5	0.48 -071	8
	HRG		10	0.5 - 0.89	
	(multi)		20 (SWR)	1.58 - 1.75	
SPOT 6 e 7		0010		0 455 0 745	40
	PAN	2013	1.5	0.455-0.745	12
Theos	PAN	2000	2	0.450 – 0.90	10
	MULTI	2009	15	0.45 – 0.90	12
WordView-1	PAN	2008	0.5 a 0.6	0.4 – 0.9	11
WordView-2	PAN	2010	0.46 a 0.52	0.450 – 0.80	11
	PAN		0.31	0.450 – 0.80	11
WordView-3	MULTI		1.24	0.4- 1.04	11
	SWIR	2015	37	1 19- 2 36	11
			30	0.40-2.20	11
Morel Correct			0.21	0.70 - 2.24	11
vvoraview-4		2016	0.31	0.450 - 0.60	
	NULTI		1.24	0.4- 1.04	11

Quadro 2.1: Principais sensores óticos em operação. Fonte: CEOS, 2014

Os sensores mais utilizados para mapeamentos com fins de cadastro, mapeamentos de risco e agricultura de precisão, ou seja, para atendimento à grandes escalas, são os de alta resolução espacial, como o Geoeye, WorldView-2 e Quickbird. Por outro lado, os sensores cujas resoluções estão entre 10 e 30 metros geralmente são mais usados para mapeamentos em pequenas e médias escalas (1:100.000 e menores) como o OLI\LANDSAT e AVNIR-2\ALOS. Porém, existem outros sensores disponíveis, como por exemplo, no caso de monitoramento da cobertura vegetal em uma área de abrangência grande, vale destacar o programa de monitoramento da Amazônia do INPE, que utiliza sensores com resoluções de 250 m (WFI / CBERS e MODIS/TERRA). (INPE, 2008)

Para maiores esclarecimentos sobre os satélites atuais, a CEOS (*Committee on Earth Observation Satellites*) disponibiliza em seu site (<u>http://www.eohandbook.com</u>) um banco de dados com informações atualizadas sobre todos os satélites, permitindo a consulta através de vários critérios.

Dentre as resoluções de um satélite, talvez a espacial seja a mais significativa no momento de escolher um determinado sensor para uma aplicação, tendo em vista que é o parâmetro que define a capacidade do sensor em detectar objetos. De qualquer forma, apenas o conhecimento do valor da resolução espacial não garante a capacidade de detectar objetos. A qualidade da imagem de um sensor de alta resolução espacial pode ser afetada pelas distorções geométricas inerentes à plataforma, ao sensor, ao angulo de inclinação do sensor, à rotação e relevo terrestre (BARROS, 2006). Showengerdt (1997) associa questão da resolução espacial com a capacidade de detectar alvos ao afirmar que vários componentes de um sensor, como lentes, espelhos e detectores, modificam as propriedades espaciais dos objetos da cena em pelo menos dois aspectos: borrando o limite entre alvos distintos e distorcendo as propriedades geométricas dos alvos. Por isso, é importante conhecer as características históricas de cada sensor, tendo em vista que ao longo do tempo, os instrumentos podem apresentar até falhas que podem comprometer a qualidade das imagens geradas. Um exemplo desse tipo de situação é o satélite CBERS-2B, que em 2009 apresentou avarias no sistema de controle da atitude, acarretando problemas no posicionamento das imagens.

Por isso, cada satélite lançado possui um tempo de vida útil estimado. Essa informação é importante para o usuário, uma vez que os satélites com o tempo de funcionamento acima da expectativa de vida útil tendem a apresentar maiores dificuldades operacionais.

Além das características geométricas, a detecção de elementos de imagem dependerá do contraste radiométrico entre o pixel desse elemento e seus vizinhos. Novo (2010) afirma que feições menores que a resolução são passíveis de detecção se a sua reflectância média for maior do que a dos objetos vizinhos. Um exemplo clássico desse tipo de situação é a detecção de rodovias, que apesar de, geralmente, possuírem larguras com até 10 metros, podem ser vistas em imagens orbitais com 30 metros. Entretanto, podem ocorrer casos de objetos que apresentam dimensões maiores que a resolução espacial, mas não é possível a sua detecção de forma nítida, como por exemplo, algumas edificações e cursos d´água.

Tratando-se em termos radiométricos, observa-se também um grande avanço uma vez que foram desenvolvidos sensores com maior capacidade de distinguir diferenças de intensidade do sinal de energia refletida pelo alvo na superfície. Alguns anos atrás, grande parte dos sensores geravam imagens com 8 bits, enquanto, atualmente, a maioria fornece imagens com até 16 bits.

Em termos espectrais, atualmente observa-se sensores com diversas características, sejam multiespectrais ou hiperespectrais. Porém, o uso para dados hiperespectrais, geralmente, é voltado para aplicações que necessitam diferenciar de forma precisa as respostas espectrais de determinados alvos, através da coleta de mais de 200 bandas ou mais. Dessa forma, esse tipo de sensor adquire imagens em estreita faixa espectral de forma contínua, desde o visível até partes do infravermelho termal.

Para desenvolver o presente estudo, serão avaliadas imagens com diferentes características, de forma a estabelecer uma comparação em termos de interpretação. Dessa forma, serão descritas as principais propriedades de alguns sensores bastante utilizados no Brasil para fins de mapeamento de referência e temático e que podem ser analisados durante o transcorrer de estudo.

A seguir serão detalhadas as principais caracreísticas dos três sensores analisados nesse estudo, selecionados por apresentarem resoluções

radiométricas, espectrais e, principalmente, especiais distintas. A escolha foi estabelecida em virtude dos diferentes tamanhos de pixels das imagens, possibilitando comparar a extração das feições realizada em sensores distintos. Apesar do AVNIR-2 não apresentar imageamento novo durante o desenvolvimento da tese, optou-se por utilizá-lo por ser um instrumento que adquiriu imagens com resolução espacial intermediária entre o RapiEye e a imagem fusionada do OLI / LANDSAT-8.

O processo de fusão de imagens de sensoriamento remoto pode ser efetuado tanto com bandas de um mesmo sensor quanto com bandas de diferentes sensores, visando como resultado melhorias na visualização dos detalhes das feições das imagens. Para Fonseca (2000), as técnicas de fusão de imagens consistem em integrar a melhor resolução espacial da banda pancromática a melhor resolução espectral das demais bandas, produzindo uma imagem colorida que reúne ambas características. Na atualidade existem diversas técnicas de fusão de imagens orbitais. Nesse estudo, optou-se pela fusão da imagem multiespectral OLI/LANDSAT-8 de resolução de 30m com a imagem pancromática de resolução de 15m, pelo método de normalização espectral de cores, sendo usadas as seguintes combinações de bandas e cores: 4R3G2B e 5R4G3B. O uso de combinações RGB foi realizado em função de a área de estudo apresentar características heterogêneas quanto ao relevo e vegetação, resultando em variações no comportamento espectral dos alvos.

2.3.1 OLI/LANDSAT-8

O LANDSAT-8 é o oitavo satélite da missão da NASA, referência para a produção e disseminação de dados e produtos de sensoriamento remoto, cujo início ocorreu com o lançamento em 1972 do LANDSAT-1. Desde então, todos os satélites desse programa (com exceção do LANDSAT-6, que não entrou em órbita) contribuíram para estudos e produção de mapas temáticos e de referência.

O LANDSAT-8 é composto por dois sensores: Operational Land Imager (OLI) e o Thermal Infrared Sensor (TIRS), sendo o OLI usado para fins de observação da paisagem, enquanto o sensor TIRS é utilizado para medir a temperatura da superfície da terra em duas bandas térmicas (bandas 10 e 11), cujo comprimento de onda nos sensores TM e ETM+ estava coberto em uma única banda. Comparando-se aos outros satélites antigos do programa, foram adicionadas duas novas bandas espectrais: a *new coastal* (banda 1), projetada especificamente para os recursos hídricos e investigação da zona costeira, e um novo canal no infravermelho (banda 9), para a detecção de nuvens tipo cirros. O acréscimo dessas bandas provocaram mudanças nos intervalos dentro do espectro dos canais de todas as bandas. Há também uma nova banda denominada Garantia de Qualidade (Banda QA), que fornece informações sobre a presença de nuvens, água e neve (NASA, 2013). Nos dois sensores a resolução radiométrica é de 12 bits. A resolução espacial no sensor OLI é de 30 metros, com exceção da banda 8, pancromática, com 15 metros. O quadro 2.3 mostra as principais características dos sensores do LANDSAT-8.

Sensor	banda	Faixa espectral (µm)	Resolução espacial (m)	
OLI	1	0.43–0.45	30	
	2	0.45–0.51	30	
	3	0.53–0.59	30	
	4	0.64–0.67	30	
	5	0.85–0.88	30	
	6	1.57–1.65	30	
	7	2.11–2.29	30	
	8	0.5–0.68	15	
	9	1.36–1.38	30	
TIRS	10	10.60–11.19	100	
	11	11.5-12.51	100	

Quadro 2.2: Principais características do LANDSAT-8.

O quadro 2.3 abaixo mostra os principais exemplos de aplicações do OLI\LANDSAT-8.

A tendência é o uso cada vez maior dessas imagens, já que representam um importante insumo para o planejamento regional. Além disso, os dados são disponibilizados gratuitamente no mecanismo de pesquisa GLOVIS (<u>http://glovis.usgs.gov/</u>) ou Earth Explorer (<u>http://earthexplorer.usgs.gov/</u>).
Quadro 2.3: Faixas espectrais e principais aplicações do OLI\LANDSAT-8.

Banda	Faixa espectral	Exemplos de aplicações			
	(μm)				
1	0.43–0.45	Monitoramento de águas com pouca profundidade e partículas finas em suspensão.			
2	0.45–0.51	Análises de uso e cobertura do solo			
3	0.53–0.59	Reflectância de vegetação verde sadia			
4	0.64–0.67	Discriminação de espécies vegetais			
5	0.85–0.88	Detecção de biomassa da vegetação Identificação de culturas agrícolas			
6	1.57–1.65	Análise sobre umidade do solo e características de rochas			
7	2.11–2.29	Análise sobre umidade do solo e características de rochas			
8 (pan)	0.5–0.68	Melhorar o detalhamento de alvos			
9	1.36–1.38	Avaliação de cobertura de nuvens cirrus			

Fonte: (NASA, 2013)

Outro fator positivo é a exatidão posicional das imagens, que segundo a NASA (2013) apresenta erro com até 12 m (CE 90) para os dados do sensor OLI. Para um sensor de média resolução espacial, o valor do erro geométrico esperado é realmente muito pequeno.

Ao longo dos anos, as principais aplicações dos sensores TM, ETM+ e OLI do LANDSAT estavam voltadas para a geração de mapas temáticos, principalmente uso e cobertura da terra. É muito comum encontrar trabalhos relacionados à estimativa de biomassa florestal, a partir da geração de índices de vegetação. Além disso, muitas instituições de pesquisa criaram bases de dados geográficos, utilizando como insumo as imagens desses sensores, além do armazenamento em séries temporais, possibilitando acompanhar a evolução de processos sobre a paisagem.

No caso de mapeamento de referência, vale destacar o uso de dados do TM\LANDSAT-5 para o mapeamento na escala 1:250.000, realizado pelo IBGE (IBGE, 2011a).

2.3.2 AVNIR-2 / ALOS

O satélite ALOS (*Advanced Land Observation Satellite*) deixou de operar em 2011, mas as suas imagens continuam a ser usadas para fins de mapeamento. Era composto por três sensores: *Panchromatic Remote-sensing Instrument for Stereo Mapping* (PRISM), *Advanced Visible and Near Infrared Radiometer type 2* (AVNIR-2) e *Phased Array type L-band Synthetic Aperture Radar* (PALSAR).

No caso do PALSAR, por se tratar de um instrumento radar, suas aplicações são específicas e suas imagens quanto utilizadas de forma isolada não possibilitam uma interpretação de feições de forma fácil. Porém, podem ser usadas como recursos extras para auxiliar o processo de interpretação e especialmente úteis em regiões que estão constantemente cobertas por nuvens.

O sensor PRISM gera imagens pancromáticas com 2,5 metros de resolução espacial e pode cobrir uma largura de 35 ou 70 km, dependendo do modo de operação, com resolução radiométrica de 8 bits e possui capacidade estereoscópica. Estudo do IBGE (2009) indicou erro planimétrico na ordem de 9,6 metros, com desvio padrão de 2.1 metros.

O AVNIR-2 apresenta resolução espacial de 10 metros, em 4 bandas espectrais equivalentes ao Azul, Verde, Vermelho e Infravermelho Próximo. O sensor AVNIR-2 é capaz de operar em visada nadir ou visada inclinada transversal à direção de órbita, com ângulo de inclinação que pode variar até +/- 44 graus, o que permite reduzir o tempo de revisita em áreas específicas. Avaliação do IBGE (2011b) mostra que 90% dos pontos de avaliação possuem erro planimétrico com até 21,7 metros, com desvio padrão de até 3 metros. O quadro 2.4 mostra algumas características do AVNIR-2 e PRISM.

Durante alguns anos, as imagens do sensor AVNIR-2 serviram como insumo para mapeamentos realizados pelo IBGE em atendimento à escala 100.000. As imagens ortorretificadas do AVNIR-2 foram disponilizadas para o público através do site do IBGE, assim como as cartas-imagens. Como a instituição obteve acesso à insumos com resolução espacial mais detalhados, as imagens do AVNIR- 2 foram gradualmente sendo substituídas para a produção do mapeamento 1:100.000, mas servem para acompanhamento da elaboração da base cartográfica contínua na escala 1:250.000. Além disso, atualmente, o seu acervo pode ser utilizado para fins de pesquisa pelos funcionários da instituição.

Além disso, outro tipo de aplicação destinada para o sensor AVNIR-2 é a elaboração de mapeamento temáticos, enquanto o PRISM, além de atender ao mapeamento urbano, possibilitava também a geração de modelos digitais de elevação.

Sensor	banda	Faixa espectral (μm)	Resolução espacial (m)		
PRISM Pan		0.52-0.77	2.5		
	1	0.42-0.50	10		
	2	0.52-0.60	10		
AVINIK-Z	3	0.61-0.69	10		
	4	0.76-0.89	10		

Quadro 2.4: Principais carecterísticas do PRISM e AVNIR-2.

2.3.3 RapidEye

O sistema Rapideye constitui uma constelação de cinco satélites idênticos: TACHYS, MATI, CHOMA, CHOROS, TROCHIA, sendo que cada um carrega o sensor denominado REIS (*RapidEye Earth Imaging System*). Essa variedade de satélites possibilita a coleta de uma área de abrangência significativa, no qual cada imagem possui 78 Km de largura e em um curto período de tempo. As câmeras atuam em 5 faixas do espectro eletromagnético, do visível ao infravermelho próximo, incluindo a chamada *Red-edge* (quadro 2.5)

As fornecedoras desse sensor disponibilizam dois tipos de produtos para os usuários:

- O Nível 1B corresponde ao produto corrigido do ponto de vista radiométrico e geométrico, a partir dos dados de efemérides e atitude dos satélites, sem uso de pontos de controle.
- O Nível 3A corresponde ao produto ortorretificado usando-se o modelo digital de elevação SRTM (nível 1 DTED). Segundo a RapidEye AG (2012), esse produto pode alcançar uma exatidão de 6m, com 12,7 m CE90).

No nível 1B a resolução espacial da imagem é de 6,5m, enquanto no nível 3A, o tamanho do pixel é reamostrado para 5 metros, sendo que nos dois níveis a resolução radiométrica original é de 12 bits, porém os dados são disponibilizados em 16 bits.

Sensor	Banda	Faixa espectral (µm)	Resolução espacial (m)
REIS	1	0.440-0.510	5
REIS	2	0.520-0.590	5
REIS	3	0.630-0.685	5
REIS	4	0.690-0.730	5
REIS	5	0.760-0.850	5

Quadro 2.5: Bandas espectrais do RapidEye.

O sistema RapidEye se caracterizou por ser um dos primeiros satélites a disponibilizar a banda *Red-Edge*, contribuindo ainda mais para estudos relacionados à distribuição da cobertura vegetal, por detectar alterações da presença de clorofila. A tabela 2.4 abaixo mostra as bandas espectrais do sistema RapidEye.

Em novembro de 2012 o Ministério do Meio ambiente (MMA) fechou contrato para aquisição de imagens RapidEye para atender as necessidades do cadastro ambiental rural de acordo com o novo código florestal. Observado, então, que essas imagens em cobertura nacional possuem diversas utilidades para o setor público brasileiro, o MMA optou por disponibilizá-las para os organismos federais e estaduais através de um sistema denominado GeoCatalogo disponível em <u>http://geocatalogos.sccon.com.br/mma</u>. Tais imagens podem servir, por exemplo, como insumos para a interpretação e classificação de feições cartográficas, bem como para a produção de mapas temáticos e de referencia.

Os funcionários do IBGE têm acesso a estes dados de forma irrestrita,com possibilidade de realizar o *download* de imagens de todo o território nacional. Até o ano de 2016, as imagens RapiEye constituíam no principal insumo para o projeto Base Contínua na escala 1:100.000.

50

2.4 CONTROLE DE QUALIDADE DO DADO CARTOGRÁFICO

Diversos países¹, a fim de criarem estruturas de compartilhamento de dados e informações geográficas, estão aderindo às normas e especificações internacionais, uma vez que tais documentos constituem os marcos reguladores dessas composições, denominados de Infraestruturas de Dados Espaciais (IDEs). A expectativa do estabelecimento desse marco é para que os dados a serem gerados e a informação a ser integrada ofereçam a garantia de compartilhamento, comparabilidade, consistência e completeza (IGN, 2011).

Alguns estudos que abordam o uso das IDEs (PAIXÃO *et al,* 2008; CONCAR, 2007 & 2010) relatam que o uso de normas e especificações permitem a descoberta, o intercâmbio, a integração e a usabilidade da informação espacial.

Atualmente, existem iniciativas globais e regionais de normas de dados geográficos, tendo a organização denominada Open GIS Consortium (OGC) um papel centralizador nas tomadas de decisão. A OGC é um consórcio internacional, formado por fornecedores e usuários de geotecnologia, cujo é 0 desenvolvimento do objetivo principal mercado. através da interoperabilidade entre serviços e softwares comerciais de geoprocessamento. A OGC trabalha em parceria com a International Organization for Standardization (ISO), que corresponde a um conjunto de comitês de especialistas, divididos em grupos de trabalho, cujo objetivo é desenvolver especificações de controle de qualidade e relatórios de "Prática recomendada". No caso dos dados geográficos, existem as especificações da família 19100, incorporadas por diversos países para a criação e implementação de suas infraestruturas de dados espaciais, inclusive no Brasil, através da Infraestrutura Nacional de Dados Espaciais (INDE).

A OGC trabalha em parceria com a International Organization for Standardization (ISO) no desenvolvimento de documentos técnicos que descrevem diferentes especificações, conforme mostra o quadro 2.6 (ISO 19115, 2003)

¹ Podem ser citados: Estados Unidos (NSDI), Canadá (CGDI), Portugal (SNIG), Espanha (IDEE), Colômbia (ICDE), Cuba (IDERC), Austrália (ANZLIC), Nova Zelândia (ANZLIC), Chile (SNIT), México (IDEMEX) e Equador (IEDG).

19101	Modelo de Referência	19113	Princípios de Qualidade
19101-2	Modelo de Referência: Imagem	19114	Procedimentos de avaliação da
			Qualidade
19103	Esquema Conceitual de banco de dados	19115	Metadados
19104	Terminologia	19115-2	Metadados para Imagens e dados grid
19105	Conformidade	19116	Serviços de posicionamento
19106	Perfis	19117	Portrayal
19107	Esquema Espacial	19118	Codificação
19108	Esquema Temporal	19119	Serviços
19109	Regras para Aplicação de Esquemas	19120	Padrões de funcionamento
19110	Metodologia para Catálogo de Feições	19121	Imagens e dados grid
19111	Referência Espacial por coordenadas	19122	Qualificação e certificação de pessoal
19111	Revisão / Validação	19123	Esquema para dados Coverage e funções
19112	Referência Espacial por geocódigos	19124	Componentes de Imagens e dados grid
19125	Acesso à feições simples – Parte 1 e 2	19134	Serviços baseados em localização –
			roteamento e navegação multimodal
19127	Códigos e parâmetros geodésicos	19135	Procedimentos para registro de ponto
19139	Implementação de Metadados.	19136	Geography Markup Language (GML)
19137	Perfis para esquema espacial	19141	Esquema para recursos móveis
19128	Interface Web Map Server	19138	Medidas para qualidade de dados
19129	Framework para dados matriciais	19142	Web Feature Service (WFS)
19130	Modelos de sensores remotos (removido)	19143	codificação de filtro
19131	Especificação de dados e produtos	19144-1	Sistema de classificação. Parte 1:
			Estrutura
19132	Serviços baseados em localização -	19144-2	Sistema de classificação. Parte 2:
	padronização		Land Cover Classification System LCCS
19133	Serviços baseados em localização –	19145	Registro de representações de
	tracking e navegação		localização do ponto geográfico

Quadro 2.6: Especificações sobre dados geográficos (ISO 19115, 2003)

A ISO 3166 é o padrão internacional para código de países e suas respectivas subdivisões, sendo importante para a padronização dos Nomes Geográficos.

As palavras norma e especificação têm significados distintos, embora complementares. A norma é um mandato, uma referência descritiva de

cumprimento obrigatório, que diz textualmente "o que fazer". As especificações são complementos das normas ao indicar os aspectos que caracterizam os dados, na forma de parâmetros. Atualmente, a norma ISO² destinada aos dados geográficos está sendo incorporada por diversos países para a criação e implementação de suas Infraestruturas de Dados Espaciais (IDEs), inclusive no Brasil, através da Infraestrutura Nacional de Dados Espaciais (INDE).

Na implementação de normas e especificações, em diversos setores do conhecimento, são utilizados padrões que propiciam a compatibilização e a comparabilidade em nível nacional e, até mesmo, internacional. Por padrão entende-se uma base de comparação, algo que o consenso geral ou um determinado órgão oficial consagrou como um modelo aprovado (HOUAISS, 2001); ou aquilo que serve de base para avaliação de qualidade ou quantidade (HOLANDA, 2004). Os padrões de dados geográficos abrangem, por exemplo, sistemas de projeção, sistemas geodésicos, modelo de dados, metadados, qualidade de dados e transferência de dados.

A Comissão Nacional de Cartografia estabelece que a definição de padrões garante que os dados possuam consistência para a sua incorporação à uma IDE, enquanto que os índices para graduar a qualidade informam o quanto os dados aderem a estes padrões estabelecendo valores mínimos de conformidade. Dessa forma, considerando que novos dados estarão integrados espacialmente e semanticamente na INDE, a primeira expectativa é que todos eles sejam consistentes, tanto no que se refere ao traçado quanto aos atributos relacionados.

Dentre todas essas especificações, vale ressaltar o documento 19113 da ISO, que trata de cinco princípios básicos de qualidade do dado geográfico (ISO 19113, 2003):

- Integridade ou completude: que envolve erros de omissão ou criação errônea de feições, atributos e relacionamentos.
- Consistência lógica: que abrange modelos com regras lógicas de estrutura de dados, atributos e relacionamentos. Esse princípio especifica se o dado está enquadrado em um modelo conceitual e

² Formado por vários comitês de especialistas, divididos em grupos de trabalho, cujo objetivo é desenvolver especificações de controle de qualidade e relatórios de "Prática recomendada". No caso dos dados geográficos, existem as especificações da família 19100.

topológico pré-definido. Ou seja, o objetivo é avaliar se uma feição atende ou não as regras determinadas pelo modelo de dados, como por exemplo, valores fora do domínio, ou relações topológicas não atendidas.

- Exatidão posicional: que envolve o tipo de exatidão alcançada no posicionamento do dado. Abrange os erros absolutos, obtidos através da comparação com valores de referência no terreno, e relativos, sendo avaliados através do desvio padrão para verificar variações da acurácia interna.
- Exatidão temática: relacionada ao tipo de exatidão que ressalta os erros de classificação dos elementos e relacionamentos envolvidos. Dois aspectos são observados: a correção de atributos qualitativos (ex.: feição associada a uma categoria de informação errada) e a exatidão dos valores quantitativos (ex.: avaliação de valores numéricos de uma determinada feição).
- Exatidão temporal: relacionada à medida temporal dos dados. Esse critério de avaliação da qualidade indica o tempo pelo qual o dado é considerado válido. Esse tipo de avaliação é mais usado para dados que apresentam uma maior dinâmica.

Considerando a própria definição da ISO de que o conceito de qualidade se refere ao grau em que um conjunto de características inerentes a um objeto atende aos requisitos, necessidades ou expectativas estabelecidas, geralmente implícitas ou obrigatórias, parte-se da ideia de que um dado geográfico com qualidade satisfatória é aquele que atende aos cinco princípios estabelecidos, considerando-se sua aplicação. Então, neste caso, a qualidade expressa o grau de aderência de um dado a padrões que atendem a um determinado uso.

Além da especificação ISO 19113, outro documento que trata de qualidade do dado é a ISO 19157, que propõe normatizar métodos de avaliação, ou seja, usar um conjunto de medidas que, sendo conhecidas por produtores e usuários da informação geográfica possam facilitar o entendimento e o uso adequando do dado. A proposta desse tipo de normatização é estabelecer uma ou mais medidas que sejam usadas como referência para o conhecimento detalhado sobre as características do dado, em termos posicionais, lógicos, temáticos, temporais e de completude. Em todas

essas avaliações, existem dois propósitos no conhecimento da qualidade do dado: a verificação de erros e a estimativa de incerteza.

A seguir, serão descritos os cinco princípios associados ao controle de qualidade. Vale destacar que dentre eles, três critérios estão relacionados ao termo exatidão: posicional, temática e temporal. Quanto ao uso do termo exatidão, alguns autores o tratam como sinônimo de acurácia (ANDRADE, 2003; RODRÍGUEZ, 2011), ou seja, o grau de concordância entre um resultado teste ou medição à um valor considerado como verdadeiro. Porém, muitas vezes, o termo acurácia é confundido com precisão. Monico *et. Al.* (2009) destacam que enquanto a precisão envolve apenas efeitos aleatórios, o uso do termo acurácia ou exatidão envolve tanto erros aleatórios quanto sistemáticos, ou seja, análises de tendências. Os autores usam exemplos de tiros ao alvo para ilustrar, de forma didática, os conceitos de acurácia e precisão. Na figura 2.13 a média dos resultados advindos do atirador A e B coincide exatamente com o centro do alvo, caracterizando tendência nula. Porém, os tiros do atirador B apresentam menor dispersão, logo o atirador B é mais preciso que o atirador A.



Figura 2.13: Exemplos de precisão e acurácia (Fonte: adaptado de Monico *et Al.*, 2009)

Comparando-se os atiradores C e D nota-se que ambos apresentam nível de precisão semelhante, porém o segundo apresenta uma significativa tendência. Sendo assim, o atirador C é mais acurado do que o atirador D.

Dessa forma, as avaliações de acurácia são importantes para se medir desvios dos valores considerados como referência com valores adquiridos, servindo para analisar parâmetros e atributos de carater posicional, temático e temporal.

Porém, antes de se avaliar a acurácia das feições, a norma ISO 19157 recomenda avaliar outros dois critérios de qualidade do dado: consistência lógica e a completude.

2.4.1 Consistência lógica

O controle de qualidade relacionado à consistência lógica (quadro 2.7) se refere ao grau de aderência às regras conceituais, lógicas e físicas da estrutura dos dados, atributos e relacionamentos. São divididas as regras em cinco sub-elementos:

- Consistência conceitual: corresponde à aderência dos dados às regras do modelo conceitual, ou seja, se os nomes das classes e atributos estão adequados.
- Consistência de domínio: corresponde à aderência dos dados aos valores dos domínios previstos no esquema conceitual.
- Consistência de formato: indica se os dados estão armazenados de acordo com a sua estrutura física e formas de compactação.
- Consistência topológica: indica se os dados possuem características e relações espaciais adequadas.

Nota-se que esse tipo de controle de qualidade está muito associado ao gerenciamento de banco de dados geoespaciais e estrutura de dados vetoriais, não sendo aplicado para avaliação de dados matriciais, com exceção da consistência de formato.

Sub-elemento	Avaliação quanto à consistência lógica	
Consistência conceitual	Número de itens que não cumprem as regras do modelo conceitual	
Consistência de domínio	Número de itens não conformes com seu valor de domínio	
Consistência de formato	Conflito de estrutura física	
Consistência topológica	Número de falhas de conexão ponto-curva	
Consistência topológica	Número de conexões ausentes por undershoots	
Consistência topológica	Número de conexões ausentes por overshoots	
Consistência topológica	Número de polígonos não válidos	
Consistência topológica	Número de erros de auto interseção	
Consistência topológica	Número de erros de auto superposição	

Quadro 2.7: Critérios de avaliação da consistência lógica. (ISO 19113, 2003).

No Brasil, os primeiros esforços de estruturação dos dados vetoriais topográficos surgiram na década de 1990 com as versões da Mapoteca Topográfica Digital (MTD), documento adotado pelo IBGE, e da Tabela da Base Cartográfica Digital (TBCD), especificação adotada pela Diretoria de Serviço Geográfico do Exército (DSG). Até alguns anos atrás, cada um desses órgãos de mapeamento passou a fazer uso de sua própria estrutura de dados, as quais diferenciam em vários aspectos. Em consequência, as bases cartográficas geradas pela DSG e pelo IBGE, nesse período, encontravam-se em estruturas diferentes, exigindo a conversão dos modelos de dados quando utilizadas em conjunto.

Porém existiam grandes dificuldades de compatibilização para um padrão único de estrutura de dados cartográficos, uma vez que as duas especificações refletiam as diferenças de concepção que tinham a DSG e o IBGE, em função das aplicações destas organizações. Isso resultou em diferentes categorias de informação, semânticas distintas para algumas categorias, feições ou elementos de feições, além de diferentes quantidades de atributos por feição.

No final de 2004, o Ministério do Meio Ambiente (MMA) necessitando da base cartográfica digital da área da Amazônia Legal, na escala de 1:100.000, para uso em SIG, manteve contato com a Comissão Nacional de Cartografia (CONCAR), com vistas à realização de auditoria técnica em bases digitais elaboradas por empresas privadas, conversão e atualização, de base nas cartas topográficas editadas pela DSG e pelo IBGE, para verificar a adequação das mesmas ao Sistema Cartográfico Nacional.

Com este objetivo, surgiu a proposta de convênio do Ministério do Meio Ambiente, com a DSG e com o IBGE, para obtenção das bases cartográficas da Amazônia Legal em área contínua e em um mesmo padrão de estrutura de dados. Tais requisitos não poderiam ser atendidos, naquele momento, conforme explicado anteriormente, pela inexistência de um padrão único de estrutura de dados espaciais vetoriais.

Contando com o apoio financeiro do MMA, no ano de 2005, os integrantes da DSG e do IBGE iniciaram os esforços para criar um padrão único e, consequentemente, o estabelecimento da Mapoteca Nacional Digital (MND). Integrando a componente de dados da INDE brasileira, a denominada Mapoteca Nacional Digital é entendida como o conjunto de dados geoespaciais vetoriais e matriciais, devidamente estruturados conforme norma em vigor, e os seus metadados, armazenados em repositórios distribuídos e compartilhados, referentes ao espaço geográfico brasileiro (CONCAR, 2007). A estrutura para a Mapoteca Nacional Digital (MND) é subdividida em três partes: estrutura de dados vetoriais, estrutura de metadados e a estrutura de dados matriciais.

Em 2006, a Comissão Nacional de Cartografia apresentou a Especificação Técnica para a Estruturação de Dados Geoespaciais Vetoriais (ET-EDGV), iniciativa para padronizar as classes de mapeamento da produção cartográfica de referência no Brasil (CONCAR, 2007). A EDGV corresponde a um modelo de estrutura de dados que contempla categorias de informação com suas respectivas feições associadas. O quadro 2.8 ilustra as categorias de informação contempladas.

Cada classe pode ser representada espacialmente através de quatro estruturas geométricas: ponto, linha, polígono e complexo, esse último ocorrendo quando uma feição é representada por uma mais de uma primitiva geométrica. Um exemplo desse tipo de ocorrência é o complexo aeroportuário, cuja pista de pouso é representada por linha, e as edificações podem ser representadas por ponto ou polígono, dependendo da escala cartográfica.

Além de estabelecer as classes de informação e seus diferentes traçados, a ET-EDVG estabelece, também, diferentes regras topológicas entre elas, associadas a questões de vizinhança, conectividade e proximidade. Estes relacionamentos descrevem como um objeto se posiciona em relação aos outros e são evidenciados através de consultas a banco de dados, inerentes aos componentes gráficos. As consultas podem se limitar a um fenômeno específico ou a relacionamentos espaço-temporais entre fenômenos geográficos distintos. A figura 2.14 mostra um modelo para a categoria Hidrografia com suas respectivas feições e relacionamentos topológicos.

Além disso, a ET-EDGV define as listas de domínios para diversos atributos das classes. A importância do domínio está em especificar os valores permitidos ou o uso de texto livre. O uso do "Texto livre" indica que não existem restrições sobre o conteúdo do campo. Para os casos de atributos com domínios, existe uma *code list*, que define os valores possíveis. No caso de alguns atributos contemplados na ET-EDGV, existe, por exemplo, o termo "desconhecido", que significa "não identificado" ou "sem informação". Esse procedimento serve para evitar valores vazios nos registros das tabelas.

Quadro 2.8: Categorias de informação da EDGV. (CONCAR, 2010)

Hidrografia	Categoria que representa o conjunto das águas interiores e oceânicas da superfície terrestre, bem como elementos, naturais ou artificiais, emersos ou submersos, contidos nesse ambiente.
Relevo	Categoria que representa a forma da superfície da Terra e do fundo das águas tratando, também, os materiais expostos, com exceção da cobertura vegetal.
Vegetação	Categoria que representa, em caráter geral, os diversos tipos de vegetação natural e cultivada.
Sistema de Transporte	Categoria que agrupa o conjunto de sistemas destinados ao transporte e deslocamento de carga e passageiros, bem como as estruturas de suporte ligadas a estas atividades.
Energia e Comunicações	Categoria que representa as estruturas associadas à geração, transmissão e distribuição de energia, bem como as de comunicação.
Abastecimento de Água e Saneamento Básico	Categoria que agrupa o conjunto de estruturas associadas à captação, ao armazenamento, ao tratamento e à distribuição de água, bem como as relativas ao saneamento básico.
Educação e Cultura	Categoria que representa as áreas e as edificações associadas à educação e ao esporte, à cultura e ao lazer.
Estrutura Econômica	Categoria que representa as áreas e as edificações onde são realizadas atividades para produção de bens e serviços que, em geral, apresentam resultado econômico.
Localidades	Categoria que representa os diversos tipos de concentração de habitações humanas.
Pontos de Referência	Categoria que agrupa as classes de elementos que servem como referência a medições em relação a superfície da Terra ou de fenômenos naturais.
Limites	Categoria que representa os distintos níveis político- administrativos e as áreas especiais; áreas de planejamento operacional, áreas particulares (não classificadas nas demais categorias), bem como os elementos que delimitam materialmente estas linhas no terreno.
Administração Pública	Categoria que representa as áreas e as edificações onde são realizadas as atividades inerentes ao poder público.





Figura 2.14: Feições da categoria Hidrografia da EDGV. (CONCAR, 2010)

2.4.2 Completude

Completude pode ser definida como um indicador que sinaliza a integridade do dado, de forma a identificar se existem elementos que excedem ou são ausentes do padrão estabelecido. Dessa forma, existem duas principais formas de avaliar a completude de um dado: por comissão ou omissão. Esse indicador pode servir tanto para dados vetoriais, quanto para dados matriciais. Uma imagem de satélite, por exemplo, pode apresentar cobertura de nuvens e sombras que prejudicam a visualização completa da superfície.

Um exemplo de avaliação por omissão de dado envolvendo a verificação de erros seria a análise de feições ausentes. Por alguma razão, por exemplo, um intérprete pode ignorar a presença de uma rodovia em uma imagem e não extraí-la. Isso pode acontecer pelas limitações cognitivas do intéterprete, pela desatenção, porque na imagem a presença da rodovia não está nítida ou pela presença de nuvens.

Em relação aos erros de comissão, existem os problemas decorrentes de elementos excededentes ou duplicados. Os elementos duplicados são feições com os mesmos atributos e localizados na mesma posição. Os elementos excedentes ocorrem, principalmente, quando um elemento fora das especificações é inserido no conjunto de dados. Por exemplo, se existe uma regra para incluir apenas edificações maiores que 50 m², e são incluídas feições menores que esse valor, todos esses elementos são considerados excedentes. O quadro 2.9 mostra os critérios de avaliação da completude do dado.

Sub-elemento	Avaliação quanto à completude
Comissão	Número de itens excedentes
Comissão	Número de instâncias duplicadas
Omissão	Número de itens ausentes

Quadro 2.9: Critérios de avaliação da completude. (ISO 19113, 2003).

Quando se avalia erros de comissão ou omissão, é estabelecido um valor de referência, considerado como verdade, que pode ser obtido através de documentos cartográficos ou levantamentos de campo. A tabela 2.1 mostra um exemplo de completude por classe de feição. Ao se estabelecer um valor de referência para cada classe, e relacionando com o número de itens excedentes e ausentes, pode-se obter uma taxa que indica o porcentual de elementos

criados a mais ou a menos. Com o cálculo desses percentuais, cada instituição que produz e avalia a qualidade de seus dados pode estabelecer critérios para o atendimento satisfatório ou não.

No Brasil, a Diretoria de Serviço Geográfico, vinculada ao Exército, está estabelecendo a Especificação Técnica de Controle de Qualidade de Produtos de Conjunto de Dados Geoespaciais (ET- CQPCDG) com a finalidade de definir os procedimentos de controle de qualidade dos produtos da Cartografia Terrestre previstos na INDE, no qual a questão da completude será abordada com critério de avaliação de qualidade. Essa documentação ainda está em fase de elaboração, mas de qualquer forma, é possível encontrar outros documentos do Exército que tratam dos erros de completude. Um desses documentos é a Especificação Técnica de Produtos de Conjuntos de Dados Geoespaciais (ET-PCDG), que regulamenta e padroniza os produtos e dados geoespaciais do Espaço Geográfico Brasileiro. Para ortofotocarta e carta imagem, por exemplo, a completude é considerada um critério de qualidade, observando-se os seguintes itens: presença de nuvens e sombras; e omissão de elementos importantes relativos ao sistema de transporte, hidrografia, relevo e localidade. Ou seja, caso o produto não atenda a esses itens, ele não é considerado um dado oficial de referência.

Classe de feição	Valor de referência	Itens excedentes	Proporção de itens excedentes	Itens ausentes	Proporção de itens ausentes
Caminho	7	1	14 %	3	43 %
Estrada	5	2	40 %	0	0 %
Árvores	25	3	12 %	2	8 %
Construção industrial	4	0	0 %	2	50 %
Construção habitacional	10	1	10 %	1	10%

Tabela 2.1: Completude por classe de feição conforme ISO 19113 (2003).

2.4.3 Exatidão posicional

Segundo Vieira *et al.* (2004), a exatidão posicional determina o quão perto a posição dos objetos discretos mostrados em um mapa, imagem retificada ou em um banco de dados espacial está de acordo com a situação real no terreno.

Um método padrão para avaliação da exatidão de posicionamento de produtos cartográficos é baseado na comparação de desvios entre os pontos

de controle homólogos, localizados em mapeamentos de referência, imagens corrigidas geometricamente e levantamentos de GNSS. Os desvios desses pontos são usados em modelos estatísticos que permitem mensurar a estimativa da incerteza, possibilitar o cálculo de erros e analisar tendências, sendo nesse caso identificar a presença de erros sistemáticos (MERCHAND,1982).

O quadro 2.10 mostra os critérios de avaliação da exatidão posicional e as formas de medida propostas na norma ISO, que incluem avaliações de erros e estimativas de incertezas, sendo alguns obrigatórios e outros opcionais.

Tipo de Exatidão	Critério de avaliação	Medida básica
Absoluta	Valor médio de incerteza posicional (1D, 2D, 3D)	Não aplicável
Absoluta	Absoluta Valor médio de incerteza posicional, excluindo outliers (2D)	
Absoluta	Número de incertezas posicionais sobre uma tolerância	Contador de erros
Absoluta	Matriz de covariância	Não aplicável
Absoluta	Erro linear provável	LEP50.0 ou LE50.0(r)
Absoluta	Erro linear padrão	LE68.3 ou LE68.3(r)
Absoluta	Exatidão linear à 90% de significado	LE90 ou LE90(r)
Absoluta	Exatidão linear à 95% de significado	LE95 ou LE95(r)
Absoluta	Exatidão linear à 99% de significado	LE99 ou LE99(r)
Absoluta	Erro linear quase certo	LE99.8 ou LE99.8(r)
Absoluta	Raiz do erro quadrático médio	Não aplicável
Absoluta	Erro absoluto linear à 90% de significado de dados verticais tendenciosa	Não aplicável
Absoluta	Movimento do desvio Padrão	CE39.4
Absoluta	Erro circular provável	CE50
Absoluta	Erro circular padrão com 90% de significado	CE90
Absoluta	Erro circular com 95% de significado	CE95
Absoluta	Erro circular quase certo	CE99.8
Absoluta	Raiz do erro quadrático médio planimétrico	Não aplicável
Absoluta	Erro absoluto circular à 90% significado de dados tendenciosos	Não aplicável
Absoluta	Elipse de incerteza	Não aplicável
Absoluta	Elipse de confiança	Não aplicável
Relativa	Erro vertical relativo	Não aplicável
Relativa	Erro horizontal relativo	Não aplicável

Quadro 2.10: Critérios de avaliação da exatidão posicional (ISO 19113, 2003).

No Brasil, em termos de padronização na avaliação da qualidade geométrica de produtos cartográficos, oficialmente é adotado o Decreto nº 89817, de 20 de junho de 1984, que estabelece o Padrão de Exatidão Cartográfica (PEC). Porém, com a mudanca para o paradigma digital, há a necessidade de rever os critérios estabelecidos pelo PEC. Atualmente, observam-se esforços de revisão deste padrão para dados geoespaciais digitais, como bases cartográficas, modelos digitais de elevação, de superfície e do terreno. O documento revisto é denominado de Padrão de Acurácia e Precisão para Produtos Cartográficos Digitais (PAP-PCD), utilizado atualmente pela Diretoria de Serviço Geográfico do Exército. Porém, outras instituições produtoras de dados cartográficos de referência, como o IBGE, ainda utiliza o PEC com padrão para avaliação da exatidão cartográfica. A tabela 2.2 mostra os valores de precisão e acurácia da planimetria dos produtos cartográficos, segundo o PEC e o PAP-PCD. Ambas são baseadas na acurácia posicional absoluta como referência na avaliação da exatidão de um produto cartográfico, sendo o desvio padrão um de seus componentes. Basicamente, a diferença entre elas está no fato da classe A do PEC corresponder à classe B da norma revisada, e assim sucessivamente para as demais classes. Dessa forma, foi criada uma nova classe, denominada de A, cujos valores de erro médio e desvio padrão representam a metade dos valores anteriores.

		1:25	5.000	1:50.000		1:100.000		1:250.000	
PEC	PAP- PCD	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)
	Α	7	4,25	14	8,51	28	17,02	70	42,55
Α	В	12,5	7,5	25	15	50	30	125	75
В	С	20	12,5	40	25	80	50	200	125
С	D	25	15	50	30	100	60	250	150

Tabela 2.2: Precisão (EP) e acurácia (PEC) da Planimetria do Produto Cartográfico (CONCAR, 2010)

Vale destacar que esses valores estão associados a qualquer produto cartográfico digital, podendo ser bases cartográficas vetoriais ou dados matriciais. Porém, no caso de imagens aéreas ou orbitais usadas como insumos na produção cartográfica, são esperados valores menores, uma vez que o processo de restituição e extração de feições cartográficas existem os erros espaciais associados. Nas normas brasileiras, não existe nenhuma específicação própria que trata da exatidão posicional para produtos para esses tipos de imagens. De qualquer forma, houve avanços no PAP-PCD, uma vez que já foram estabelecidos valores de exatidão posicional para modelos digitais de elevação, de terreno e superfície.

O trabalho entitulado *Spatial Accuracy Standars for Large Scale Line Maps*, Merchand (1982) serve como referência para diversos estudos sobre exatidão posicional, inclusive no PAP-PCD, tendo em vista que contribuiu para os procedimentos metodológicos empregados. Galo e Camargo (1994) abordam a mesma inferência estatística de Merchand, aplicando a sua metodologia aos critérios de precisão estabelecidos no PEC.

Vieira & Genro (2011) descrevem uma metodologia que possibilita classificar os produtos cartográficos de acordo com seu nível de exatidão posicional. Para isso, os autores fazem uma reflexão sobre as características dos dados amostrados, em termos de dimensionamento e à espacialização, além de detalhar técnicas de inferência estatísticas. Para os autores, para se garantir uma análise completa de acurácia é necessária uma avaliação da distribuição *t-Student*, destinada à verificação da ausência de tendência, e a distribuição Qui-Quadrado, destinada à verificação da validade do Erro-Padrão.

2.4.4 Exatidão temática

Quando se usa a expressão "temática", inicialmente se pensa em mapeamentos específicos com ênfase em um determinado tema, como por exemplo os mapas de cobertura vegetal, geomorfologia ou geologia. Dificilmente é utilizado o termo temático quando se trata de cartografia de referência. Porém, ao se identificar as classes do mapeamento topográfico, pode-se associar a vários temas relacionados à hidrografia, sistema de transporte, relevo, dentre outros. Reforçando essa ideia, nota-se que as categorias de informação e suas respectivas classses especificadas na ET-EDGV não são separadas de acordo com o dado, seja temático ou de referência. Evidentemente, as instuições normatizadoras dos mapeamentos de referência é que selecionam o que é fundamental em suas especificações, mas a referência é única. Desta forma, as feições cartográficas do mapeamento de

referência também podem ser tratadas como temas a serem mapeados em diferentes escalas.

Sendo assim, a exatidão temática se refere à acurácia de atributos quantitativos e qualitativos dos dados geoespaciais, ou seja, se as classificações dos objetos representados no mapeamento são verdadeiras ou estão próximas do que se considera como verdadeiro.

Segundo a norma ISO 19113, a exatidão temática pode ser dividida nos seguintes elementos (quadro 2.11):

- Correção de classificação: refere-se aos erros envolvidos durante o processo de classificação através da comparação entre feições.
- Correção de atributo qualitativo: define-se se determinados atributos foram classificados de forma correta ou incorreta.
- Exatidão de atributo quantitativo: refere-se a verificar os valores de incerteza envolvidos na acurácia de valores numéricos.

Nome	Subelemento	Medida básica
Número de elementos classificados		
incorretamente	Correção de classificação	Contador de erros
Matriz de confusão	Correção de classificação	Não aplicável
Exatidão global	Correção de classificação	Não aplicável
Coeficiente Kappa	Correção de classificação	Não aplicável
Quantidade de atributos incorretos	Correção dos atributos qualitativos	Contador de erros
Grau de incerteza		
valor atributo à 68.3% de significado	Exatidão de atributos quantitativos	LE68.3
Grau de incerteza		
valor atributo a 50% de significado	Exatidad de atributos quantitativos	LE50
valor atributo à 90% de significado	Exatidão de atributos quantitativos	LE90
Grau de incerteza		
valor atributo à 99% de significado	Exatidão de atributos quantitativos	LE99
Grau de incerteza		
valor atributo à 99.8% de significado	Exatidão de atributos quantitativos	LE99.8

Quadro 2.11: Critérios de avaliação da exatidão temática (ISO 19113, 2003).

O Número de elementos classificados incorretamente constitui apenas uma contagem simples do número de feições que não foram classificadas adequadamente. A partir do total de elementos é possível, então, quantificar o número de elementos classificados corretamente. Em termos de correção de classificação do dado, a forma de avaliação da acurácia temática mais comum é a matriz de confusão, elaborada com o objetivo de confrontar as classes do mapeamento gerado com dados de referência.

A matriz de confusão é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma categoria particular relativa, inferida por um classificador ou regra de decisão, e comparada com a categoria atual verificada no campo (CONGALTON & GREEN, 2009). Normalmente abaixo das colunas representase o conjunto de dados de referência que é comparado com os dados do produto da classificação que são representados ao longo das linhas. Os elementos da diagonal principal, em negrito, indicam o nível de acerto, ou concordância, entre os dois conjuntos de dados. A tabela 2.3 mostra a representação de uma matriz de confusão.

	Dado	s de referêr	Total nas linhas ni +	
Classificação	1	2	3	
1	X ₁₁	X ₁₂	X _{1c}	X ₁₊
2	X ₁₁	X ₂₂	X _{2c}	X ₂₊
С	X ₃₁	X ₃₂	X ₃₃	X _{c+}
Total nas colunas n+ i	X ₊₁	X ₊₂	X +c	n

Tabela 2.3: Representação de uma matriz de confusão (ISO 19113, 2003).

A matriz possibilita a extração da exatidão por classe e da exatidão global, além da determinação dos erros de omissão (subestimação) e comissão (superestimação) e acabou se tornando o método padrão para avaliação da precisão temática atualmente. A matriz de confusão fornece a base para descrever a precisão da classificação e caracterizar os erros, ajudando a refinar a classificação. De uma matriz de confusão podem ser derivadas várias medidas de precisão da classificação, sendo a exatidão global e o índice Kappa algumas das mais conhecidas (FOODY, 1992).

Congalton & Green (2009) relata que o uso do índice Kappa é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo,

que utiliza somente os elementos diagonais (concordância real). O Coeficiente Global e o índice Kappa são muito usados na avaliação de dados temáticos. Como não existe uma padronização oficial no Brasil, pode-se considerar essas práticas as mais utilizadas nos estudos de mapeamento. No capítulo 5 serão apresentados mais alguns detalhes desses índices, que servirão para construir o índice de interpretabilidade.

Além desses indicadores também a possibilidade de usar o índice Tau, proposto por Ma e Redmond (1995), cujo objetivo seria corrigir algumas possíveis deficiências no índice Kappa. Foody (1992) aponta por exemplo, que o grau de concordância por chance poderia estar sendo superestimado, pelo fato de incluir também a concordância real, ou seja, leva em consideração duas vezes o total de acertos. Figueiredo & Vieira (2007) estudaram o comportamento desses três índices e encontraram valores muito semelhantes para o índice Kappa e Tau.

As classes de mapeamento podem apresentar atributos que a descrevam de forma qualitativa e quantitativa, por isso, é necessário identificar os possíveis erros e incertezas envolvidas em seus atributos. Em termos qualitativos, a tarefa é mais simples, tendo em vista apenas a correção de sua classificação em termos booleanos, ou seja, a classificação está correta ou não.

Em termos de exatidão de atributos quantitativos, para se avaliar os atributos numéricos das classes, são usados modelos estatísticos com distintas estimativas de incerteza, baseadas em diferentes níveis de confiança. Ou sejam ao redor do valor de Kappa podem ser calculados intervalos de confiança usando a variância da amostra e o fato de que a distribuição estatística do Kappa é normalmente assintótica. Congalton e Green (2009) sugerem meios de testar a significação estatística do Kappa para uma única matriz de confusão, através da variância, a fim de determinar se o nível de acerto da classificação e os dados de referência são significativamente maior que zero.

2.4.5 Exatidão temporal

O objetivo da avaliação da exatidão temporal é especificar a acurácia da medida de tempo, a consistência temporal e a validade temporal (quadro 2.12).

69

A acurácia da medida de tempo diz respeito à exatidão do tempo medido em relação à uma referência de tempo estabelecida como verdadeira.

A consistência temporal indica se um determinado dado está ordenado cronologicamente de forma adequada em relação à outros dados. Por exemplo, o usuário possui um conjunto de imagens de anos diferentes. Para a sua análise, é importante estabelecer uma ordem temporal ajustada para o acompanhamento de seu trabalho.

A validade temporal está associada ao limite de tempo estabelecido para um determinado dado. Após esse prazo, o dado não possui qualidade suficiente para ser utilizado de acordo com uma determinada aplicação.

Em termos de produção cartográfica, a questão que envolve a validade temporal está relacionada com o problema da desatualização cartográfica. No mapeamento topográfico é possível encontrar feições com "prazos de validade" diferenciados. É de se esperar que feições relacionadas à estruturas urbanas, industriais e agrárias possuem mudanças mais dinâmicas quando comparadas com feições de hipsografia, por exemplo. Talvez seja difícil estabelecer uma "data de validade" para os dados cartográficos, tendo que vista que uma determinada informação pode ser atualizada para um usuário, mas não ser adequada para a finalidade de outro usuário. De qualquer forma, é necessário que os órgãos produtores estabeleçam programas de atualização para as feições presentes do mapeamento, descrevendo no metadado do produto, como uma folha topográfica, por exemplo, a data que determinada feição foi atualizada.

Nome	Subelemento	Medida básica
Exatidão temporal à 68.3% de significado	Acurácia da medida de tempo	LE68.3
Exatidão temporal à 50% de significado	Acurácia da medida de tempo	LE50
Exatidão temporal à 90% de significado	Acurácia da medida de tempo	LE90
Exatidão temporal à 99% de significado	Acurácia da medida de tempo	LE99
Exatidão temporal à 99.8% de significado	Acurácia da medida de tempo	LE99.8
Erro cronológico	Consistência temporal	Não aplicável
Número de itens não conformes	Validade temporal	Não aplicável

Quadro 2.12: Critérios de avaliação da exatidão temporal. (ISO 19113, 2003).

3. INTERPRETABILIDADE

A proposta desse estudo é iniciar as discussões sobre a interpretação em imagens para fins cartográficos, mais precisamente na avaliação da qualidade de extração de feições. Por isso, serão destacados exemplos de aplicações voltadas para mapeamentos de referência, como a elaboração de cartas topográficas.

As aplicações envolvem, para fins de interpretação, o uso de legendas ou modelos de estruturas de dados, que auxiliem nos critérios para a extração de feições e classificações. No caso do mapeamento de referência, existem modelos de dados, a ET-EDGV, que aponta os elementos que devem ser interpretados, divididos em categorias de informação. A própria ET-EDGV é um avanço na questão de padronização de modelos de dados, uma vez que o processo facilita o intercâmbio de dados geográficos. Talvez, em algumas áreas temáticas, há a necessidade de estudos direcionados para a padronização, como no caso dos Mapas de Uso e Cobertura do Solo. Será visto mais adiante, o trabalho norte-americano nessa área de padronização, além de ser citado na tabela 1 uma especificação ISO que aborda um sistema de classificação da Terra denominado *Classification System. Land Cover Classification System (LCCS).*

Porém, também é necessário aprofundar as discussões de uma possível padronização sobre interpretação em Imagens, baseado no conceito de Interpretabilidade.

Na literatura específica de sensoriamento remoto, o termo Interpretabilidade não é muito difundido. A primeira vez que o termo é usado está na publicação de Draeger (1967), cujo enfoque é destacar o uso de imagens para a gestão de recursos florestais. Durante as décadas de 1970 e 1980, o Departamento de Defesa Americano já adotava critérios de interpretação para classificar diferentes sensores, a fim de detectar, distinguir e identificar alvos que fossem de interesse para a segurança americana.

A partir da década de 1990, com o uso mais disseminado de imagens pela comunidade civil, aparecem os primeiros trabalhos que abordam o conceito de Interpretabilidade (Greer & Caylor, 1992; Mayer *et al.*, 1995; Leachtenauer *et al.*, 1996; *Hothem et al.*, 1996). Nesses estudos, o conceito de

1

71

interpretabilidade está associado à um potencial de uso das imagens, cujos conteúdos apresentam informações com qualidades e escalas¹ distintas. Na verdade, o conceito de Interpretabilidade, herdado das aplicações militares, é definido como:

"Adequação de uma imagem para finalidade de interpretação, de forma que o seu conteúdo responda à critérios de reconhecimento do alvo". (IRVINE, 1997)

Atualmente, muitos autores (Kim *et al.* 2012; Stefanou &. Kerekes, 2009), usam os termos "*image utility*" ou "*image quality*" para expressar o grau de interpretação de uma determinada imagem. O uso desses termos acaba destacando o potencial de interpretação. Mas, independente do termo usado, o que se observa é que a maioria dos trabalhos destacam dois aspectos importantes nas tarefas fundamentais para se estabelecer a interpretabilidade em imagens: detectar e identificar.

3.1 DETECÇÃO E IDENTIFICAÇÃO

O primeiro conceito está associado à capacidade de encontrar a presença de um objeto ou elemento de interesse, baseado em seu contorno geral e/ou outra informação contextual da cena. Já o processo de identificação envolve a capacidade de nomear ou qualificar um objeto por tipo ou classe, com base na sua configuração, principalmente na observação dos detalhes de seus componentes. (SCHOTT, 2007). Sendo assim, a detecção implica na construção do traçado de um objeto a partir do uso de imagens, cuja forma de representação se estabelece a partir de superfície contínua. Já a identificação se caracteriza na diferenciação dos objetos detectados a partir da classificação. Essas duas abordagens são importantes para definir o grau de interpretação de uma imagem. Pode-se, por exemplo, usar imagens TM\LANDSAT para o processo de detecção de rodovias, mas não será possível identifica-la em termos de número de faixas, uma vez que sua resolução não permite esse tipo de interpretação. Para atingir a fase de identificação usando esse tipo de sensor, é necessário usar dados auxiliares, como uma base cartográfica mais detalhada ou levantamento de campo. Porém, se o usuário deseja identificar o

¹ O conceito de escala de de interpretabilidade não está associado à escala cartográfica. Refere-se apenas a forma de graduar valores.

número de faixas de uma rodovia apenas usando uma imagem,, será necessário utilizar imagens com melhor resolução espacial.

De uma forma geral, pode-se pensar que apenas a resolução espacial seja suficiente para determinar o grau de interpretação. Segundo Jensen (2009), a comunidade de usuários civis normalmente relata a utilização de um determinado tipo de imagem para a extração de informação com base na resolução espacial nominal, também chamada de resolução em distância no solo. Para o autor, é necessário um mínimo de quatro observações (pixels) sobre um mesmo objeto urbano para conseguir identificá-lo. Dito de outra forma, a resolução espacial do sensor deve ser metade da largura do menor objeto de interesse. Por exemplo, para a identificação de *trailers* com 5 metros de largura, a resolução espacial mínima da imagem, sem bruma atmosférica ou outros problemas, teria de ser aproximadamente 2,5 x 2,5 metros.

Talvez a resolução espacial seja a mais influente no momento de se interpretar uma imagem. Porém, muitos elementos podem ser detectados ou qualificados explorando-se as variações das bandas espectrais específicas de cada sensor. Cabe ao intérprete saber escolher as bandas espectrais mais adequadas para se extrair os objetos de interesse.

Além da questão da resolução espacial e espectral, a característica radiométrica também será importante no processo de extração dos elementos de uma imagem. Nesse caso, a análise visual não aproveita os recursos da variedade de sensores, sejam com 8 bits ou 12 bits. Isso porque a visão humana não possui a capacidade de perceber variações mínimas dos tons de cinza. Por outro lado, as técnicas computacionais de classificação e extração de informações conseguem utilizar os recursos radiométricos de uma imagem de uma forma mais eficaz. Processos de classificação supervisionada, não supervisionada ou híbrida dependem de forma significativa do atributo numérico armazenado em cada pixel para a obtenção de resultados satisfatórios.

Nos capítulos seguintes é realizada uma descrição que propõe a construção de um índice de interpretabilidade que considere duas premissas fundamentais. A primeira é a possibilidade de avaliação da delimitação do objeto através do índice de detecção, incluindo etapas que envolvem desde o seu processo de criação durante a segmentação, até a análise do traçado de

suas formas e seu posicionamento adequado à escala cartográfica. A segunda premissa se baseia na avaliação da identificação correta dos objetos, de forma a apontar objetos ausentes, denominados erros de omissão, ou identificados de forma errada, erros de comissão. Os erros de comissão estão associados à problemas de identificação, já que mostram os elementos classificados de forma indevida. Já os erros de omissão podem estar associados à problemas de detecção, quando não é possível delimitar na imagem, ou na identificação, tendo em vista que um elemento omisso pode estar presente em outra classe, o que geraria também um erro de comissão. Dessa forma, propõe-se a geração dos indicadores de detecção e identificação, cujo propósito é estabelecer uma forma mensurável de avaliar a qualidade da interpretabilidade.

3.2 INTERPRETAÇÃO e INTERPRETABILIDADE

Todas as especificações que tratam do controle de Qualidade (19113, 19114 e 19138) estão sendo revisadas pelo Comitê Técnico da ISO. O objetivo é contemplar em um único documento (19157) todas as informações referentes à qualidade de dados geográficos.

Uma das novidades do novo documento é a inserção do conceito de Usabilidade². Segundo a especificação proposta, o termo usabilidade pode ser entendido como "*uma informação específica da qualidade de um dado, que indica a sua adequação para uma determinada aplicação*".

O objetivo do termo usabilidade é permitir ao usuário, seja especialista ou leigo, entender de forma clara a utilidade do dado, considerando os cinco princípios básicos de qualidade, geralmente mensurados e analisados por especialistas (INSPIRE, 2010). A usabilidade passa a ser mais um critério de qualidade, de forma a considerar todos os critérios anteriores e definir as aplicações possíveis.

Considerando a importância das imagens obtidas através do sensoriamento remoto para a elaboração de mapeamentos, através de suas diferentes características espaciais, radiométricas e espectrais, serão descritos,

² Esse conceito foi inicialmente proposto através da especificação 19115-2, que trata de metadados para dados matriciais (sensoriamento remoto), elaborado no ano de 2009.

no próximo capítulo, detalhes sobre o conceito de interpretabilidade em imagens e a sua contribuição no que se refere ao uso das imagens.

Analistas de imagens geralmente baseiam-se no comportamento espectral dos diferentes objetos presentes, definidos a partir da assinatura espectral dos alvos, seja através de uma análise visual ou no uso de algoritmos de classificação automática.

Trabalhando-se com análise visual ou automatizada, o fato é que o processo de interpretação de uma imagem não é uma tarefa fechada. Isto é, não se sabe de antemão, quais elementos e padrões irão aparecer. Diversos elementos naturais ou artificiais podem apresentar características espectrais diferentes entre si de acordo com a sua localização, declividade ou sombreamento por exemplo.

Por isso, além dos tons de cinza e da cor, considerados como elementos de interpretação básicos, outros parâmetros mais complexos são necessários. Para Jensen (2009) as próprias tonalidades de cinza e a combinação de cores possuem fatores geométricos específicos, como o tamanho, forma, textura, altura e padrão, correspondendo a elementos de interpretação mais complexos do que a análise de tons de cinza e cor. A combinação desses elementos possbilita a criação de chaves de identificação de diferentes objetos presentes na imagem, comforme mostra o quadro 3.1.

Chaves de interpretação	Complexidade
Cor	Baixa
Localização	
Tamanho e forma	
Textura	
Padrão e sombra	Moderada
Profundidade e volume	
Declividade e aspecto	
Situação e associação	alta
Dados colaterais	Muito alta
Análises temporais e de escala	

Quadro 3.1: Chaves de Interpretação.

75

Novo (2010) cita um exemplo dessa estrutura desenvolvida para interpretar floresta, corpos d'água e plantas aguáticas em uma composição multitemporal de imagens do satélite RADARSAT, conforme mostra o quadro 3.2.

	Classe		
Chave	Floresta	Água	Plantas
			Aquáticas
Tom			Amarelo
Cor	Rosa	Azul escuro	Verde
Cor			Marrom
Textura	Rugosa	Lisa	Lisa
Padrão	Dissecado	Dentrítico	Dentrítico
Localização -		-	Junto aos vales
Forma	Irregular	Linear	Linear
Sombra	Perpendicular a fonte	-	-
Tamanho	-	-	Grandes bancos

Quadro 3.2: Chave de interpretação desenvolvida para imagens Radarsat	
Fonte: adaptado de Novo, 2010	

Ocasionalmente, apenas essas chaves de interpretação podem não ser suficientes para detecção e identicação de feições. Para uma extração ou classificação mais eficiente pode ser necessário associar parâmetros topográficos, de localização, organização e relacionamento entre os objetos entre si na imagem. Nesse nível, incluem-se o sítio, a situação e a associação, considerados elementos de interpretação de ordem superior, ou seja, apresentam um caráter mais complexo em relação aos elementos de interpretação anteriores. Quando se realiza uma classificação de cobertura vegetal, por exemplo, é de se esperar que os manguezais estejam em áreas próximas ao litoral, e presentes em áreas com topografia plana.

Essa necessidade de integrar e relacionar numerosos e diferentes tipos de dados (vetoriais, índices de vegetação, modelos digitais, imagens com múltiplas resoluções), leva os usuários a possuírem um maior interesse em

métodos estatísticos baseados em algortimos não-paramétricos, como as aplicações baseados em redes neurais, cuja abordagem possibilita uma grande capacidade de lidar com as incertezas.

De qualquer forma, o uso de algoritmos paramétricos ainda são bastante disseminados na literatura. Alguns exemplos são as aplicações baseadas no algoritmo máxima verossimilhança. Nessa abordagem, se a hipótese assumida de uma distribuição normal para cada classe da área de treinamento está correta, então a classificação tem uma probabilidade mínima de erro e o algoritmo é uma escolha acertada (SCHOWENGERDT, 1997).

Com o crescente volume de imagens e a preocupação na obtenção de melhores resultados em termos estatísticos, a ênfase tem sido no desenvolvimento de recursos de extração automatizada. No entanto, o uso de reconhecimento de padrões e de técnicas de processamento automático de imagem continua a ser insuficiente para algumas aplicações, nas quais a visão humana é imprescidível, principalmente nos casos nos quais estimativas de área são imprecisas e são necessários julgamentos sobre as propriedades do objeto na imagem.

O aspecto negativo da análise visual é o tempo ainda gasto para o processo de extração de feições, além do fato de diferentes intérpretes apresentarem capacidades distintas de interpretação, em virtude de sua capacitação e experiência profissional.

Além disso, as próprias limitações do sensor podem impossibilitar a interpretação satisfatória das imagens. Mas como identificar as características de um sensor ideal para atender a determinadas aplicações? Como definir o melhor sensor que atenda a uma determinada escala cartográfica, em termos geométricos e de interpretação? As imagens de um sensor podem atender as exigências de exatidão posicional, mas não serem adequadas à extração de feições que confira exatidão temática ao mapa.

O uso do sensoriamento remoto orbital para aplicações cartográficas tem aumentado nos últimos anos (CRUZ & BARROS, 2012). Os dados obtidos por sensores orbitais vêm contribuindo para a elaboração de bases cartográficas de referência, além de servir como uma ferramenta tecnológica para diversas aplicações temáticas, tais como os estudos de vegetação, qualidade de águas, geologia e avaliações agrícolas (NOVO, 2010).

77

Correa et. al. (2005) analisaram a contribuição de imagens CBERS na atualização do mapeamento sistemático brasileiro na escala 1:100.000, abordando a importância do sensoriamento remoto orbital na cartografia e ressaltando algumas vantagens, tais como: imageamento de áreas de difícil acesso terrestre e aéreo; o caráter sinóptico aliado ao recurso de imageamento repetitividade: os custos financeiros contínuo е sua decrescentes compartilhados por um número crescente de usuários; e a combinação de bandas espectrais que proporciona uma capacidade de identificação de feições e alvos.

Estudo do IBGE (2011a) descreve o uso de imagens TM\LANDSAT-5 no mapeamento na escala 1:250.000, realizado pela Coordenação de Cartografia. A documentação objetiva estabelecer e padronizar as normas e os procedimentos para a fiscalização, controle de qualidade, validação e homologação das Bases Cartográficas Digitais Contínuas do Brasil na escala 1:250.000, elaboradas por contratação de empresas especializadas na prestação de serviços de mapeamento e atualização cartográfica.

Porém, o uso de imagens orbitais para escalas maiores que 1:25.000 não é um tema unânime. Machado e Silva *et al.* (2005) avaliaram o uso de imagens IKONOS para mapeamentos topográficos na escala 1:25.000 ou menores e encontraram bons resultados na qualidade dos dados.

Em outro estudo, Silveira *et al.* (2005) ressaltaram a utilidade de imagens IKONOS na identificação de alterações ocorridas no espaço urbano, como a sua ocupação e expansão, porém destacaram que não seria recomendável o uso desse tipo de sensor para a geração e atualização de base cadastral.

Diversos estudos tratam da questão da atualização cartográfica a partir de imagens orbitais. D'Alge (1997) tece considerações teóricas e um detalhamento conceitual sobre a importância da correção geométrica de imagens do satélite TM\LANDSAT-5 para atualização de folhas topográficas. Posteriormente, Mangabeira *et al.* (2003) e Vergara *et al.* (2007) relataram o uso do sensoriamento remoto orbital como instrumento para atualização cartográfica, auxiliando estudos voltados para diferentes aplicações .

Cruz & Barros (2012) apresentam um estudo com avaliações de acurácia em termos de geometria para 10 sensores que atendem à geração de

78

produtos cartográficos. Ressalta-se a importância em se conhecer os limites das imagens em termos de acurácia planialtimétrica e altimétrica para escalas cartográficas específicas, ressalvando-se que isso não garante a extração de feições para a mesma escala. Para isso, seria necessário se refletir em um estudo sobre acurácia em termos de interpretabilidade.

Em 2004, um comitê de especialistas (OGC, 2004) elaborou um documento técnico que relacionava as resoluções espectrais e espacias dos principais sensores (à época) com possíveis aplicações, conforme é mostrado na figura 3.1.



Figura 3.1: Requisitos de Imagens para determinadas aplicações (OGC, 2004)

A figura ilustra a necessidade de associar os tipos de imagens com determinadas aplicações, considerando as resoluções espacial e espectral. Percebe-se a tentativa de atribuir usos, de acordo com o tamanho do pixel e as diferentes faixas espectrais. Faltaria, ainda, a questão da radiometria, que realça, por exemplo, aspectos de sombreamento. Mas a análise da figura permite reconhecer a questão da usabilidade, mencionado anteriormente.

Outro aspecto importante ressaltado no gráfico, é o custo envolvido para a aquisição de imagens. No caso de interpretação em áreas urbanas, por exemplo, que necessita de imagens com alta resolução espacial do sensor, deve-se levar em consideração os recursos financeiros necessários, uma vez que imagens com alta resolução espacial, são comercializadas por poucas empresas que ainda agregam serviços de processamento. De qualquer forma, a utilização desse tipo de imagem orbital para elaboração e atualização cartográfica vem acompanhada de uma qualidade cada vez maior no que diz respeito à resolução espacial e multiespectral de alta tecnologia, atendendo aos requisitos de precisão planimétrica exigidos para as escalas do mapeamento sistemático. Ainda assim, deve-se ressaltar o menor custo de aquisição de imagens orbitais quando comparado a realização de novo recobrimento aéreo. Essa questão dos custos, reforça a necessidade de mais avaliações nessa linha de estudo que relaciona sensores e aplicações possíveis. Conhecendo-se as potencialidades de um determinado sensor para determinados fins, evita-se a aquisição de imagens com o custo mais alto de forma desnecessária.

3.3 EXEMPLOS DE CRITÉRIOS DE INTERPRETABILIDADE

3.3.1 Classificação de uso e cobertura do solo da USGS

O Serviço Geológico Norte-Americano (USGS) criou, em 1971, um sistema de classificação de cobertura e uso da terra baseado em técnicas de sensoriamento remoto, denominado *A Land Use and Land Cover Classification System for Use with Remote Sensor Data* (USGS,2001), que corresponde a um padrão usado por todas as instituições produtoras e usuárias desse tipo de dado nos Estados Unidos. Um dos aspectos interessantes desse sistema é a divisão em quatro níveis de detalhamento dos dados, tendo em vista que os inúmeros sensores disponíveis irão fornecer dados com diferentes resoluções e escalas. O quadro 3.3 mostra os requisitos mínimos de resolução espacial e espectral que devem atender para cada nível.

Quadro 3.3: Requisitos mínimos dos sensores para atender aos níveis do mapeamento. (adaptado de Jensen, 2009)

Nível	Resolução	Resolução Espectral	Exemplos
	Espacial		
11	20 -100 m	V-NIR-MIR-Radar(op.)	TM\Landsat-5
II	5-20 m	V-NIR-MIR-Radar(op.)	SPOT-5
	1-5 m	Pan-V-NIR-MIR (op.)	IKONOS-II
IV	0,25 – 1 m	Pan	Fotografias aéreas

Cada nível atenderia a um conjunto de características próprias de um mapeamento de cobertura e uso, considerando que quanto maior o nível, maior será o detalhamento a ser obtido. O conceito de nível está intrinsecamente relacionado à escala de análise, segundo a qual cada nível possui suas especificidades e contribuições para as formas de representação da superfície terrestre.

Os níveis são agrupados em nove categorias: Solo construído; Agricultura; Paisagens Naturais; Floresta; Água; Áreas Úmidas; Áreas Rochosas; Tundra; e Neve perene. Em cada categoria estão incluídos quatro níveis de dados (quadro 3.4) que podem ser extraídos a partir dos requisitos mínimos dos sensores.

Quadro 3.4: Categorias e níveis de Informação para o uso e cobertura do solo. (USGS, 2001)

Solo construído	Solo construído	Solo construído	Solo construído
1- Residencial	1- Residencial	1- Industrial	1- Industrial
2- Unifamiliar	2- Multi-familiar	2-Processamento	2- Extração
3- Casa	3- Condomínio	3- Químico	3- Céu aberto
		4- Farmacêutica	4- Cobre

3.3.2 Escalas Nacionais de Valoração da Interpretação de Imagens (NIIRS)

O critério NIIRS constitui a métrica usada pela comunidade de inteligência norte-americana para caracterizar a utilidade de imagens com propósitos de interpretação, sendo inicialmente empregadas para fins militares e posteriormente elaboradas para estudos ambientais e planejamento territorial (Leachtenauer, 1996; Campbell & Wynne, 2011; Schott, 2007; Jansen, 2009).

Tal indicador consiste em 10 níveis de avaliação, correspondendo a valores inteiros, que refletem o grau de interpretabilidade de um determinado tipo de imagem, de acordo com o que se pode extrair dela. Esses valores são estabelecidos através de uma avaliação de um comitê especialista, denominado *Imagery Resolution Assessments and Reporting Standards Committee* (IRARS). Dessa forma, a proposta NIIRS serve para padronizar um índice de interpretabilidade que associe imagem com tarefas a serem executadas de acordo com os objetivos a serem alcançados. Por isso, existem variações dessa escala de acordo com o uso e os tipo de imagem, conforme mostra o quadro 3.5. Em virtude de diferentes tipos de imagem, foram desenvolvidos cinco modalidades de NIIRS: visível, Civis, Radar, Infravermelho e Multiespectral.

Escala	Tipo de imagem	Comentário
NIIRS visível	Imagens Pancromáticas	Feições militares
NIIRS Civil	Imagens Pancromáticas	Equivalente ao NIIRS visível,
		mas focado em feições não-
		militares
NIIRS Radar	Radar Abertura Sintética	
NIIRS IR	Termal IR	
NIIRS MS	Imagens multiespectrais	7 níveis (no caso do NIIRS
		visível são 9 níveis)

Quadro 3.5: Variações do NIIRS
No caso das aplicações militares, por exemplo, as tarefas estão associadas basicamente ao reconhecimento de construções militares; estruturas portuárias e aeroportuárias; tipos de aeronaves, embarcações e veículos para transporte de tropas. Sendo assim, uma imagem com o melhor nível de avaliação deve permitir a identificação detalhada de objetos e alvos militares ou de interesse para o Serviço de Defesa americano.

Além da aplicação militar nos Estados Unidos, existe uma escala NIIRS definida para uso civil, dividida em três categorias: Recursos Naturais, Agricultura e Urbano/Industrial. A categoria Recursos Naturais estabelece critérios que dizem respeito a objetos naturais tais como vegetação, rochas, linhas de água e formas de terreno. A categoria Agrícola relaciona tarefas de detecção e identificação de culturas e atividade pecuária, enquanto a categoria Urbano/industrial é usada para objetos construídos, não militares, como vias de comunicação e edifícios.

Para detectar ou identificar determinadas feições é necessário o uso de imagens cujos valores NIIRS variam de zero (interpretabilidade nula) até nove (maior interpretabilidade), sendo que, basicamente, os valores de NIIRS são divididos utilizando-se como critério o tamanho do pixel da imagem. O quadro 3.6 mostra alguns exemplos de tarefas para a categoria Urbano/Industrial inserida nas aplicações civis. Nota-se que quanto maior o valor do NIIRS, maior é o detalhamento das tarefas a serem esperadas. Para NIIRS com valor igual a 1, cujas imagens apresentam resolução acima de 9 metros, são definidas como tarefas as detecções de áreas urbanas/rurais, as grandes pontes e rodovias com múltiplas faixas. Estariam classificadas nesse nível, por exemplo, as imagens dos sensores AVNIR. Já as imagens do satélite RapidEye estariam no nível 2, cujas tarefas esperadas seriam, por exemplo, a Identifica os principais padrões de ruas em áreas urbanas, a detecção dos trechos ferroviários com duas ou mais linhas e a Identificação de quarteirões em uma área metropolitana. Alguns exemplos de tarefas apresentam contexto fora dos padrões para a interpretação realizada pelos especialistas, já que são citadas tarefas bastante específicas de determinados usuários. De qualquer forma, o quadro permite obter uma ideia geral do que se espera interpretar a partir das imagens.

Quadro 3.6: Tarefas do	padrão NIIRS	para aplicação	o civil nos	Estados Unidos.

NIIRS	GSD	Tarefas da categoria urbano / industrial							
0		Interpretabilidade da imagem é impossibilitada por							
		obscurecimento, degradação ou resolução inadequada.							
1	> 9 m	- Detecta áreas urbanas e rurais.							
		- Detecta grandes pontes.							
		- Detecta rodovias com múltiplas faixas.							
2	4.5 -9 m	- Identifica os principais padrões de ruas em áreas urbanas.							
		- Identifica quarteirões em uma área metropolitana.							
		- Detecta trechos ferroviários com duas ou mais linhas.							
		- Detecta grandes aeronaves num grande aeroporto comercial.							
3	2.5-4.5 m	- Detecta estradas sem pavimentação com duas faixas.							
		- Detecta grandes veículos.							
		- Detecta torres associadas a linhas de transporte de energia.							
4	1.22.5 m	- Detecta barreiras/obstáculos em uma estrada.							
		- Detecta estragos estruturais em edificações urbanas.							
5	0.75-1.2 m	- Identifica postes em zonas residenciais.							
		- Identifica linhas em campos de futebol.							
6	0.4-0.75 m	- Detecta transformadores elétricos montados em postes numa							
		zona residencial.							
		- Detecta pequenos sinais de trânsito em uma zona urbana.							
7	0.2 - 0.4 m	- Identifica veículos pequenos.							
		- Detecta detalhes na carroceria de caminhões.							
8	0.1 -0.2 m	- Detecta corrosão em superfícies de metal.							
		- Identifica detalhes de obras e construções em andamento.							
9	< 0.1 m	- Identificar pegadas de animais de médio porte							
		- Identificar detalhes de cerca de arame farpado.							

Basicamente, a escala de NIIRS trata da resolução espacial, porém vale destacar uma documentação complementar que trata de imagens multiespectrais, cujo objetivo é especificar o grau de interpretabilidade e os requisitos adequados em termos de cobertura espectral, ou seja, além de separar as imagens usando os critérios espaciais, é estabelecida uam metodologia para destacar os comprimentos de ondas específicos a uma tarefa. O quadro 3.7 mostra um exemplo com três tarefas, o valor NIIRS correspondente ao intervalo do tamanho de pixel adequado e as bandas necessárias (N) e desejáveis (D).

Quadro 3.7: Especificação de interpretabilidade e comprimentos espectrais necessários e desejáveis para imagens multiespectrais (IRARS, 1999)

		Cobertura espectral				
Tarefa	NIIRS	Azul	Verde	Vermelho	IV próximo	IV médio
Detectar plantação de alfafa	4	D	Ν	N	N	D
Detectar pivô de irrigação	5		D	Ν	Ν	D
Identificar áreas dragadas em estrutura portuária	3	N	Ν	Ν		

Dessa forma, considerando essa metodologia de avaliação da qualidade de imagem, pode-se refletir sobre sua aplicação para fins de mapeamento no Brasil. Nos Estados Unidos, existem metodologias de NIIRS, adaptadas do estudo de Irvine, aplicadas para fins civis usando apenas composições coloridas. Ou seja, para cada imagem com um determinado tipo de composição colorida, assim como para a feição que se quer extrair, existe um valor de NIIRS associado.

Manta (2012) adaptou essa metodologia em Portugal, para fins de gestão e apoio ao mapeamento municipal, na escala 1:10.000, usando imagens do satélite Quickbird. A autora menciona que mesmo sendo usado um sensor de alta resolução espacial, com o uso de imagens fusionadas de 60 cm, só foi possível detectar a presença de alguns elementos nas imagens, não sendo possível qualificá-los apenas interpretando as imagens, como por exemplo as linhas de transmissão de energia (figura 3.2).



Figura 3.2: Algumas tarefas possíveis em uma imagem QuickBird fusionada. (MANTA, 2012).

Essas abordagens enfatizam a questão das diferentes resoluções e combinações das bandas espectrais no tratamento da interpretabilidade. Porém, existem estudos que consideram alguns elementos que podem prejudicar a interpretabilidade de imagens de um sensor remoto. Esses fatores seriam, por exemplo, bruma atmosférica, contraste, ângulo de visada e ruídos que podem reduzir a habilidade de um analista bem treinado para detectar, discriminar e identificar objetos em uma imagem.

A partir de 2009, são encontrados alguns estudos que apontam a necessidade de se considerar diversos parâmetros do sensor e condições

atmosféricas que interferem na radiometria no momento da aquisição da imagem (Kim *et al.* 2012; Stefanou &. Kerekes, 2009). Para se alcançar um índice de interpretabilidade com maior detalhamento, na escala NIIRS, é usada a equação geral de qualidade da imagem (*General Image Quality Equation*) cujas variáveis estão destacadas na equação 3.1:

NIRS = 11.81+ 3.32 * $\log_{10} (\text{RER}_{\text{GM}}/\text{GSD}_{\text{GM}}) - (1.48*\text{H}_{\text{GM}}) - (G/\text{SNR})$ Equação 3.1

Onde:

NIIRS = National Imagery Interpretability Rating Scale RER_{GM} = Relative Edge Response GSD_{GM} = Ground Sampled Distance H_{GM} = Edge overshoot G= Convolver gain SNR= Signal-to-noise

A tabela 3.1 mostra os resultados de NIIRS para diferentes imagens IKONOS e QuickBird, segundo estudo de Glittone (2010). Os campos denominados RER (*Relative Edge Response*) e H (edge overshoot) dizem respeito às características geométricas (dimensões) e efeitos de radiância do alvo em relação aos pixels vizinhos. A valor de G está associado ao processamento da imagem, especificamente ao ruído gerado durante o processo de reamostragem da imagem (vizinho mais próximo, bilinear, convolução cúbica). Já o GSD *significa Ground Sampled Distance*, parâmetro relacionado ao sistema sensor que define o valor do tamanho do pixel. Esse valor pode ser influenciado pelo ângulo de inclinação do satélite no momento da captura da imagem.

Os resultados da equação correspondem a valores de interpretabilidade em números reais e representativos para a data na qual a imagem foi adquirida, ou seja, cada imagem terá um valor específico, independente do sensor

	RER	Н	G	GSD	NIIRS
Quickbird 1	0.2135	0.7783	4.16	0.69994	3.16
Quickbird 2	0.2043	0.7735	4.16	0.6797	3.15
Quickbird 3	0.2711	0.7832	4.16	0.7509	3.34
Quickbird 4	0.2515	0.7668	4.16	0.7661	3.23
IKONOS 1	0.2444	0.7939	4.16	0.9295	3.01
IKONOS 2	0.2233	0.7765	4.16	0.9099	2.92

Tabela 3.1: Valores de NIIRS para seis imagens dos satélites IKONOS e Quickbird (fonte: Glittone, 2010)

O problema dessa metodologia, além do uso de cálculos de alta complexidade, está na obtenção de parâmetros de satélites, que, na maioria das vezes, são difíceis de serem disponibilizados pelas empresas fornecedoras, o que pode impossibilitar o desenvolvimento do estudo.

Para finalizar a questão da interpretabilidade, Jensen (2009) elabora um quadro (figura 3.3) que ilustra uma comparação entre os quatro níveis da classificação da USGS para uso e cobertura do solo e a metodologia NIIRS, considerando a resolução espacial como critério de separação entre os níveis.



Figura 3.3: Quadro comparativo entre as metodologias de interpretabilidade usada pela USGS e NIIRS (fonte: Jensen, 2009).

3.4 DETECÇÃO E IDENTIFICAÇÃO DE FEIÇÕES CARTOGRÁFICAS NA BHRSJ

Considerando as características envolvidas no conceito de interpretabilidade em imagens de sensoriamento remoto, acredita-se que exista um enorme potencial no desenvolvimento desse tipo de estudo. Atualmente, há uma grande diversidade de sensores com resoluções distintas, cujas imagens servem como insumos para mapeamentos de referência ou temáticos.

No caso do mapeamento de referência, a produção cartográfica é planejada conforme as escalas previstas através do Sistema Cartográfico Nacional (SCN). No Brasil, para o mapeamento topográfico nas escalas 1:100.000 e 1:250.000 tem-se utilizado insumos derivados de sensores remotos orbitais, como por exemplo os satélites da série LANDSAT, ALOS e RapidEye.

Além das características das imagens, o conceito de interpretabilidade pode estar vinculada à escala cartográfica, uma vez que, a própria ET-ADGV descreve os tipos de feição que devem ser contemplados para cada escala cartográfica. Por exemplo, a feição fonte d'água só está prevista para ser representada na escala 1:25.000. Dessa forma, ao se trabalhar com imagens que atendam a escalas menores, a tarefa de detectar e identificar fontes d'água não será importante. Além disso, cada feição possui diversos atributos que detalham as suas características.

Porém, a ET-ADGV menciona ainda duas observações importantes. A primeira é a possibilidade de extrair feições com dimensões inferiores às previstas ou não contempladas para uma determinada escala. Nesse caso, deverá ser considerada a relevância desse elemento para o contexto da superfície terrestre que está sendo mapeada. Dois exemplos dessa situação são postos de combustíveis em locais afastados dos centros urbanos e massas d'água em áreas áridas. A outra observação diz respeito a elementos que no terreno possuem pequenas dimensões, mas são estruturas relevantes, como é o caso das cercas divisórias nas áreas de pecuária extensiva (DSG, 2010).

Na abordagem teórica-conceitual desse estudo, ao estudar alguns indicadores de interpretabilidade, como por exemplo o NIIRS, percebe-se que o conceito de escala cartográfica não está vinculado ao potencial de interpretação envolvida, pelo menos de forma direta. Ao se trabalhar com o

conceito de interpretabilidade, questão fundamental é a própria extração do alvo, ou seja, o mais importante é avaliar se um determinado objeto é visível ou não em uma determinada imagem, independente de suas dimensões. Talvez refletir sobre as dimensões associadas à cada escala seja um caminho a ser estabelecido em um estudo futuro. Nesse cenário, poderia se pensar em formas de aquisição detalhada e dependendo da escala, aplicar ferramentas de generalização cartográfica. Por isso, esse estudo preocupa-se na reflexão de dos alvos, sem enfatizar as suas dimensionalidades.

Além disso, há de se considerar a dificuldade prevista na interpretação de alguns tipos de feições, como as edificações, uma vez que a imagem favorece a interpretação de tipos de cobertura, mas muitas vezes não é possível identificar o tipo de uso de obras e construções. Estes são exemplos de demandas só atendidas através do trabalho de reambulação.

A figura 3.4 ilustra o método proposto no estudo, estabelecido a partir de três aspectos básicos: interpretabilidade, INDE e as imagens.

As questões teóricas da interpretabilidade foram descritas ao longo desse capítulo, sendo discutidas as definições que sustentam esse conceito. A partir do entendimento conceitual, neste estudo detalha-se uma proposta para a geração de um índice de interpretabilidade, criado a partir dos parâmetros de detecção e identificação das feições.

O segundo aspecto que dá sustentação para esse estudo, em termos de método, constitui a abordagem da Infraestrutura Nacional de Dados Espaciais (INDE) no tocante ao uso de padrões e especificações técnicas, envolvendo estrutura e controle de qualidade dos dados espaciais produzidos no Brasil. Essas normas servem como modelos para o desenvolvimento do estudo de caso proposto, como por exemplo a avaliação geométrica, no qual optou-se por comparar o PEC, padrão oficial, com outras abordagens mais recentes.

Para a avaliação da qualidade dos dados ainda existem outros componentes de avaliação do dado espacial não mencionados nos padrões oficiais, como por exemplo, o conjunto de procedimentos para avaliação da qualidade radiométrica das imagens. Não existe, dentro do contexto da INDE, um documento que trate desse tipo de avaliação.



Figura 3.4: Fluxograma com as principais etapas de desenvolvimento do índice de interpretabilidade.

E o terceiro aspecto representa os principais insumos para a construção do índice de interpretabilidade: as imagens orbitais. É a partir de sua interpretação e processamento que se dará a produção dos dados cartográficos referentes à cada sensor, de forma que se possa realizar uma comparação e mensurar a qualidade no que se refere ao seu potencial de interpretação. Conforme descrito no capítulo anterior, para o desenvolvimento de interpretação, foram definidos três sensores do processo com características distintas de resoluções, a fim de se conhecer as potencialidades e limitações envolvidas para a detecção e identificação. Esses sensores são as imagens multiespectrais do OLI\LANDSAT-8 fusionada em 15 metros, AVNIR-2 \ALOS e AVNIR-2 RapidEye. Ao longo desse capítulo, pretende-se detalhar os aspectos da extração e classificação dos dados cartográficos referentes à área de estudo.

3.4.1 Caracterização da área de estudo

A escolha da bacia hidrográfica do rio São João como área de estudo deve-se, por ela apresentar uma diversidade significativa de elementos naturais e antrópicos, o que possibilita trabalhar com interpretação de diferentes feições cartográficas, como hidrografia, vegetação e sistema de transporte. Além disso, as diferentes formas de relevo existentes na área possibilitam uma análise sobre a influência da diversidade geomorfológica no processo de interpretação das imagens, principalmente nas áreas mais montanhosas.

Localizada na porção leste do Estado do Rio de Janeiro (figura 3.5), a bacia posiciona-se em sua totalidade na Região das Baixadas Litorâneas do Estado do Rio de Janeiro, sendo que a sua parte norte faz divisa com alguns municípios da Região Serrana do estado do Rio de Janeiro e à oeste com os municípios da Região Metropolitana.

Sendo assim, oito municípios estão inseridos parcialmente na bacia do rio São João, cuja área é ocupada principalmente pelo município de Silva Jardim. A tabela 3.2 mostra o percentual de área ocupada na bacia pelos oito municípios que integram a bacia do rio São João.

Município	Percentual de área ocupada na bacia			
Silva Jardim	44,3 %			
Araruama	16,7 %			
Casimiro de Abreu	15,6 %			
Rio Bonito	12,3 %			
Cabo Frio	7,59 %			
Cachoeiras de Macacu	2,82 %			
São Pedro da Aldeia	0,39 %			
Rio das Ostras	0,32 %			

Tabela 3.2: Municípios inseridos na bacia do rio São João.

A bacia está situada entre as coordenadas -42° 39' 36" e -22° 23' 59" referente ao ponto mais a noroeste; e - 41° 57' 58" e -22° 49' 59" referente ao ponto mais a sudeste. Estende-se por aproximadamente 65 quilômetros no sentido leste-oeste e 45 quilômetros no sentido norte-sul, possuindo uma área total de 2.115 km²



Figura 3.5: Mapa de localização da bacia hidrográfica do rio São João.

3.4.1.1 Caracterização geomorfológica

O conhecimento sobre o relevo da área é de fundamental importância para as diferentes etapas que envolvem o processamento de imagens como, por exemplo, o georreferenciamento e a classificação. Os dados obtidos através do sensoriamento remoto são fortemente influenciados pelas características geomorfológicas. Por isso, a aplicação da correção geométrica é uma das primeiras etapas de processamento, tendo em vista que são aplicadas alterações que visam reduzir o efeito da topografia nas imagens. Posteriormente, na fase de classificação, os efeitos do relevo, como os sombreamentos em áreas montanhosas podem dificultar o reconhecimento de objetos nas imagens.

Segundo Cunha (1995), na bacia do rio São João distinguem-se três domínios geomorfológicos: a Serra do Mar, os Maciços e a Baixada (figura 3.6). Na sua porção Norte e Noroeste predomina o conjunto de montanhas e escarpas pertencentes à Serra do Mar. Os maciços, sejam os costeiros ou alcalinos, situam-se predominante nas porções noroeste e sudoeste, porém destaca-se na parte nordeste, o maciço do Morro de São João, com sua forma peculiar. A parte central da bacia é constituída, basicamente, pela superfície aplainada das baixadas e a baixada propriamente dita, representando as planícies aluviais, destacando-se a do rio São João. A figura 3.7 mostra as principais classes geomorfológicas da bacia.

Na escarpa da Serra do Mar, originada por processos orogenéticos, estão os divisores mais elevados da bacia, com altitudes entre 500 a 1000 metros, podendo ser encontradas altitudes superiores (até 1500 m), principalmente na parte noroeste, nas proximidades do município de Cachoeiras de Macacu. Segundo Cunha (1995), o rio São João coincidiu seu leito com a direção dos antigos dobramentos dos gnaisses, constituintes da serra em questão. Seus afluentes da margem esquerda penetram profundamente na escarpa, através de vales retilíneos, encaixadas entre cristas elevadas e cuja direção foi influenciada por falhas. No contexto da escarpa da Serra do Mar, destacam-se as unidades geomorfológicas Espigão das Serras de Santana e Botija; e as escarpas das Serras de Macaé, Macabu e Imbé (CPRM, 2001).

De altitudes mais modestas, entre 200 e 500 metros, o conjunto de maciços que fazem parte da bacia apresentam escarpas abruptas e paralelas à Serra do Mar. CPRM (2001) classifica dois principais tipos de maciços: os maciços alcalinos intrusivos e os maciços costeiros. O primeiro grupo compreende um conjunto de maciços montanhosos de rochas alcalinas geradas num período de atividade vulcânica entre o final do Cretáceo e o início do Terciário, decorrente da abertura do oceano Atlântico. Esse magmatismo gerou uma série de corpos alcalinos que intrudiram o embasamento cristalino de idade pré-cambriana (ALMEIDA, 1976). Na bacia do rio São João, destacam-se os maciços alcalinos intrusivos de Tanguá-Rio Bonito e o Morro de São João. (CPRM, 2001).

Já os maciços costeiros se referem ao conjunto de estruturas montanhosas relativamente alinhadas sob direção WSW-ENE, desde o Maciço da Juatinga, em Parati, ao maciço da Região dos Lagos. A sua principal característica é estar situado entre as baías e baixadas litorâneas. Segundo Almeida & Carneiro (1998), os maciços costeiros presentes no Rio de Janeiro são remanescentes de uma antiga borda meridional do *graben* da Guanabara, outrora inserida no Planalto Atlântico, no Paleoceno, e que foi intensamente erodida pelo recuo da escarpa da Serra do Mar, originada junto à Falha de Santos. Na bacia do rio São João, destaca-se o Maciço da Região dos Lagos, que abrange os municípios de Maricá, Saquarema e Araruama.

A unidade geomorfológica mais extensa na área da bacia é a superfície aplainada das baixadas litorâneas, representando áreas planas com eventuais terrenos de colinas com baixa amplitude de relevo. As superfícies aplainadas estão compreendidas entre a Serra do Mar e as baixadas fluviomarinhas. Na bacia do rio São João predomina a superfície aplainada da Região dos Lagos, que se estende desde a parte leste da Baía de Guanabara até aproximadamente a margem direita do rio São João. A partir da margem direita está situada a superfície aplainada do norte fluminense, que se estende até o município de Campos de Goytacazes.



Figura 3.6: Mapa geomorfológico da bacia do rio São João.

Por último, destacam-se as áreas de baixada, referentes às planícies aluviais originadas pela sedimentação marinha, além dos materiais de aluviões trazidos pelos rios que descem da Serra do Mar e dos maciços. Segundo Amador (1997), a sua evolução está relacionada a eventos quaternários de oscilação climática e variação do nível do mar. Na bacia, destaca-se a baixada do rio São João, localizada predominante no seu baixo curso.

3.4.1.2 Caracterização hidrológica

Os sensores remotos disponíveis disponibilizam dados de objetos da superfície terrestre que ressaltam as suas formas espaciais e propriedades biológicas, químicas e físicas. No caso dos corpos hídricos, o uso de imagens possibilita a delimitação de canais e massas d'água, além de ampliar o conhecimento sobre parâmetros relacionados à poluição, ao transporte de carga de sedimentos e à presença de clorofila, por exemplo. Particularmente, nesse estudo, a ênfase será na possibilidade de se extrair e identificar elementos de hidrografia localizados na bacia do rio São João, que apresenta uma grande variedade de feições hidrológicas.

Segundo Cunha (1995), a bacia do rio São João pode ser dividida, do ponto de vista hídrico, em três compartimentos:

- O alto São João, das nascentes até a lagoa de Juturnaíba;
- A Represa de Juturnaíba, com seus afluentes Capivari e Bacaxá;
- Rio São João, a jusante da lagoa.

O primeiro compartimento se caracteriza pelo conjunto de drenagem que flui na Serra dos Órgãos e os maciços. Predominam os rios em vales encaixados até atingir a superfície aplainada e as planícies de inundação. Destacam-se os rios Bananeiras, Maratuâ, Pirineus, do Ouro, Salto d´água e Águas Claras. Todos com extensão maior ou igual a 10 quilômetros.

A represa de Juturnaíba, localizada na porção central da bacia, possui grande importância estratégica para o estado do Rio de Janeiro, sendo uma das principais fontes de abastecimento de água para a Região dos Lagos, para a irrigação das áreas agrícolas e para o controle das áreas de inundação. A construção da barragem foi estabelecida em função da Lagoa de Juturnaíba, sendo realizada pelo extinto Departamento Nacional de Obras e Saneamento (DNOS) durante as décadas de 1970 e 1980. Dois rios com grande extensão deságuam suas águas na represa: os rios Bacaxá e Capivari.

A partir da área da represa, o rio São João percorre uma extensa planície aluvial até chegar ao oceano. No passado, o rio São João fluía através de inúmeros meandros, atualmente abandonados. Além da construção da represa, o DNOS realizou diversas modificações em ecossistemas aquáticos, como as intervenções de retificação no próprio canal principal, localizadas à jusante da lagoa e em áreas adjacentes no mesmo período da construção da represa.

3.4.1.3 Caracterização da cobertura vegetal

Uma das principais características da bacia é o fato de abrigar grande parte dos últimos fragmentos de Mata Atlântica em áreas de baixada no estado do Rio de Janeiro, com vegetação em diferentes estados de conservação. A bacia localiza-se dentro do contexto da Mata Atlântica, situada entre o corredor da Serra do Mar e o litoral do oceano Atlântico. Além disso, existem outros tipos de cobertura vegetal, como os manguezais, as matas de restingas, brejos e pequenas áreas de campos de altitude. O quadro 3.8 mostra os principais tipos de cobertura vegetal presentes na bacia (BIDEGAIN, 2005).

Тіро	Ocorrência
Campos de Altitude	Unicamente nas cercanias da Pedra do Faraó
Florestas (Mata	Manchas diversificadas nas Serras de Silva Jardim, Rio
Atlântica)	Bonito, Casemiro de Abreu e Saquarema. Matas com
	pau-brasil em Armação dos Búzios e Cabo Frio.
Restinga	Arredores de Jaconé, nas restingas de Massambaba e
	de Cabo Frio e em Itapebussus (Rio das Ostras),
Estepe Arbórea	Morros costeiros de São Pedro de Aldeia, Cabo Frio,
Aberta	Arraial do Cabo e Armação dos Búzios
Manguezais	Foz dos rios São João e das Ostras e alguns trechos
	das margens das lagoas de Araruama e Saquarema.
Brejos	Espalhados pela baixada

Quadro 3.8: T	ipos de cobe	ertura vegetal na	a área da bacia	(BIDEGAIN, 20)05)
		0		`	

Além da variedade entre os principais tipos, a vegetação apresenta uma diversidade de características internas. Há diversos tipos de florestas que refletem a inclinação nas encostas, a profundidade do solo, a orientação das encostas e, ainda, o tempo decorrido desde a última perturbação, como por exemplo, os desmatamentos e queimadas.

3.4.1.4 Caracterização socioeconômica

A bacia é atravessada por uma extensa rede de rodovias e estradas sob administração pública federal, estadual, municipal e privada. Destaca-se a BR-101, que se estende por 70 km na bacia e é operada pelo consócio Autopista Fluminense, empresa responsável, desde 2008, pelos 320 quilômetros da rodovia BR-101 no trecho que atravessa o estado do Rio de Janeiro, de Niterói à divisa com o Espírito Santo. O Departamento de Estradas de Rodagem (DER/RJ), órgão criado em 1975, após a fusão dos estados do Rio de Janeiro e Guanabara, administra sete rodovias estaduais localizadas na bacia. Além disso, a Via Lagos (RJ-124) estende-se por 24km pela bacia do rio Bacaxá, indo de Rio Bonito em direção a São Pedro da Aldeia. Com 60 km de comprimento total, trata-se de uma estrada pública gerenciada pela empresa Concessionária Via Lagos.

Nos municípios costeiros, as principais atividades econômicas estão ligadas à construção civil, à extração de petróleo em alto mar e à pesca. Porém, o turismo é o grande destaque, ressaltando-se o fato da população duplicar, principalmente no verão. Já nos municípios do interior da bacia, predominam as atividades de pecuária e agricultura, principalmente a citricultura, cana-de-açúcar, arroz, mandioca e banana.

Além da barragem de Juturnaíba, outras instalações de grande porte presentes na área são os dutos da Transpetro que transportam hidrocarbonetos de Macaé para a Refinaria Duque de Caxias e Linhas de transmissão da Companhia de Eletricidade do Estado do Rio de Janeiro e a ferrovia Vitória- Rio de Janeiro, administrada pela Companhia Centro Atlântica (FCA).

3.4.2. Processo de Inspeção para avaliação da interpretabilidade

Uma das abordagens desse estudo é realizar uma avalição sobre as imagens de acordo com objetos descritos segundo a ET-EDGV, sem haver uma preocupação com as especificações associadas aos valores de escala.

Nessa proposta de estudo, será observado se as imagens avaliadas possibilitam a interpretação adequada das feições ou se existem dificuldades de reconhecimento do contorno dos objetos e / ou identificação dos tipos de objetos. Conforme descrito na proposta do índice primeira atividade será perceber se os objetos representados nas imagens possuem seus contornos bem definidos, ou seja, se é possível extrair de forma completa o alvo a ser interpretado. Caso não seja possível delimitar o contorno do alvo ou não se consiga delimitá-lo de forma completa, será considerado como erro de detecção. Uma vez detectado, será realizado o segundo procedimento, cujo objetivo é analisar o grau de identificação do alvo na imagem.

A Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais (ET-EGDV) estabelece uma modelagem de dados bastante ampla e com uma quantidade de classes, atributos e relacionamentos bastante vasto. A documentação trata dos processos de aquisição de dados espaciais segundo a normatização da INDE ET-EDGV, prevê a possiblidade de uma geometria ser adquirida de forma parcial, considerando os eventuais problemas que impossibilitem a sua aquisição integral, conforme descrito abaixo:

> "A primitiva geométrica de um mesmo objeto nunca deveria ser interrompida, porém, considerando a impossibilidade de atingir esta premissa, a interrupção não desejável desta geometria deve ser sinalizada com a classe de objetos Descontinuidade_Geometria." (CONCAR, 2007).

Comtemplar todas as classes em um estudo de caso seria uma tarefa bastante difícil e inviável em virtude do tempo para o desenvolvimento da tese. Por isso, foi necessário definir um recorte dos temas a serem trabalhados considerando alguns critérios importantes.

3.4.2.1 Categorias e classes analisadas

Existem doze categorias de informação propostas na ET-EDGV, no qual cada uma possui inúmeras classes, no qual algumas são interpretadas facilmente e em outras, apenas o uso das imagens é insuficiente para a geração de uma base cartográfica. Para a identificação de algumas classes, apenas a interpretação da imagem não é suficiente, sendo indispensáveis outras fontes de informação, como por exemplo, as classes relacionadas à edificações (hospitais, escolas etc.). Outras classes podem apresentar muitas restrições para sua detecção, principalmente no caso de imagens orbitais de média resolução espacial, como por exemplo, as quedas d'água. Além disso, algumas classes servem apenas para facilitar a análise espacial em um ambiente de Sistema de Informações Geográficas, não sendo criadas a partir da interpretação de imagem, mas obtidas através de funções automáticas de análise espacial, como por exemplo, os pontos de início de drenagem e confluência.

Para a realização do procedimento metodológico da pesquisa, sugere-se selecionar, a partir da ET-EDGV, algumas feições cartográficas que atendem ao mapeamento topográfico de referência, usando com critérios principais:

- A representatividade expressiva em todo território nacional;
- A possibilidade de serem representadas através das formas geométricas poligonais e lineares;
- A inserção em categorias diferentes, a fim de contemplar elementos naturais ou estabelecidos pela ação humana.

Sendo assim, foram escolhidas três categorias cujas classes de mapeamento se enquadrem nos critérios estabelecidos acima e que podem ser extraídas e identificadas através do processo de interpretação de imagens. Sendo assim, as categorias de informação a serem analisadas são: Hidrografia, Sistema de Transporte e Vegetação. As geometrias extraídas de forma completa serão classificadas de acordo com o que é visível na imagem, possibilitando obter a exatidão temática das feições cartográficas.

Segundo a ET-EDGV (CONCAR,2010), a hidrografia pode ser definida como a categoria que representa o conjunto das águas interiores e oceânicas da superfície terrestre, bem como elementos, naturais ou artificiais, emersos ou

submersos, contidos nesse ambiente. Sendo assim, essa categoria contém classes associadas a elementos hidrológicos (figura 3.7) estabelecidos naturalmente ou modificados pela ação humana, além de incluir classes que representam construções associadas diretamente ao uso da água, como por exemplo, as comportas e barragens. Na figura estão destacadas as cinco classes que são extraídas e classificadas nesse estudo.



Figura 3.7: Classes de Hidrografia (adaptado de DSG, 2016)

No contexto da hidrografia, algumas classes não são representadas apenas por um tipo de geometria, mas são formadas a partir da agregação de vários tipos de traçados. A ET-EDGV denomina de objeto complexo, quando ocorre a agregação entre os traçados de diferentes classes do tipo linha e/ou polígono, que no caso da Hidrografia correspondem ao curso d'água e trecho de curso d'água. Essa última classe agrega as classes trecho de drenagem (linha) e trecho de massa d'agua (polígono). Por sua vez, o trecho de massa d'água possui uma classe especializada denominada massa d'água (polígono), que contém a classe limite de massa d'água (linha). Assim, um curso d'água (classe abstrata) é formado por vários trechos de curso d'água e trechos de drenagem. As classes trecho de drenagem, trecho de massa d´agua, massa d´água e limite de massa d´água formam, basicamente, a composição básica de uma rede de drenagem. Por isso, as quatro classes foram estabelecidas como referência para avaliar a interpretabilidade de dados de hidrografia nesse estudo. A justificativa se baseia pelo fato de serem elementos bastante representativos na superfície terrestre quando comparadas com outras feições de hidrografia modeladas na ET-EDGV. É comum, também, a utilização dessas feições como referência para a elaboração de feições de outras classes, como por exemplo, os limites, sejam político-administrativos ou áreas militares ou de proteção ambiental. Além disso, as classes de hidrografia são representadas através de traçados distintos, o que permite avaliar o grau de interpretação com o propósito de extração de linhas ou de áreas. Dessa forma, é importante estabelecer a diferença conceitual entre essas quatro classes de hidrografia.

Segundo a ET-EDGV, a massa d'água constitui um corpo d'água que possui uma superfície equipotencial, ou seja, não possui fluxo, sendo esta o principal atributo para definir os limites do polígono dessa massa. São considerados como tipos de massa d'água os seguintes elementos: oceano, baía, enseada, meandro abandonado, lago, lagoa e represas/açudes (usadas para irrigação, piscicultura e atividades afins). A figura 3.8 ilustra um exemplo dessa classe na área de estudo.



Figura 3.8: Exemplo de massa d´água: Lagoa de Juturnaíba.

A figura 3.9 mostra a localização da foto na imagem RapidEye, representado pelo ponto vermelho. A delimitação da massa d´água é estabelecida através da separação entre a água e terra, porém, muitas vezes, essa distinção é prejudicada pela presença da vegetação ou áreas úmidas.



Figura 3.9: Localização da posição da foto na Lagoa de Juturnaíba.

Já o trecho de massa d'água, também representado através de polígono, constitui segmentos de cursos d'água que possuem fluxo e cujos traçados das margens possam ser adquiridos. Ao ser representado em uma determinada escala do mapeamento topográfico, a largura deve ser maior ou igual a 0,8 mm. São considerados como tipos de trecho de massa d'água os seguintes elementos: rio, canal, laguna e represa/açudes (quando é caracterizado o fluxo). A figura 3.10 ilustra um exemplo dessa classe na área de estudo.



Figura 3.10: Exemplo de trecho de massa d´água: rio São João

A figura 3.11 mostra a localização da foto na imagem RapidEye, representado pelo ponto vermelho. Assim como no caso da delimitação da massa d´água, para a extração do trecho de massa d´água é necessário utilizar uma imagem que consiga separar bem a água e terra.



A terceira classe de hidrografia selecionada para avaliação da interpretabilidade é o que a ET-EDGV chama de trecho de drenagem, correspondendo a um corpo d'água, cujo traçado linear representa o fluxo de água. Essa classe pode estar presente isoladamente, estando obrigatoriamente conectada com outra classe, ou contida em um trecho de massa d água. Em função da escala de aquisição, o traçado poligonal (trecho de massa d'água) não é representado, sendo visualizada apenas a feição linear. O trecho de drenagem pode estar conectado ou coincidir com os seguintes elementos: Represa/açude, laguna, rio, canal, vala, queda d'água, corredeira, barragem, eclusa, terreno sujeito à inundação ou foz marítima.

Fazendo uma comparação com os modelos de dados antigos, o trecho de drenagem corresponde à classe curso d´água não representável em escala (Manual Técnico T-34 700 do Exército) e à classe rio de margem simples (Mapoteca Topográfica Digital do IBGE). Já o trecho de massa d´ água representa a classe curso d´água representável em escala (Manual T-34 700 do Exército) e rio de margem dupla (Mapoteca Topográfica Digital do IBGE). As classes lago, lagoa, açude e oceano, que atualmente são atributos de massa d´água da ET-EDGV, constituem em classes diferentes nos modelos antigos.

Uma diferença fundamental entre massa d'água e trecho de massa d'água é a presença, na base cartográfica, do trecho de drenagem no trecho de massa d'água, conforme mostra a figura 3.12.



Figura 3.12: Massa d´água (A) e trecho de massa d´água (B) adaptado de DSG (2016)

Nota-se que a massa d'água não possui em seu interior o elemento trecho de drenagem, que se constitui em uma estrutura importante no trecho de massa dá água, a fim de dar a ideia de fluxo de água.

Vale destacar que a ET-EDGV estabelece também a classe Limite de massa d'água, representado através de uma feição linear, cujo objetivo é servir como um limite definidor de massa d'água e trechos de massa d'água. O propósito é indicar a margem (esquerda ou direita) do trecho de massa d'água, estabelecer a separação entre corpos d'água e ser a linha definidora da costa marítima. A figura 3.13 ilustra alguns exemplos do limite de massa d'água



Figura 3.13: Limite de Massa d´água separando dois trechos de massa d´ água (A) e limite de massa d´água separando o canal do oceano (B) adaptado de DSG (2016)

A separação entre massas d'água a partir do uso de imagens á bastante subjetivo, tendo em vista que não há uma definição precisa. O objetivo dessa delimitação é permitir o fechamento das áreas e o estabelecimento de objetos distintos. Segundo a ET-EDGV (CONCAR, 2010), a vegetação constitui a categoria que representa, em caráter geral, os diversos tipos de cobertura vegetal natural e cultivada. A figura 3.14 ilustra as classes previstas no modelo de dados e as classes destacadas são aquelas selecionadas para a avaliação da interpretabilidade.



Figura 3.14: Modelo de dados da categoria Vegetação (adaptado de DSG, 2016)

A categoria Vegetação possui duas classes especializadas: Vegetação Natural e Antropizada. A vegetação Natural é considerada a que se mantém intacta, não tendo sofrido a ação humana, enquanto a antropizada reflete o grau de modificação pelas atividades humanas. Ambas as classes não são instanciáveis, ou seja, não são delimitadas através de traçados. Essa informação fica armazenada em um atributo nas classes especializadas: Mangue, Floresta, Brejo/Pântano, Caatinga, Cerrado/Cerradão, Macega/chavascal, vegetação de restinga, campinarana e estepe.

Nesse estudo não se pretende especificar se uma área está antropizada ou não, tendo em vista que esse tipo de análise requer uma observação mais ampla da paisagem do que apenas a interpretação da imagem. Uma área pode parecer natural, mas em seu interior podem estar ocorrendo processos não detectados e identificados pelo sensor. A ET-EDGV recomenda que a informação de antropização só deverá ser confirmada caso exista algum dado que permita ter a certeza desse cenário. Dessa forma, nas classes analisadas, todas estarão caracterizadas como natural, com exceção da vegetação cultivada, paisagem que pressupõe o uso humano.

Além dessas classes, o modelo prevê uma classe denominada de Área de contato, correspondendo à uma área de transição entre diferentes objetos de vegetação. Segundo a DSG (2016), este objeto ocorre na interseção entre as especializações da classe vegetação e acontece em virtude da dificuldade de definição dos limites entre os tipos, em decorrência da existência de uma área de transição real ou pela indefinição dos limites, em face da escala do insumo utilizado na aquisição. A única classe não está vinculada às classes natural ou antrópica é a classe Campo.

Enquanto na categoria hidrografia algumas classes são formadas a partir da agregação de vários tipos de geometria, na categoria vegetação esse cenário não se apresenta modelado. O que existe é apenas a especialização de cada classe, sendo que cada uma possui a sua própria geometria, basicamente poligonal.

Quatro classes foram estabelecidas como referência para avaliar a interpretabilidade de dados de vegetação nesse estudo: Campo, Floresta, Mangue e vegetação cultivada. A justificativa se baseia pelo fato de serem elementos bastante representativos na área de estudo e serem mapeáveis em bases cartográficas de referência, apesar de ser um tema mais abordado em mapeamentos temáticos, onde as classes de vegetação costumam ser mais detalhadas. De qualquer forma, nesse estudo tenta-se contribuir para a produção desse tipo de dado para o mapeamento topográfico e de certa forma para a sua atualização.

Segundo a ET-EDGV, o mangue (figura 3.15) é uma vegetação típica de zona costeiro-estuarina, adaptada à água salobra e aos movimentos das marés. O modelo prevê um atributo para essa classe que classifica o seu porte, seja arbustiva, arbórea ou mista. No mapeamento topográfico, não se atinge esse nível de detalhamento, por isso nesse estudo não se pretende classificar o porte do mangue.



Figura 3.15: Exemplo de manguezal.

A interpretação de áreas de manguezais em imagens está vinculada principalmente à sua proximidade com margens de baías, enseadas, barras, desembocaduras de rios, lagoas e reentrâncias costeiras. Porém, também podem ocorrer outros tipos de vegetação nessas regiões, como por exemplo, as matas de restingas e outras formações arbóreas que podem ser confundidas com manguezal. A figura 3.16 ilustra uma área de manguezal na imagem RapidEye onde se localiza a figura acima. Nota-se um fragmento florestal cercado na porção norte e leste pela área urbana de Rio das Ostras, enquanto à oeste predomina a atividade agrícola.



^{42°2'} Figura 3.16: Localização da foto na área de manguezal .

A segunda classe estabelecida é a Floresta, definida na ET-EDGV como uma comunidade arbórea densa ou aberta, cobrindo média ou extensa área, na qual ocorrem árvores altas, copadas e com troncos de porte ou por vegetação emaranhada e de grande complexidade de espécies, formada por árvores altas, cujas copas se tocam formando um teto. No modelo a classe floresta possui um atributo denominado característica da Floresta, possibilitando ao intérprete identificar bosque, mata ou floresta propriamente dita. A principal diferença entre os domínios está na densidade da cobertura vegetal, sendo menor no caso do bosque, sendo que, para esse estudo, não foi abordada essa distinção.

A figura 3.17 mostra um exemplo de floresta na área de estudo, localizado às margens da Represa de Juturnaíba. Nesse exemplo, a cobertura florestal faz parte da Reserva Biológica de Poço das Antas, importante unidade de conservação responsável pela preservação dos ecossistemas, principalmente florestal, junto ao rio São João, que aparece em primeiro plano da foto.



Figura 3.17: Exemplo de floresta nas margens do rio São João

Ao se elaborar a base cartográfica, usa-se o próprio traçado do trecho de massa d'água como referência para a delimitação da cobertura vegetal, tendo em vista que o polígono que representa a floresta não deve ultrapassar a representação do espelho d'água, de forma que um ajuste topológico entre os dois polígonos torna-se indispensável.

A figura 3.18 mostra o posicionamento aproximado da foto acima. Ao norte está a Reserva com alguns fragmentos florestais, ao sul ocorre o predomínio de uma extensão área agrícola.



Figura 3.18: Localização da foto na área de floresta na imagem.

A terceira classe escolhida para o estudo de caso é a vegetação cultivada, caracterizada, segundo a ET-EDGV pelo plantio de uma ou mais espécies vegetais com objetivos ecológicos, de alimentação, aproveitamento industrial ou para proteção do solo contra erosão. Os tipos de lavouras podem ser:

- Perenes: quando se estabelece culturas de longa duração, ou seja, após a colheita não é necessário um novo plantio. Alguns exemplos são: café, laranja, cacau e banana;
- Semiperenes: Abrangem as áreas plantadas ou em preparo para o plantio de culturas de longa ou curta duração;
- Anual: espécie vegetal cultivada com extração para beneficiamento. Abrangem as áreas plantadas ou em preparo para o plantio de culturas de curta duração (em torno de um ano) e que necessitam geralmente, de novo plantio após cada colheita, tais como: arroz, algodão, milho, trigo, flores e hortaliças.

Na área de estudo predomina o cultivo da citricultura (cultura perene) e cana-de-açúcar(cultura anual), principalmente no baixo curso do rio São João, além das atividades de silvicultura e pequenas propriedades familiares (principalmente banana e coco) na escarpa da Serra do Mar (Bidegain, 2005). Essas pequenas propriedades apresentam dimensões que podem não ser suficientes para uma boa diferenciação dos cultivos pelo sensor. A figura 3.19 mostra um exemplo de uma plantação de cana-de-açúcar, atividade bastante presente na bacia do rio São João.

Vale destacar que existem alguns desafios na interpretação de áreas agrícolas, como por exemplo (MOREIRA &RUDORFF, 2002):

 Os diferentes comportamentos espectrais dos cultivos, o que acarreta em análises específicas de cada resposta espectral para uma identificação correta;
Nem todas as culturas são passíveis de serem mapeadas através do sensoriamento remoto em virtude de sua homogeneidade espectral entre diferentes plantios.



Figura 3.19 Exemplo de canavial na bacia do São João

Segundo Ortiz *et al.* (1997), áreas plantadas com as mesmas culturas durante anos sucessivos criam padrões úteis no processo de interpretação para a identificação de alvos agrícolas. Isto ocorre porque há uma tradição regional de cultivo, e fatores como solo, clima e infraestrutura, fazem com que, numa determinada área, ao longo dos anos, seja plantado um mesmo conjunto de culturas. Esse parece ser o cenário da bacia do São João, que apresenta uma divisão regional tradicional entre os tipos de cultivo em seu interior.

De qualquer forma, a discriminação de culturas em imagens de satélite não é tarefa trivial e envolve inúmeros fatores. No entanto, uma análise multitemporal aliada ao padrão de cultivo, à experiência do intérprete e ao conhecimento da área de estudo e das culturas, possibilita um bom resultado na identificação de culturas agrícolas em imagens de satélite. Sendo assim, por conta da grande demanda de tarefas para avaliar os cultivos, a proposta desse estudo é apenas discriminar as áreas de cultivo dos demais tipos de classes. A figura 3.20 mostra a localização da foto na imagem RapidEye.



Figura 3.20: Localização da foto na área de canavial na imagem RapidEye.

A última classe da vegetação selecionada para o estudo é o campo, que segundo a ET-EDGV "a área em que predominam as gramíneas e às vezes com presença de arbustos e espécies arbóreas esparsas". É uma classe modelada de forma diferente das demais, considerando que não está vinculada à classe vegetação natural ou antrópica. A justificativa se baseia no fato do campo ser uma classe que ocorre obrigatoriamente em uma das classes especializadas da vegetação natural ou antrópica podendo estar parcialmente ou totalmente inserido. Ou seja, esta classe destina-se a indicar a presença de vegetação de porte rasteiro, em parte ou em toda a área de uma especialização da classe Vegetação.

A pastagem encontra nesse ambiente um espaço propício para o seu desenvolvimento, por isso, a paisagem composta pela criação de gado em extensas áreas planas ou nas colinas da região é bastante comum. A figura 3.21 ilustra um exemplo desse tipo de vegetação



Figura 3.21: Paisagem de campo com a floresta ao fundo.

O campo sujo apresenta uma fisionomia herbácea e arbustiva com arbustos e subarbustos espaçados entre si, geralmente estão sobre solos mais rasos que podem apresentar pequenos trechos de rochas ou solos mais profundos, mas pouco férteis. Já o campo limpo apresenta poucos arbustos e nenhuma árvore, comumente encontrada próximo às veredas, olhos d'água e em encostas e chapadas (CONCAR, 2010).

Segundo a ET-ADGV a regra de construção dessa classe se baseia na sua inserção em outra classe de vegetação, conforme mostra a figura 3.22. Nesses exemplos, o campo ocorre em uma área de cerrado e uma área de floresta, ou seja, isoladamente a classe não existe.



Figura 3.22: Delimitação de Campo. Adaptado de DSG (2016)

A figura 3.23 mostra a localização na imagem RapidEye do ponto referente à figura 3.21, onde predomina uma extensa área de campo com fragmentos florestais localizados principalmente nas maiores elevações. Essa região constitui a localidade de Bananeiras, região agrícola do município de Silva Jardim.



Figura 3.23: Localização da foto na área de campo na imagem RapidEye.

Segundo a ET-EDGV (CONCAR, 2010), o Sistema de Transporte representa "conjunto de sistemas destinados ao transporte e deslocamento de carga e passageiros, bem como as estruturas de suporte ligadas a estas atividades".

Como essa categoria contempla uma grande quantidade de classes, o modelo foi desmembrado em cinco subsistemas: rodoviário, ferroviário, aeroportuário, portuário e dutos (figura 3.24). Cada subsistema agrupa classes específicas, mas mantendo o relacionamento entre elas.

Além dos subsistemas, existem classes próprias da categoria de transporte, que não fazem parte de nenhum subsistema específico.



Figura 3.24: Modelo de dados da categoria Sistema de Transporte (adaptado de DSG, 2016)

Dentro desse complexo, esse estudo focará três classes pertencentes aos subsistemas rodoviário e ferroviário: Trecho rodoviário, Arruamento e Trecho ferroviário. No caso do trecho ferroviário, será feita a interpretação dos trechos pavimentados e os trechos com leito natural (em alguns modelos de dados antigos era denominado de não pavimentado). A figura 3.25 ilustra a modelagem das classes subsistema rodoviário e ferroviário.



Figura 3.25: Modelo de dados dos subsistemas Ferroviário e Rodoviário (adaptado de DSG, 2016)

Enquanto na categoria Hidrografia o trecho de curso d´água é composto por trechos de massa d´água, no caso do subsistema rodoviário e ferroviário acontece a mesma situação. Uma via rodoviária é composta por trechos rodoviários, enquanto uma via férrea é composta por trechos ferroviários. O atributo que dá o nome dos trechos rodoviários e ferroviário está, respectivamente, na via rodoviária e na via férrea. Assim, por exemplo, uma via rodoviária, pode conter vários trechos rodoviários.

A primeira classe definida para avaliar a interpretabilidade das imagens é o trecho rodoviário, que segundo a ET-EDGV, constitui a "ligação rodoviária entre dois pontos rodoviários". Esses pontos podem ser entroncamentos (conexão entre trechos) ou pontos de mudança da via (alteração de jurisdição, número de faixas, número de pistas, ou tipo de revestimento, por exemplo). Essa feição é sempre representada através de uma estrutura linear e possui um atributo denominado tipo de revestimento, cujo domínio é: leito natural,

revestimento primário (saibro ou cascalho), pavimentado e calçado (paralelepípedos ou blocos de pedras). Considerando a resolução espacial dos sensores analisados nesse estudo, dificilmente haverá a possibilidade de discriminar todos os tipos de pavimentos. Sendo assim, a proposta é identificar os trechos rodoviários que tenham leito natural ou estejam pavimentadas. Existem outros domínios para a classe trecho rodoviário, mas para o seu preenchimento é obrigatório um trabalho de reambulação ou de resgate de outras fontes de dados que não seja a imagem, como por exemplo, a jurisdição do trecho rodoviário (federal, estadual, municipal ou particular). Considera-se como trecho rodoviário de leito natural a rodovia cuja superfície de rolamento se apresenta no próprio terreno natural, enquanto a rodovia pavimentada constitui a superfície cuja superfície é rígida ou flexível, como por exemplo, asfalto ou concreto asfáltico, concreto, cimento. Segundo as regras de construção da ET-ADGV, a linha que representa o trecho rodoviário sempre será traçada no eixo central da rodovia, mesmo no caso de trechos com múltiplas vias. Caso as pistas estejam separadas por canteiro passível de ser adquirido, em escala máxima, prevista para sua visualização serão adquiridos todos os eixos da via rodoviária. Um objeto da classe trecho rodoviário que coincida com um arruamento, deve ser duplicado criando-se um objeto da classe Arruamento

A figura 3.26 ilustra dois exemplos de trecho rodoviário pavimentado (A) e leito natural (B). As figuras 3.27 e 3.28 mostram, respectivamente, as localizações, da rodovia pavimentada e de leito natural na imagem RapidEye.



Figura 3.26: Exemplos de trecho rodoviário pavimentado (A) e leito natural (B).



Figura 3.27: Localização da foto referente ao trecho rodoviário pavimentado.



Figura 3.28: Localização da foto referente ao trecho rodoviário de leito natural.

A segunda classe definida para avaliar a interpretabilidade das imagens é o arruamento, que assim como o trecho rodoviário, faz parte do subsistema rodoviário. Segundo a ET-EDGV, constitui-se as vias internas de uma área urbana. Na versão da ET-EDGV usada para esse trabalho (versão 2.1.3), a denominação a classe é apenas arruamento. Na versão atualizada no ano de 2016, a classe passa a ser denominada de trecho_arruamento.

Assim como o trecho rodoviário, essa feição é sempre representada através de uma estrutura linear e possui um atributo denominado tipo de revestimento, cujo domínio é: leito natural, revestimento primário (saibro ou cascalho), pavimentado e calçado (paralelepípedos ou blocos de pedras). Considerando a resolução espacial dos sensores analisados nesse estudo, dificilmente haverá a possibilidade de detecção dos arruamentos. Mais difícil então será identificar o tipo de revestimento. Por isso, propõe-se nesse estudo apenas verificar a possibilidade de identificar os arruamentos. Segundo a ET-EDGV, consideram-se como arruamento as vias internas de uma área urbana. Para a elaboração desse estudo, será utilizado como referência de delimitação de área urbana, a base cartográfica 1:25.000 elaborado pelo IBGE. Os trechos rodoviários inseridos na área urbana serão identificas também como arruamentos, conforme estabelece a ET-ADGV (DSG, 2016): *um objeto da classe Trecho Rodoviário que coincida com um arruamento, deve ser duplicado criando-se um objeto da classe Arruamento.*

A figura 3.29 ilustra um exemplo de arruamento na área de estudo, enquanto a figura 3.30 mostra a localização da foto na imagem RapidEye.



Figura 3.29: Exemplo de arruamento.



Figura 3.30: Localização da foto referente ao arruamento.

3.4.2.2 Recortes espaciais e unidades de amostragem para a avaliação da interpretabilidade

Para desenvolver as atividades práticas relativas à construção do índice de interpretabilidade, serão testados processos de extração e classificação de feições cartográficas em imagens de três sensores, sendo avaliado o grau de interpretação envolvida para cada imagem.

Um desafio para essa atividade é a dimensão do local de estudo, de forma que a bacia do rio São João apresenta uma área total de 2.115 km². Seria necessário bastante tempo para se extrair todas as feições cartográficas e realizar a validação dos resultados e, provavelmente, impactaria no cronograma desse estudo.

Sendo assim, propõe-se a definição de seis recortes espaciais que contemplem a diversidade das características hidrográficas, botânicas e de estrutura do sistema de transporte, categorias escolhidas para a análise da interpretabilidade. Cada recorte representa uma área de amostragem para a avaliação estatística das feições extraídas, possibilitando realizar o estudo em um perído de tempo compatível com o cronograma do trabalho.

Casa recorte apresenta uma dimensão de 4x4 Km, sendo possível realizar os respectivos layouts em folhas de papel A4 na escala 1:25.000. A impressão desse material auxiliou no desenvolvimento de um trabalho de campo, cujo objetivo foi à construção de eixos rodoviários e a validação de elementos hidrográficos e da cobertura vegetal.

O estabelecimento de cada recorte foi definido de forma semi-aleatória na bacia do rio João. Caso fosse estabelecida uma forma aleatória de seleção, determinadas feições poderiam não ser contempladas para a avaliação, como por exemplo, o trecho ferroviário. Essa estrutura do sistema de transportes, só aparece representada através de um segmento linear que cruza diagonalmente a bacia. Dessa forma, foi definida uma parcela da bacia, dessa vez de forma aleatória, onde o trecho ferroviário está presente. A figura 3.31 mostra a localização dos recortes distribuídos na bacia do rio São João, destacando-se a distribuição que representasse diversos ambientes.







Figura 3.31: Localização dos recortes na área de estudo.

Dentre os métodos de avaliação, destacam-se dois procedimentos de inspeção: por amostragem e completo.

Alves (2014) apresenta uma proposta de metodologia para a realização da avaliação da qualidade da informação geoespacial do componente completude e, para isso, enfatiza a importância da inspeção por amostragem no processo de controle de qualidade de um grande volume de dados cartográficos. Tal metodologia se baseia na norma ISO 19114, na ET-ETGV e ET-ADGV. O autor sugere alguns procedimentos de inspeção por amostragem para dados geoespaciais (ALVES, 2014)

- Método de amostragem: Amostragem aleatória simples, amostragem estratificada (por exemplo, guiado por tipo de feição, relacionamento entre feições ou uma área), vários estágios de amostragem e amostragem não aleatória.
- Lote e escopo: O lote é um local especifico que vai ser inspecionado, podendo ser: uma folha topográfica, um bloco ou uma área prédeterminada limitada por coordenadas. No caso desse estudo, o lote corresponde à bacia do rio São João, sendo formado por um ou vários itens do conjunto dos escopos (população). Os escopos, nesse estudo, correspondem às as classes da ET-EDGV selecionadas para a avaliação da interpretabilidade.
- Item: representa a unidade mínima para ser inspecionada, podendo ser um elemento geométrico ou um atributo. Nesse estudo, os itens são os traçados e atributos que representam as classes da ET-EDGV selecionadas.
- Unidades de amostragem: área onde o lote ou a amostra do lote será inspecionado. No caso desse estudo, são denominados de recortes.
- Tamanho da amostra: informações sobre quantos itens, em média, são extraídos para a inspeção de cada lote. Nesse estudo haverá uma grande variação do tamanho da amostra em função do tipo de feição. Por exemplo, a massa d´água terá poucos elementos a serem avaliados, enquanto os trechos de drenagem terão uma quantidade de elementos bem superior.

A figura 3.32 mostra alguns exemplos de lotes e unidades de amostragem. A figura representa um lote com 48 folhas e 4 unidades de amostragem (figura A) e outro lote composto por uma folha topográfica, também com quatro unidades de amostragem (figura B).





Sendo assim, a amostra deve ser estabelecida de forma a representar, da melhor forma possível, a população. A utilização de uma amostra implica na aceitação de uma margem de erro, denominado de erro amostral. Erro Amostral é a diferença entre um resultado amostral e o verdadeiro resultado populacional; tais erros resultam de flutuações amostrais aleatórias. Nesse estudo, serão coletados, no mínimo, 30 amostras representativas de cada classe, sendo analisadas aleatoriamente dentro de unidades de amostragem, seguindo a proposta de Alves (2014)

Além dos procedimentos de inspeção por amostragem, existem também os meios de inspeção completa, mais adequados para pequenas populações ou para testes que podem ser realizadas automaticamente. Nesse caso, todos os itens do escopo são utilizados para as análises estatísticas. Nesse estudo, as classes que apresentarem menos de 30 itens serão avaliados através de inspeção completa, como por exemplo, o trecho ferroviário e a massa d´água.

Apesar de se tentar representar a diversidade de feições geográficas nas seis unidades de amostragem (recortes) estabelecidas, não há a

possibilidade de fazer uma comparação estatística entre eles, uma vez que cada escopo (classe) não pode ser encontrado em todos os recortes.

Sendo assim, as inferências estatísticas bases para a obtenção dos índices de detecção e identificação, constituem o somatório de todos os recortes.

Vale destacar que no caso do recorte 6, o limite da bacia está situada na sua porção sudoeste, o que implicaria na exclusão dos elementos extraídos fora da bacia do rio São João. A exclusão não foi realizada, sendo cccontabilizado todas as feições extraídas no recorte.

3.4.3 Levantamento de campo

Para auxiliar no processo de validação dos dados produzidos, foi realizada uma campanha de campo nos seis recortes estabelecidos para estudo na bacia do rio São João. As atividades, desenvolvidas entre os dias 19 a 23 de outubro de 2015, envolveram dois procedimentos: o reconhecimento e validação de eventuais dúvidas na pré-classificação e a geração de uma rede de linhas representativas do sistema de transporte, construída através do levantamento de *tracking* nas estradas e ruas dos seis recortes.

O preparativos para o levantamento de campo envolveu a preparação das pranchas referentes à cada recorte com a imagem e os dados de classificação da hidrografia, sistema de transporte e vegetação em *layouts* distintos, impressos em papel A4 na escala 1:25.000. Durante a execução do trabalho de campo, foram realizados registros fotográficos, anotações sobre as observações e a coleta de coordenadas com o uso de um GNSS de navegação. Assim, faziam-se as validações da pré-classificação e os erros corrigidos na classificação final, elaborada posteriormente no gabinete. Além do orientador e orientando, a equipe foi composta por dois bolsistas de iniciação científica, o que permitiu um bom andamento dos trabalhos.

Além de avaliar a classificação, outro objetivo do campo foi realizar um tracking para a elaboração de um arquivo vetorial com as linhas dos trechos rodoviários e arruamentos. Os equipamentos utilizados foram dois receptores modelo Trimble R6 PP capazes de rastrear simultaneamente sinais L1/L2, L2C e L5 dos sistemas GPS e GLONASS. O equipamento apresenta precisão

136

horizontal de 3mm+0,1ppm em levantamentos L1/L2 estático sendo compatível com a qualidade geométrica esperada para o projeto. O método de posicionamento adotado foi o relativo semicinemático (*stop and go*). Como a área de estudo é extensa, foi necessário, nesse levantamento de campo, utilizar dois marcos de referências. A primeira em uma estação geodésica do IBGE (pontos SAT 96136) localizada em uma escola no município de Silva Jardim, na parte oeste da bacia do rio São João. Além disso foi necessário implantar uma base local na Reserva Biológica de Poço das Antas, no município de Silva Jardim, cuja localização na parte central da bacia auxiliou no levantamento dos dados nos recortes situados na parte central e leste da bacia, cuja distância máxima é de 30 quilômetros.

Dessa forma, durante o levantamento, um equipamento receptor ficou alocado no marco de referência enquanto o outro foi utilizado para a determinação dos pontos planimétricos para a obtenção dos vértices

Como tal atividade era uma novidade para o laboratório de pesquisa, foi realizado um teste antes da execução do campo. O teste correspondeu à um rastreio pelas ruas da Cidade Universitária utilizando alguns procedimentos diferentes para a avaliação. Tais procedimentos envolveram a posição mais adequada da antena durante a movimentação do veículo, assim como sua velocidade e alguns parâmetros de configuração do equipamento, como por exemplo, o tempo de rastreio.

Os resultados do teste foram comparados com uma imagem ortorretificada GeoEye da Cidade Universitária, havendo uma boa aderência entre os dados. Como o objetivo do trabalho era apenas verificar se o procedimento funcionava, não foram anotadas as avaliações geométricas desse teste. De qualquer forma, serviu para estabelecer os procedimentos finais para a atividade de campo. Um exemplo é o posicionamento da antena, no qual ficou decidido que ficaria posicionada na parte central do painel do veículo, tendo em vista que se ficasse presa em uma haste na janela lateral com alguém segurando, haveria problemas nas curvas, sendo o dado coletado nas calçadas. Além disso, optou-se pelo tempo de rastreio de 1 segundo, que apesar de deixar os arquivos grandes, garantiria um melhor traçado com a coleta mais frequente dos vértices. Em campo, foram percorridas as rodovias pavimentadas, de leito natural e arruamentos nas principais áreas urbanas. Também foram percorridas algumas áreas rurais, porém houve trechos com dificuldade de acesso em algumas fazendas. Porém, como as vias internas das propriedades não fazem parte do sistema de transporte, não acarretou em grandes problemas para o desenvolvimento do trabalho. Um aspecto fundamental foi dar preferencia para as vias com maior número de curvas, a fim de avaliar a forma da linha extraída no campo com as linhas extraídas nas imagens.

4. AVALIAÇÃO GEOMÉTRICA E RADIOMÉTRICA DAS IMAGENS

Antes da realização dos procedimentos de extração e classificação das imagens, é importante avaliar a qualidade dos dados a fim de se ter uma noção das características das imagens nas quais está se trabalhando. Qual é a escala que a imagem de um determinado sensor pode atender em termos geométricos? A radiometria atende às respostas espectrais esperadas das classes a serem mapeadas? Para responder a essas questões, são necessários testes de avaliação da qualidade geométrica e radiométrica. Para a avaliação geométrica, serão usadas novas inferências estatísticas, além da tradicional avaliação usando o Padrão de Exatidão Cartográfica (PEC). Para a avaliação radiométrica, serão realizados procedimentos de correção atmosférica, análises comparativas entre as respostas espectrais dos dados originais e corrigidos.

Sendo assim, busca-se por métodos estatísticos detalhados que visam levantar a existência de tendências ou desvios que podem interferir significativamente no padrão de enquadramento especificado. O objetivo é conhecer mais sobre os pontos que são determinantes para se definir quais sensores são adequados para se atingir à exatidão geométrica e radiométrica (temática) esperada para uma dada escala cartográfica. Dessa forma, pretende-se trabalhar nesse capítulo os seguintes objetivos:

- Analisar a exatidão planimétrica de imagens OLI\Landsat-8, AVNIR-2\ALOS e RapidEye com relação ao Padrão de Exatidão Cartográfica (PEC).
- Analisar o cenário de tendência das amostras e estimar padrão de acurácia posicional segundo a metodologia de Viera & Genro (2013)
- Avaliar a qualidade radiométrica das imagens após a aplicação da correção atmosférica.

4.1. AVALIAÇÃO GEOMÉTRICA

4.1.1 Levantamento dos pontos de avaliação

A primeira etapa para o estabelecimento da avaliação da qualidade posicional sobre as imagens foi a realização de um levantamento de campo para determinar as coordenadas dos pontos através do uso de rastreadores de Sistema de Navegação Global por Satélite (GNSS) de uma frequência (L1). Adotou-se o método relativo estático, cujo objetivo consiste em rastrear dados transmitidos pelos satélites com um receptor em um marco geodésico (estação de referência ou base) e outro nos pontos a serem determinados (*rover*), simultaneamente.

Como a á área de estudo é extensa, foi necessário, nesse levantamento de campo, utilizar duas estações geodésicas do IBGE (pontos SAT 96136 e 93948) como implantação da base. A primeira localizada em uma escola no município de Silva Jardim, na parte oeste da bacia do rio São João, e a segunda estação localizada na Reserva Biológica da União, no município de Rio das Ostras, no extremo leste da bacia. Porém, como alguns pontos a serem determinados na parte central da bacia estavam distantes dos dois pontos, foi necessário implantar uma base local na Reserva Biológica de Poço das Antas, no município de Silva Jardim. A figura 4.1 ilustra a localização das estações geodésicas do IBGE, a base local e a distribuição dos pontos. Os círculos representam o entorno de 20 quilômetros das três bases de referência.

Durante o planejamento, foram obtidos pontos opcionais no caso se haver problemas na chegada ao ponto prioritário para a medição. Por isso, a numeração dos pontos para avaliação não seguem uma ordenação sequencial crescente, ou seja, existem pontos com o valor maior que 26, número total de pontos.



Figura. 4.1: Distribuição dos pontos para avaliação das imagens.

Foram obtidos 26 pontos, cuja taxa de aquisição foi de um segundo. O tempo de rastreio foi de 30 minutos para os pontos localizados até 20 quilômetros e de 40 minutos para os pontos localizados entre 20 e 30 quilômetros de distância para a base utilizada. Dessa forma, foi possível realizar uma distribuição homogênea sobre a área de estudo a partir dos pontos coletados.

O planejamento para a coleta de cada ponto envolveu a escolha de lugares onde é possível plotar um ponto de forma mais precisa possível, evitando-se áreas com maior incerteza no seu posicionamento. Por isso, foi dado preferência à cruzamentos de estradas e outras vias de deslocamento, marcando a interseção entre eixos centrais das vias. Em campo, frequentemente não é possível ter acesso aos lugares planejados, principalmente quando se trata de propriedades particulares, por isso, durante o planejamento são escolhidos pontos complementares.

4.1.2 Seleção das imagens

Para esse estudo foram usadas:

- Uma cena OLI\LANDSAT 8, cuja órbita/ponto é 216/076, imagem da banda pancromática, cuja aquisição ocorreu em 08 de abril de 2014.
- Quatro cenas AVNIR-2\ALOS (quadro 4.1) adquiridas no modo 1B2R, sendo ortorretificadas a partir da coleta de coordenadas de ortoimagens do projeto RJ25, disponibilizadas pelo IBGE e usando os dados do modelo digital de elevação SRTM (versão 4) como referência altimétrica para a correção.

Cena	Satélite	Data
ALAV2A219894050	ALOS-2	11/03/2010
ALAV2A188824060	ALOS-2	06/30/2010
ALAV2A229084050	ALOS-2	19/10/2010
ALAV2A193054060	ALOS-2	07/07/2010

Quadro 4.1: Características das cenas AVNIR-2\ ALOS.

• Oito cenas oito RapidEye (quadro 4.2) em modo 3A.

Cena	Satélite	Data
2328525	Tachys	13/08/2011
2328526	Choros	04/12/2012
2328625	Mati	14/08/2011
2328626	Trochia	04/09/2011
2328627	Trochia	24/12/2012
2328725	Mati	16/10/2012
2328726	Trochia	04/09/2011
2328727	Trochia	04/09/2011

Quadro 4.2: Características das cenas RapidEye.

4.1.3. Estimativa da exatidão posicional a partir do PEC

Segundo Vieira *et al.* (2004), a exatidão posicional determina o quão perto a posição dos objetos discretos mostrados em um mapa, imagem retificada ou em um banco de dados espacial está de acordo com a situação real no terreno.

Um método padrão para avaliação da exatidão de posicionamento de produtos cartográficos é baseado na comparação de afastamentos entre os pontos de controle homólogos, localizados em mapeamentos de referência, imagens corrigidas geometricamente e levantamentos de GNSS. Os desvios desses pontos são usados em modelos estatísticos que permitem mensurar a estimava da incerteza, possibilitar o cálculo de erros e analisar tendências, identificar sendo nesse caso а presença de erros sistemáticos (MERCHAND, 1982).

Estudo de Monico *et al.* (2009) esclarece os conceitos envolvidos no processo de controle da qualidade posicional, especificamente esclarecendo os termos de acurácia e precisão. Enfatizando que o primeiro se refere aos efeitos sistemáticos e aleatórios dos erros nas medições, enquanto a precisão apenas incorpora os efeitos aleatórios.

A tabela 4.1 apresenta os valores dos erros médios (PEC) encontrados a partir da comparação entre as coordenadas observadas nas imagens e suas homólogas levantadas em campo. Os valores de CE 90 estão destacados em amarelo e correspondem ao valor limite de 90% das amostras usando como critério a ordenação numérica crescente de todos os valores dos resíduos, ou seja, os valores 10 % mais elevados são descartados. Sendo 26 pontos amostrais, foram descartados os 2 pontos com maiores valores na avaliação de cada sensor.

Considerando o intervalo de confiança a 90%, o valor de exatidão encontrado para a imagem OLI\LANDSAT-8 é de 15,54 metros (CE90), com valor de erro padrão de 3,19. Tais valores, segundo o PEC atenderiam ao especificado para a escala 1:25.000, classe B. Em relação ao AVNIR-2\ ALOS, o valor do PEC encontrado foi de 16,06 (CE90) e erro padrão de 3,66, ou seja, assim como o OLI\LANDSAT-8 atenderia à escala 1:25.000, classe B. Já o

RapidEye apresentou o valor de exatidão igual a 7,53 e erro padrão de 2,7, possibilitando especificá-lo na escala 1:10.000, classe B.

	PEC	PEC	PEC
Ponto	LANDSAT-8	AVNIR	Rapideye
3	15,54	16,06	5,31
5	5,36	11,91	15,02
6	8,30	6,39	7,09
12	17,88	5,48	3,65
15	7,76	12,38	1,09
16	15,65	9,84	6,36
23	5,56	19,38	2,13
24	7,32	17,62	3,11
26	13,23	10,18	2,52
30	8,04	15,09	3,55
34	5,33	8,05	4,04
37	8,86	9,70	7,53
38	10,93	9,70	4,41
41	5,94	12,95	2,70
43	10,02	8,57	7,59
45	11,13	6,96	4,82
46	9,73	13,42	6,32
47	10,80	11,69	5,39
49	9,00	5,67	2,77
51	10,86	14,14	2,58
52	10,58	8,64	5,17
53	9,62	14,39	4,40
54	8,44	11,10	7,14
56	12,00	8,52	4,04
58	8,23	15,28	4,89
62	12,24	10,39	4,41

Tabela 4.1: Valores de erro das imagens avaliadas, segundo o PEC.

4.1.4 Análise de Tendência

O método aplicado aqui, proposto por Vieira & Genro (2013), indica uma forma de estimar a acurácia independente da existência de tendência relevante, baseando-se em estudos de Merchand (1982), Galo & Camargo (1994) e Congalton & Green (2009).

A escolha pelo uso da análise t-Student ajuda na discussão sobre a possibilidade de utilização de inferências estatísticas que aprimorem a avaliação de dados cartográficos digitais, cenário diferente quando houve a regulamentação do PEC como critério oficial. Os fundamentos estatísticos aplicados são baseados no Padrão de Exatidão Cartográfica (PEC), considerando 90% de probabilidade para diferentes classes, e como inferência estatística a distribuição t-Student, enfatizando-se que os valores de acurácia dependem, preponderantemente, do método de amostragem. Ressalta-se ainda, de acordo com Vieira & Genro (2013), que este método é válido para amostras maiores que 20 pontos. A estimativa do padrão de acurácia posicional é realizada, desta forma, através da distribuição t-Student, em um intervalo de confiança a 90% (0,1), com valor central correspondente ao erro médio quadrático dos erros (EMQ) obtidos nas amostras. Para a planimetria, pode-se aplicar tanto para a resultante (conforme o estabelecido na legislação) quanto para as componentes X e Y (no caso, coordenadas E e N), de modo a permitir o diagnóstico de diferentes problemas. A tabela 4.2 apresenta as fórmulas para a obtenção da estimativa do erro médio quadrático (EMQ) e a análise de tendência.

$EMQ_{\Delta X} = \sqrt{\frac{(\sum_{i=1}^{N} \Delta X_i^2)}{N}}$			
EI	$MQ_{\Delta P} = \sqrt{EMQ_{\Delta E}^2 + EMQ_{\Delta N}^2}$		
	$S_{EMQ_{\Delta X}} = \sqrt{\left[\frac{\sum_{i=1}^{N} (\Delta X _i - EMQ_{\Delta X})^2}{N-1}\right]}$		
Estimativa do desvio- padrão da população de erros	$S_{EMQ_{\Delta P}}^{2} = \left(\frac{EMQ_{\Delta N}}{\sqrt{EMQ_{\Delta N}^{2} + EMQ_{\Delta E}^{2}}}\right)^{2} \cdot S_{EMQ_{\Delta N}}^{2}$		
	$+ \left(\frac{EMQ_{\Delta N}}{\sqrt{EMQ_{\Delta N}^2 + EMQ_{\Delta E}^2}}\right)^2 \cdot S_{EMQ_{\Delta E}}^2$		
Intervalos de	$t_{90\% N-1}$ (bicaudal)		
confiança da acurácia			
estimada da população de erros	$EMQ_{\Delta X} \pm t_{90\%,N-1}(S_{EMQ_{\Delta X}})$		
acurácia estimada da população a partir do erro máximo provável	$EMQ_{\Delta x} + t^{\theta}_{90\%,N-1}(S_{EMQ_{\Delta X}})$		
	ANÁLISE DE TENDÊNCIA		
Estimativa do desvio- padrão da população de resíduos	$S_{\Delta \bar{X}} = \sqrt{\frac{\sum_{i=1}^{N} (\Delta X_i - \Delta \bar{X})^2}{N-1}}$		
Estimativa da média da população de resíduos	$\Delta \bar{X} = \frac{(\sum_{i=1}^{N} \Delta X)}{N}$		
Estatística t	$t_{90\%,N-1}$ (bicaudal) $t_{amostral} = (\Delta \overline{X}/S)\sqrt{N}$		

Tabela 4.2: Fórmulas para a Estimativa do EMQ e análise de tendência.

ESTIMATIVA DE ERRO MÉDIO QUADRÁTICO DA POPULAÇÃO DE ERROS

A tabela 4.3 apresenta as inferências estatísticas relativas aos cálculos efetuados para a geração do EMQ das componentes e da resultante planimétrica para os 26 pontos amostrais coletados em campo.

ESTIMATIVA DO ERRO MÉDIO QUADRÁTICO DA POPULAÇÃO DE ERROS				
	EMQ _{ΔN}	EMQ _{ΔE}	ΕΜQ ΔΡ	
OLI	8,73	5,69	10,42	
AVNIR-2	7,73	8,97	11,85	
RapiEye	3,44	4,41	5,59	
EST	IMATIVA DO DESVIO PADRÃO DA PO	DPULAÇÃO DE ER	ROS	
	$S \text{ Emq}_{an}$	$S \text{ Emq}_{\text{Ae}}$	$S \text{ emq}_{\text{AP}}$	
OLI	3,51	3,71	3,57	
AVNIR-2	4,43	5,18	4,88	
RapiEye	1,5	3,31	2,77	
INTERVALO	DS DE CONFIANÇA DA ACURÁCIA EST	TIMADA DA POP	ULAÇÃO DE	
	ERROS		• /. •	
	T-student tabulado	Precisão pl	animétrica	
	1,/1	10,42	± 6,08	
AVNIR-2	1,/1	11,85	± 8,32	
RapiEye	RapiEye 1,71 5,59 ± 4,72			
ACURACIA ES		DO ERRO MAXIN	10 PROVAVEL	
	I-student acumulada			
	1,31			
AVNIR-2	1,31	75,95		
каріЕуе		20,	36	
	ANALISE DE TENDENC	JA Jacão do recíduo		
	Estimativa do desvio padrão da popu	liação de residuo	os	
	S _{AN}	S DE	S _{AP}	
OLI	4,38	5,68	3,19	
AVNIR-2	6,82	8,25	3,66	
RapiEye	3,44	3,85	2,7	
	Estimativa da média da populaçã	io de resíduos		
	ΔΝ	ΔE	ΔΡ	
OLI	7,6	-1,17 9,94		
		,	0,0	
AVINIK-Z	-3,88	-3,88	11,29	
RapiEye	-3,88 0,66	-3,88 -2,29	11,29 4,92	
RapiEye	-3,88 0,66 Estatístca t	-3,88 -2,29	11,29 4,92	
RapiEye	-3,88 0,66 Estatístca t N	-3,88 -2,29	11,29 4,92	
Avnik-2 RapiEye OLI	-3,88 0,66 Estatístca t N 9,5	-3,88 -2,29	11,29 4,92 12	
AVNIR-2 RapiEye OLI AVNIR-2	-3,88 0,66 Estatístca t N 9,5 -3,12	-3,88 -2,29 [11,29 4,92 12 57	

Tabela 4.3: Inferências estatísticas das imagens avaliadas.

Pelos valores observados, a imagem OLI\LANDSAT-8 avaliada atende, em termos de exatidão geométrica, ao especificado para a escala 1:50.000, classe C. Já a imagem AVNIR-2\ ALOS atenderia a escala 1:100.000 classe B, enquanto a RapidEye atenderia ao mapeamento 1:25.000 classe C, porém bem próximo do limite da classe B, tendo em vista que o limite entre essas duas classes é de 20 metros. Em termos de tendência, nota-se que existe uma tendência forte para Norte na imagem OLI\LANDSAT-8 e uma tendência moderada para leste na imagem Rapideye e para sul na imagem AVNIR-2\ ALOS.

4.1.5 Resultados da avaliação geométrica

Nota-se que os resultados obtidos mostram variações significativas quando se realiza as análises estatísticas baseadas no PEC e as inferências sugeridas pela metodologia de Vieira & Genro (2013). Ressalta-se que os resultados da avaliação das imagens apresentaram valores dentro do esperado, com exceção da avaliação do AVNIR-2\ ALOS a partir das inferências estatísticas propostas por Vieira & Genro (2013), no qual se esperava uma classificação dentro da escala 1:100.000, classe A. A avaliação da exatidão planimétrica em imagens de sensoriamento remoto é de fundamental importância para o controle da qualidade de bases cartográficas de georreferenciamento ocasionam produtos de qualidade inadequada. De certa forma, todos os produtos obtidos através de classificação e interpretação tendem a apresentam erros superiores ou, no mínimo iguais ao insumo utilizado, no caso uma imagem orbital.

A tabela 4.4 mostra uma síntese das avaliações geométricas das imagens dos três sensores associado à cada escala cartográfica.

148

	Método de avaliação			
Sensor	PEC	Inferência (Vieira & Genro, 2013)		
OLI/Landsat-8	1:25.000 classe B	1:50.000 classe C		
AVNIR-2/ALOS	1:25.000 classe B	1:100.000 classe B		
RapidEye	1:10.000 classe C	1:25.000 classe C		

Tabela 4.4: Comparação da avaliação posicional entre os métodos.

4.2 AVALIAÇÃO RADIOMÉTRICA

4.2.1 Correção atmosférica

Para o tratamento de imagens oriundas de sensores remotos, principalmente de sensores orbitais, é importante considerar os efeitos da atmosfera e as significativas alterações no fluxo radiante proveniente dos alvos na imagem gerada. A diminuição dos valores digitais registrados e do contraste entre superfícies adjacentes, bem como alteração do brilho dos pixels são os principais efeitos observados. O espalhamento e a absorção são os processos físicos resultantes da interação entre atmosfera e fluxo. A combinação destes dois efeitos é conhecida por atenuação atmosférica.

A absorção atmosférica é um fenômeno termodinâmico que resulta na perda efetiva de energia para os constituintes atmosféricos em determinados comprimentos de onda. Os principais constituintes atmosféricos que absorvem radiação no espectro solar, além dos aerossóis e das nuvens, são principalmente, o vapor d'água, dióxido de carbono e ozônio (RICHARDS e JIA, 2006).

No entanto, é importante mencionar que as maiores distorções radiométricas ocorrem por meio do espalhamento, ao se considerar os diferentes elementos espalhadores e o respectivo comprimento de onda da radiação. Nesse processo, é possível identificar dois mecanismos básicos, o espalhamento seletivo e o espalhamento não seletivo. No primeiro caso, o raio das partículas é menor ou da mesma ordem de grandeza do comprimento de onda da radiação incidente. Pode-se citar, como exemplo, o do tipo molecular, também denominado Rayleight, que é inversamente proporcional à quarta potência do comprimento de onda da radiação, afetando pequenos comprimentos de onda da região espectral do visível. O espalhamento Rayleight ocorre quando a radiação interage com moléculas atmosféricas e outros tipos de partículas que possuem raio menor que o comprimento de onda da radiação incidente. Outro exemplo desse tipo de espalhamento é o denominado Mie, resultante do espalhamento da radiação por partículas maiores, que tem o tamanho aproximadamente igual ao do comprimento de onda da energia (identificada pelo sensor), sendo formada por partículas como fumaça, névoa ou poeira (RICHARDS e JIA, 2006).

O espalhamento não seletivo ocorre quando os raios das partículas que causam espalhamento são muito maiores do que o comprimento de onda da radiação incidente. Estas partículas têm normalmente diâmetros que variam de 5 µm a 100 µm (ex: nuvens) (LILLESAND e KIEFER, 2004). Os modelos para correção dos efeitos atmosféricos, geralmente incorporam o tratamento dos efeitos causados pelo espalhamento seletivo do tipo Rayleigh (molecular) e pelo espalhamento seletivo Mie (aerossóis). É importante destacar que o processo de correção atmosférica busca atenuar os efeitos atmosféricos por meio do aproveitamento de janelas nas quais a radiação registrada pelo sensor apresenta altos valores de transmitância com baixa influência atmosférica. Resumidamente, a execução da correção atmosférica em imagens de sensoriamento remoto possibilita o ajuste dos efeitos de absorção e espalhamento causados pela presença de gases e aerossóis na atmosfera, que afeta o sinal do sensor e influenciam as respostas espectrais observadas. Ela pode ser executada a partir de duas metodologias distintas:

- A partir de modelos de transferência radiativa (Moderate Resolution Atmospheric Transmission - MOTRAN), sendo esse mais eficiente, e com exigência de conhecimentos sobre as condições atmosféricas da área de estudo onde a cena foi gerada, bem como de alguns dados do sensor. Também é necessário conhecer alguns dados sobre a calibração radiométrica do sensor.
- Uso de algoritmos empíricos. Esse método exige apenas a aplicação de cálculos com base nos níveis de cinza disponíveis nas próprias bandas, tendo como base, por exemplo, as técnicas de subtração por pixel escuro.

Nesse estudo, optou-se pelo uso do modelo ATCOR (*Atmospheric and Topographic Correction for Satellite Imagery*) e FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercube*). Ambas as técnicas usam o modelo de transferência radiativa do tipo MODTRAN., cuja correção dos efeitos atmosféricos é feita através da equação 4.1 (ANDERSON, *et al.*, 1999):

$$L = \left(\frac{A\rho}{1-\rho_e S}\right) + \left(\frac{B\rho_e}{1-\rho_e S}\right) + L_a \quad \text{Equação 4.1}$$

Onde:

L = radiância no sensor

 ρ = reflectância de superfície do pixel

 ρ_e = média da reflectância de superfície do pixel e vizinhos.

s = albedo esférico da atmosfera

 L_a = radiância retroespalhada da atmosfera

 $A \in B$ = parâmetros que dependem das condições atmosféricas e da geometria de iluminação.

4.2.2 Características das cenas e parametrização

Os programas *Erdas Imagine* 2014 e *PCI Geomatica* 2014 podem incorporar o módulo ATCOR versão2, enquanto o software ENVI 5.2 possui o módulo FLAASH como função para correção atmosférica de imagens. Em todos os casos é necessário converter os valores de níveis de cinza da imagem para radiância espectral.

Ao iniciar o processo de correção atmosférica, é necessário informar alguns parâmetros dos sensores e de iluminação, obtidos através dos metadados. A tabela 4.5 mostra algumas dessas características das cenas RapidEye.

	7ônite			Sensor
Cena	Solar	Azimute solar	Azimute	Ângulo de incidência
2328525	50.95	17.75	97.62	14.8
2328526	79.86	89.84	278.97	930
2328625	51.49	17.76	97.66	16.08
2328626	56.96	27.65	280.02	24.66
2328627	78.18	96.77	278.58	7.37
2328725	75.61	25.00	97.78	14.57
2328726	57.14	27.83	280.05	25.51
2328727	57.25	27.45	279.84	23.16

Tabela 4.5: Parâmetros dos sensores e de iluminação das cenas RapidEye.

A tabela 4.6 mostra as características dos sensores e da iluminação das cenas AVNIR-2.\ALOS.

Tabela 4.6: Parâmetros dos sensores e de iluminação das cenas AVNIR-2.

	7ênite			Sensor
Cena	Solar	Azimute solar	Azimute	Ângulo de incidência
ALAV2A219894050	61.25	80.62	-	0
ALAV2A188824060	37.02	43.49	-	0
ALAV2A229084050	42.52	32.64	-	0
ALAV2A193054060	52.54	43.73	-	0

A tabela 4.7 mostra as características dos sensores e da iluminação da cena OLI\LANDSAT-8.

Tabela 4.7: Parâmetros dos sensores e de iluminação da cena OLI

Zânite			Sensor	
Cena	Solar	Azimute solar	Azimute	Ângulo de incidência
216/076	47,27	48,53	-	0

Além dos parâmetros do sensor, foram definidas também as informações de localização de cada cena, conforme mostra a tabela 4.8.

Satélite	Cena	Centroide (long/lat)	Elevação média
Rapideye	2328525	-42,5606 /-22,8548	50
Rapideye	2328526	-42,3101 / -22,8565	5
Rapideye	2328625	-42,5482 / -22,6634	100
Rapideye	2328626	-42,3092 / -22,657	50
Rapideye	2328627	-42,0794 /-22,6414	5
Rapideye	2328725	-42,5589 / -22,4442	250
Rapideye	2328726	-42,341 / -22,4343	200
Rapideye	2328727	-42,068 / -22,4302	100
AVNIR-2	ALAV2A219894050	-41,935 / - 22,395	250
AVNIR-2	ALAV2A188824060	-42,604 / -22,89	100
AVNIR-2	ALAV2A229084050	-42,473 / - 22,018	200
AVNIR-2	ALAV2A193054060	-42,063 / -22,887	5
OLI	216/076	-41,021 / -23,085	150

Tabela 4.8: Informações de localização.

O modelo atmosférico escolhido para todas as cenas foi o tropical e o modelo de aerossol foi o rural. Além dessas informações, foi usado o valor de 40 Km para visibilidade como padrão.

4.2.3 Resultados da avaliação radiométrica das imagens RapidEye

Para uma avaliação da qualidade radiométrica, foram coletadas nas oito cenas, originais e corrigidas, amostras de classes representativas da área de estudo: Floresta, água de canais fluviais e solo exposto. Para cada ponto amostral foi calculada a média de uma matriz de 3 x3 pixels (valor do pixel central e seus respectivos 8 pixels vizinhos).

Para cada cena foram coletadas duas amostras de cada classe, totalizando 16 amostras para cada classe. Para cada banda espectral obtevese a média de todas as amostras e elaborando-se um gráfico que ilustra a reflectância de cada classe.

A figura 4.2 ilustra a reflectância das imagens corrigidas RapidEye da classe floresta considerando os resultados gerados nos três softwares testados: ATCOR / Erdas, ATCOR / PCI e Envi.

Os resultados mostram mudanças significativas na curva espectral quando se realiza a correção atmosférica nos três algoritmos. O gráfico

compara os valores da imagem original (linha azul clara) com as imagens corrigidas.



Floresta - RapidEye

Figura. 4.2: Comparação entre reflectâncias de floresta para as imagens Rapideye.

Nos algoritmos testados houve uma redução na reflectância das bandas da faixa do visível, principalmente na banda do azul. De uma forma geral as curvas apresentam semelhanças no ATCOR (*Erdas* representada pela linha verde e PCI representada pela linha laranja). A exceção é a resposta espectral da imagem corrigida no ENVI (linha roxa) nas bandas do infravermelho e Rededge, onde houve um acréscimo bastante elevado nos valores de reflectância.

A figura 4.3 ilustra a resposta espectral referente à classe solo exposto, considerando os resultados gerados nos três softwares testados. Nota-se uma mudança brusca no comportamento das curvas. Houve uma diminuição nítida de contraste nas bandas do azul e verde e o processo inverso nas bandas do infravermelho e red-edge. Novamente a imagem corrigida no ENVI apresentou variações maiores em relação às imagens corrigidas nos outros dois softwares, principalmente se for considerado o infravermelho próximo.


Figura. 4.3: Comparação entre as reflectâncias de solo exposto para as imagens Rapideye.

Por fim, foi realizada uma avaliação das curvas espectrais para água (figura 4.4), sendo coletadas amostras apenas em ambientes fluviais. Por conta da dinâmica espacial e temporal do aporte de sedimentos nos rios, as curvas apresentam características distintas em função da quantidade de sedimentos presentes. Além disso, vale destacar que, em algumas imagens, muitos rios possuem uma largura estreita, podendo haver pixels com influência das margens. De qualquer forma há de se destaca uma mudança no comportamento espectral em relação à imagem original e as semelhanças entre as curvas das imagens produzidas nos dois módulos do ATCOR (*Erdas e PCI*).



Figura. 4.4: Comparação entre as reflectâncias de água em canais fluviais para as imagens Rapideye.

O resultado da correção está ilustrado na figura 4.5 que representa a cena 2328725. Percebe-se visualmente as diferenças entre a imagem original e a imagem corrigida no ATCOR / *Erdas*. Cabe ressaltar que o módulo do ARTCOR do *Erdas* e PCI apresentam resultados semelhantes.



Figura 4.5: Comparação entre a imagem original (a) e a imagem corrigida (b). Composição colorida 3R2G1B.

4.2.4 Resultados da avaliação radiométrica das imagens AVNIR-2\ALOS

A figura 4.6 mostra os percentuais de reflectância das imagens corrigidas AVNIR-2\ALOS da classe floresta considerando os resultados gerados nos três softwares testados: ATCOR / Erdas, ATCOR / PCI e Envi.

Assim como observado na correção das imagens RapiEye, os resultados da correção atmosférica das imagens AVNIR-2\ALOS mostram mudanças significativas na curva espectral quando se realiza a correção atmosférica nos três algoritmos. O gráfico ilustrado na figura 4.6 compara os valores da imagem original (linha pontilhada) com as imagens corrigidas (linhas contínuas).



Figura 4.6: Comparação entre reflectâncias de floresta para as imagens AVNIR-2/ALOS

No comprimento de onda do azul, houve uma redução da reflectância usando os três softwares, havendo uma elevação significativa no comprimento de onda do verde. O comportamento dos gráficos é semelhante nas imagens processadas nos três softwares, mas no ATCOR PCI há uma discrepância significativa em relação aos valores de reflectância observados no ENVI e ATCOR ERDAS.

A figura 4.7 mostra a resposta espectral referente à classe solo exposto, considerando os resultados gerados nos três softwares testados.

Nota-se que nas imagens corrigidas no ATCOR do PCI, a curva espectral apresentou uma diferença significativa em relação às outras curvas, no qual há um aumento bastante acentuado dos valores de reflectância das imagens. Enquanto na imagem original, há um decréscimo dos valores com o aumento da faixa espectral, nas imagens corrigidas ocorre o inverso, ou seja, na medida em que aumenta o comprimento de onda, há um acréscimo dos valores de reflectância.



Figura. 4.7: Comparação entre as reflectâncias de solo exposto para as imagens AVNIR-2/ALOS

A massa d'água foi a última classe analisada do AVNIR-2\ALOS. A figura 4.8 ilustra o comportamento espectral das imagens corrigidas. Assim como foi observado no solo exposto, há uma discrepância significativa das imagens corrigidas no ATCOR PCI. Já a curva da imagem corrigida no ATCOR do *Erdas* apresentou uma semelhança considerável em relação à imagem original.



Figura. 4.8: Comparação entre as reflectâncias de água em canais fluviais para as imagens AVNIR-2/ALOS

O resultado da correção está ilustrado na figura 4.9 que representa a cena ALAV2A193054060. Percebe-se visualmente as diferenças entre a imagem original e a imagem corrigida no ATCOR / *Erdas*. Cabe ressaltar que, diferentemente da correção nas imagens RapidEye, o módulo do ARTCOR do *Erdas* e PCI apresentaram resultados bastante distintos.



Figura 4.9: Comparação entre a imagem original (a) e a imagem corrigida (b). Composição colorida 3R2G1B.

4.2.5 Resultados da avaliação radiométrica das imagens OLI\LANDSAT-8

A figura 4.10 mostra as porcentagens de reflectância da imagem corrigida OLI/LANDSAT-8 da classe floresta considerando os resultados gerados no três softwares testados: ATCOR / *Erdas*, ATCOR / PCI e Envi.





Assim como foi observado nas imagens dos outros dois sensores, nos algoritmos testados nas imagens OLI houve uma redução na reflectância nas bandas da faixa do visível. De uma forma geral, as curvas apresentam semelhanças no ATCOR nessa faixa espectral, mas na faixa infravermelho ocorrem as maiores diferenças entre as imagens corrigidas nos três softwares. No Envi e no ATCOR do PCI os valores de reflectância aumentam significativamente, enquanto no ATCOR do *Erdas* há um aumento menos significativo.

A figura 4.11 mostra a reflectância referente à classe solo exposto para a imagem OLI\LANDSAT-8, considerando os resultados gerados nos três softwares testados. Nota-se que a curva espectral das imagens corrigidas no ATCOR do *Erdas* segue um mesmo padrão quando comparada com as curvas espectrais do solo exposto das imagens corrigidas do RapidEye e AVNIR - 2\ALOS. Ou seja, a curva tende a apresentar maiores valores com o aumento do comprimento espectral até o infravermelho distante, quando há um decréscimo.



Figura. 4.11: Comparação entre as reflectâncias de solo exposto para as imagens OLI.

A figura 4.12 mostra a avaliação das curvas espectrais para água, sendo coletadas amostras apenas em ambientes fluviais. Nota-se que os resultados foram bem distintos nos três softwares testados. Destacam-se as variações no infravermelho próximo encontradas para o ATCOR PCI e ENVI.

Os valores divergentes podem ser atribuídos a diferentes fatores, como por exemplo, os algoritmos específicos de cada software para tratar os valores radiométricos da imagem. No caso da água, essas diferenças tendem a ser mais acentudas em virtude das variações espectrais dos corpos hídricos, já que são influenciados pela presença de sedimentos presentes.



Figura. 4.12: Comparação entre as reflectâncias de água em canais fluviais para as imagens OLI.

O resultado da correção está ilustrado na figura 4.13 que representa a cena 216/076. Percebe-se visualmente as diferenças de brilho entre a imagem original e a imagem corrigida no ATCOR / *Erdas*. Assim como foi observado nas imagens AVNIR-2\ALOS, os módulos do ATCOR do *Erdas* e PCI apresentaram resultados bastante distintos.



Figura 4.13: Comparação entre a imagem original (a) e a imagem corrigida (b). Composição colorida 4R3G2B.

4.2.6 Análise final dos resultados da correção radiométrica

Em termos radiométricos, para classificação de feições cartográficas, é fundamental o ajuste a uma curva espectral mais adequada, mesmo considerando o fato de que usa bibliotecas espectrais especificas de outros ambientes climáticos. De qualquer forma, o procedimento de correção atmosférica é fundamental, tendo em vista que os valores dos pixels nas imagens originais nesse estudo não retratam um cenário mais adequado. A interferência de gases e aerossóis influi de forma significativa ao se usar procedimentos automáticos de extração dos valores.

Por isso, para a avaliação das imagens corrigidas, foi feita a comparação entre as respostas espectrais esperadas com as bibliotecas espectrais disponíveis na literatura. (JENSEN, 2009)

Os resultados gerados apresentaram diferenças entre classes e entre sensores. Para a floresta, houve uma tendência de resultados mais satisfatórios para a correção no ENVI para os três sensores. Para o solo exposto, nenhum software teve maior destaque nesta classe, ficando cada software satisfatório para um determinado sensor. Enquanto que para a água apresentou resultados menos satisfatórios dentre as três classes.

As curvas espectrais das imagens corrigidas no módulo FLAASH do *Envi*, de uma maneira geral, apresentaram comportamentos mais próximos com a média esperada para cada classe. Por isso, foram utilizadas as imagens corrigidas no algoritmo de ENVI para os processos de extração e classificação das imagens nos três sensores.

De qualquer forma, ressalta-se a necessidade de estudos mais detalhados que testem as variações dos modelos atmosférico, de aerossóis e da visibilidade a fim de analisar resultados diferentes.

Para finalizar, esse estudo tentou mostrar a importância da preparação das imagens para atingir bons níveis de qualidade da exatidão temática, cujos resultados podem estar também associados à falta de adequação geométrica e principalmente radiométrica das imagens.

5. INDICADOR DE DETECÇÃO

Um estudo metodológico do IBGE (2011b) descreveu a avaliação da qualidade das imagens ortorretificadas do sensor AVNIR-2 em termos de exatidão cartográfica, indicando que as imagens usadas no trabalho são compatíveis com a escala 1:50.000 do ponto de vista posicional. Porém, o trabalho ressalta que a resolução de 10 metros não favorece a interpretação de elementos nessa escala, tendo em vista que não é possível distinguir, visualmente ou automaticamente, todas as feições cartográficas apropriadas para esta escala. Ou seja, a sua resolução espacial, bem como as demais resoluções, limita o processo de interpretação.

È importante destacar essas comparações, uma vez que as imagens de um sensor podem atender ao rigor da exatidão posicional em uma determinada escala, mas não possibilitar uma extração e classificação adequadas, em virtude da falta de detalhamento dos objetos, ocasionado pela limitação das resoluções do sensor.

Nesse estudo, pretende-se associar os tradicionais critérios de avaliação de qualidade do dado cartográfico com as diferentes exigências para uma boa interpretação. No caso da exatidão posicional, por exemplo, existem normas que estabelecem valores para avaliar a qualidade do dado, como o Padrão de Exatidão Cartográfica (PEC), referência para classificar a qualidade de um produto cartográfico de acordo com sua exatidão posicional. Para que um produto digital possa ser aceito como produto de referência do Sistema Cartográfico Nacional, noventa por cento dos erros dos pontos coletados no produto cartográfico, quando comparados com as suas coordenadas levantadas em campo por método de alta precisão, devem apresentar os valores iguais ou inferiores aos previstos no PEC, devendo ainda apresentar os valores de erro padrão também iguais ou inferiores.

Porém, em termos de interpretação de imagens, como mensurar o grau de interpretabilidade para atender à extração e classificação de feições? Há a possibilidade de classificar imagens de diferentes sensores de acordo com o seu potencial de interpretação? Para tentar obter as respostas destas questões, propõe-se fazer uma associação com os critérios de qualidade do dado geoespacial, mencionados no capítulo 2.

167

Assim como é possível quantificar os erros de posicionamento e de classificação, é viável estabelecer critérios quantitativos para se conhecer os erros envolvidos no processo de interpretação, cuja magnitude interfere diretamente na qualidade do dado, ou seja, integrar os métodos de avaliação de forma que se crie um método síntese para avaliar a interpretabilidade. Dentre os cinco critérios estabelecidos pela norma ISO 19113, foram selecionados três que estão mais diretamente associados à questão da interpretação em imagens: a completude e as exatidões posicional e temática. Poderia ser incluída a exatidão temporal, que representaria o quarto critério, cuja contribuição para essa avaliação envolveria a questão da sazonalidade dos dados. Para a extração de áreas de inundação, por exemplo, seria fundamental a interpretação de imagens adquiridas em épocas úmidas e compará-las com as imagens referentes aos períodos secos. Outra abordagem relativa à resolução temporal se refere à validade no intervalo de tempo entre os dados analisados. Esse estudo não avalia essa situação, mas de gualguer forma, é uma proposta que pode ser refletida para trabalhos futuros.

Esse estudo parte do pressuposto de que para se estabelecer uma avaliação da interpretabilidade, não basta apenas relacionar o conceito com a resolução espacial. Durante 0 processo de interpretação, diversas características dos dados produzidos são afetadas pela influência das resoluções espacial, espectral ou radiométrica. Por isso, a proposta de um índice de interpretabilidade deve envolver tarefas que possam testar as capacidades do sensor, através de parametrizações que lidam com suas resoluções. Isso envolve, por exemplo, os testes com diferentes bandas espectrais de um mesmo equipamento e a comparação entre imagens com diferentes resoluções espaciais e radiométricas.

Os testes permitem a produção de dados com o mínimo de erros ligados às questões operacionais, de forma que se possa apenas avaliar os erros gerados pelas próprias limitações do sensor. Essas questões envolvem a completude (ausência e excesso de dados) e as exatidões temática e posicional, consideradas fundamentais para a avaliação da interpretação.

Dessa forma, em todos os tipos de feições, sejam lineares ou poligonais, deve-se considerar se o dado está integralmente representado, se o posicionamento está mais próximo do ideal, se a forma representa de modo

168

satisfatório a delimitação do objeto e se houve uma boa quantidade de elementos extraídos, seja através de uma contagem do número de objetos ou em termos de extensão. Além dessas características, também é importante avaliar a segmentação, processo inicial da produção dos dados, de forma que se possa estabelecer um método de controle da qualidade das delimitações dos objetos. Isso permite ao intérprete saber se as delimitações dos segmentos estão próximas do que se considera como ideal ou não. Em caso afirmativo, continuar-se-ia a fase de extração e classificação, em caso negativo, retornar-se-ia aos testes de segmentação até atingir o resultado mais satisfatório. Vale destacar que mesmo optando-se pelo uso de métodos automáticos para a extração dos dados, em algumas situações, a análise visual será abordada, principalmente no que se refere ao processo de inspeção e geração das feições lineares, no qual foi escolhido um método de vetorização semiautomático.

Por isso, para se estabelecer o Indicador de Detecção (IDET), optou-se por desmembrá-lo em parâmetros de qualidade para avaliação de feições lineares e poligonais, considerando as diferentes abordagens para o controle da delimitação dos objetos. Para se avaliar a qualidade da detecção foram estabelecidos os seguintes parâmetros:

- Qualidade da Segmentação (QS);
- Qualidade da Detecção das Extensões (QDE);
- Qualidade da Detecção dos Objetos (QDO);
- Qualidade da Forma (QF);
- Qualidade Posicional (QP).

Para cada parâmetro de qualidade, será estabelecido um valor numérico, com intervalo entre zero e um, cuja associação permitirá obter o Indicador de Detecção, cujo objetivo é mensurar o potencial de extração nas imagens de um determinado sensor.

Na maioria dos parâmetros de qualidade, houve a necessidade de normalização dos dados para efetivar a comparação, porém vale destacar que a normalização por mínimo e máximo é aplicável para o conjunto de dados que está sendo utilizado e a introdução de dados que fogem das características previstas pode gerar deformações nas análises. Por isso, sugere-se para novos estudos a reflexão do uso de outras formas de normalização.

5.1 CONSTRUÇÃO DO INDICADOR DE DETECÇÃO

5.1.1 Qualidade da segmentação (QS)

O primeiro parâmetro para avaliar a detecção dos elementos, constitui o critério para analisar o início da extração das feições cartográficas denominado de Qualidade da Segmentação. Conforme mencionado anteriormente, propõese desse estudo a utilização algoritmos de segmentação baseados em similaridades e descontinuidades, cujos resultados são produtos que representam segmentos expressos através de áreas.

Para avaliar a qualidade das segmentações das duas abordagens (similaridade e descontinuidade) foi utilizada a metodologia testada por Espíndola (2006). A proposta da autora é combinar dois indicadores: um que possa expressar o grau de homogeneidade interna dos segmentos e outro que estabeleça a separabilidade entre segmentos vizinhos.

Para se mensurar o nível de homogeneidade entre os pixels de um determinado segmento, propõe-se usar o que a autora denomina de Índice de Homogeneidade Interna (neste estudo será denominado de Qualidade de Homogeniedade Interna – QHI), calculado a partir da equação 5.1, onde v_i é a variância dos níveis de cinza dos pixels de uma região segmentada e a_i é a área dessa região.

$$QHI = rac{\sum_{i=1}^{n} \mathbf{a}_i \cdot v_i}{\sum_{i=1}^{n} \mathbf{a}_i}$$
 Equação 5.1

O valor de QHI mensura a variância média de todas as regiões resultantes do processo de segmentação de forma ponderada, cujo peso é dado pela área da região segmentada. Dessa forma, as áreas pequenas, principalmente as que apresentam valores distorcidos, acarretarão menos instabilidades no valor da QHI.

Sendo assim, o que a autora denomina de QHI é o retrato da variância média para cada resultado de segmentação. Valores de variância média baixos representam maior homogeneidade dos pixels, ou seja, bons resultados.

Porém, a autora destaca que uma boa segmentação não é traduzida apenas pela homogeneidade dos pixels internos, mas também pela heterogeneidade dos pixels entre regiões vizinhas. Para isso, Espindola (2006) estabelece o Índice de Separabilidade entre Segmentos Vizinhos (neste estudo denominado de Qualidade de Separabilidade entre Segmentos Vizinhos -QSSV), cujo objetivo é comparar o conjunto de pixels de uma determinada região com o seu vizinho. Para se atingir esse índice, propõe-se o uso do método de autocorrelação espacial, parâmetro estatístico que mede a correlação de uma variável de um determinado local em relação à sua vizinhança, cujos valores variam de -1 a 1. Valores próximos de zero, indicam a inexistência de autocorrelação espacial significativa entre os valores dos objetos e seus vizinhos. Valores positivos para o índice indicam autocorrelação espacial positiva, ou seja, o valor do atributo de um objeto tende a ser semelhante aos valores dos seus vizinhos. Valores negativos para o índice, por sua vez, indicam autocorrelação negativa (SANTOS & SOUZA, 2007). Os valores próximos a zero são desejáveis para o QSSV, já que refletem a pouca ou inexistente correlação.

A QSSV proposta é equivalente ao Índice Global de Moran, tipo de autocorrelação espacial onde os valores medidos (média dos valores de nível de cinza dos pixels das regiões) não são constantes em todas as áreas da imagem. O uso do teste de Moran pressupõe que o conjunto de dados analisado é estacionário, ou seja, a média do processo medido não varia ao longo da área de estudo. Na equação 5.2 (SANTOS & SOUZA, 2007), *n* é o número de áreas; z_i é o valor do atributo considerado na área i; \overline{z} é o valor médio do atributo na região de estudo; VAR corresponde à variância das taxas; e w_{ij} são os elementos da matriz de proximidade espacial normalizada.

$$QSSV = \frac{1}{\sum \sum_{i=1}^{n} w_{ij}} X \frac{\sum_{i=1}^{n} \sum_{i=1}^{n} w_{ij} (z_i - \overline{z}) (z_j - \overline{z})}{VAR(z)} \quad \text{Equação 5.2}$$

Para estimar a variabilidade espacial dos dados de área, usa-se a Matriz de vizinhança espacial por adjacência, sendo definida pelos elementos w_{ii} e

leva em consideração as medidas de proximidade espacial em cada um de seus elementos. Dado um conjunto de n áreas $\{a_1, a_2, .., a_n\}$, se A_i compartilha um lado comum com A_{j_i} o valor de w_{ij} é igual a 1, caso não sejam vizinhos, w_{ij} é igual a 0.

A figura 5.1 mostra um exemplo hipotético para o cálculo da QSSV de quatro regiões onde a região 1 faz vizinhança com todas, as regiões 2 e 3 fazem vizinhança entre si (além da região 1), enquanto a região 4 apenas faz vizinhança com a região da 1.



Figura 5.1: Exemplo de regiões para o cálculo da QSSV.

A tabela 5.1 mostra um exemplo de matriz de vizinhança espacial por adjacência considerando um exemplo hipotético entre quatro regiões segmentadas. Os valores iguais a 1 mostram as regiões que se tocam, enquanto os valores iguais a 0 informam que não há vizinhança próxima entre as regiões. No final da tabela são descritas a média e a variância dos valores de nível de cinza para as quatro regiões.

Área segmentada	Região	Região	Região	Região	NC	
	1	2	3	4		
Região 1	0	1	1	1	5	
Região 2	1	0	1	0	190	
Região 3	1	1	0	0	70	
Região 4	1	0	0	0	135	
Média das taxas (z)						
Variá	ància das t	taxas VAR	(z)		6416,66	

Tabela 5.1: Matriz de vizinhança espacial e a média dos níveis de cinza (NC) de quatro áreas segmentadas.

Aplicando a equação 5.2 pode-se estabelecer a correlação da média do nível de cinza entre uma determinada região e seus vizinhos. A tabela 5.2 apresenta as etapas do cálculo da autocorrelação espacial entre as quatro regiões hipotéticas.

· · · · · · · · · · · · · · · · · · ·	, , ,	5		
Duplas de áreas	Vizinhança	Taxa em i	Taxa em j	$W_{ij(zi-z)}(zj-z)$
segmentadas	(W _{ij})	(z _i)	(z _i)	
Região 1 x Região 2	1	5	190	-8550
Região 1 x Região 3	1	5	70	2850
Região 1 x Região 4	1	5	135	-3325
Região 2 x Região 3	1	190	70	-2700
Região 2 x Região 4	0	190	135	0
Região 3 x Região 4	0	70	135	0
Soma	4			-11725

Tabela 5.2: Matriz de vizinhança espacial e a média dos níveis de cinza (NC) de quatro áreas segmentadas.

Na última coluna está o valor registrado que entra no somatório da equação 5.2. Destaca-se que quando as regiões não são vizinhas, a contribuição delas é nula para o cálculo do indicador. Aplicando esses valores na equação:

 $\sum_{i=1}^{n} w_{ij} = 2 X 4 = 8$ $\sum_{i=1}^{n} \sum_{i=1}^{n} w_{ij} (z_i - \overline{z}) (z_j - \overline{z}) = 2 X - 11725 = -23450$ $\frac{1}{\sum_{i=1}^{n} w_{ij}} X \frac{\sum_{i=1}^{n} \sum_{i=1}^{n} w_{ij} (z_i - \overline{z}) (z_j - \overline{z})}{VAR(z)} = \frac{1}{8} X \frac{-23450}{6416,66} = -0,456$

Nesse exemplo, o valor da função de autocorrelação, quando se considera apenas os vizinhos próximos, é de -0,456,o que indica uma correlação inversa média entre as regiões. Esse valor é estabelecido para definir a Qualidade de Separabilidade entre Segmentos Vizinhos (QSSV).

Calculado a Qualidade de Homogeneidade Interna (QHI) e a Qualidade de Separabilidade entre Segmentos Vizinhos (QSSV) é possível estabelecer um parâmetro que integre os dois índices e permita mensurar a qualidade da segmentação gerada, ou seja, se internamente as regiões são homogêneas (medida pela QHI) e quando comparadas com as regiões adjacentes apresentam uma boa distinção (medida pela QSSV).

Espíndola (2006) denomina de Função Objetivo (FO) o parâmetro que integra os dois índices, sendo descrito na equação 5.3, onde (v) e (I) representam os índices QHI e QSSV respectivamente:

$$FO = F(v, I) = F(v) + F(I)$$
 Equação 5.3

Nesse estudo, usou-se a mesma abordagem de Espindola (2006) ao se realizar uma normalização nas funções F(v) e F(I), optando-se pelo método de normalização linear no intervalo [0,1] para os índices QHI e QSSV (equação 5.4), visando enquadrá-los em uma faixa numérica que possa ser comparada com os outros índices de interpretabilidade. A autora usa o método de normalização pelo valor máximo dos elementos.

$$F(x) = \frac{Xmax - X}{Xmax - Xmin}$$
 Equação 5.4

Bons resultados da segmentação são representados por baixos valores de QHI e QSSV, ou seja, a região é bastante homogênea internamente e heterogênea com as regiões adjacentes. Dessa forma, baixos valores de QHI e QSSV retornam respectivamente altos valores de F(v) e F(I)

Sendo assim, a Função Objetivo serve como critério para a avaliação das segmentações, processo básico para a detecção das feições cartográficas representadas por polígonos e linhas. Para contextualizar o índice nesse estudo, ele será denominado de Qualidade da Segmentação (QS), expresso na equação 5.5.

QS = (F(v) + F(I)) / 2 Equação 5.5

No estudo de caso proposto foram feitos testes de segmentação para classificar feições de cobertura vegetal, hidrografia e sistema de transporte.

Para a realização dessas atividades, três abordagens de segmentação foram estabelecidas: a segmentação multiresolução (baseada em similaridades), o segmentador *Contrast Split* e o filtro de Sobel (baseado por descontinuidades).

5.1.2 Qualidade da Detecção das Extensões

De uma forma geral, o termo completude está associado à integridade do dado, seja pela componente espacial ou o atributo em um banco de dados. Para a fase de interpretação, a tarefa ideal é poder extrair os traçados de forma integral, sem elementos omissos ou excedentes. Essa abordagem da completude, de caráter espacial, está associada à definição de uma avaliação que auxilie a mensurar a quantidade de traçados. O uso da expressão traçado serve apenas para destacar que o foco nesse estudo é conseguir detectar na imagem uma quantidade elementos cartográficos representativos em uma escala determinada, a partir do processo de interpretação de imagens.

São considerados erros de completude a constatação de elementos omissos ou excedentes (ISO 19113, 2003). Neste estudo são considerados importantes para a avaliação da interpretabilidade, sendo analisados os erros de omissão ou excesso de atributos no banco de dados e os traçados das feições.

A escolha pelo critério de completude se deve ao fato de estar diretamente relacionado ao primeiro princípio da interpretabilidade: a detecção. Caso um alvo seja detectado completamente em uma determinada imagem, é perfeitamente viável a aquisição de um traçado que o represente. Se o alvo não é detectado ou detectado parcialmente, a extração fica comprometida. A figura 5.2, a seguir, ilustra uma imagem obtida no comprimento de onda do infravermelho-próximo, com resolução de 5 metros. Nota-se na faixa diagonal da imagem a presença de um trecho de drenagem com largura aproximada entre 10 e 15 metros. É possível perceber continuidade da drenagem, facilitando o processo de extração da geometria dessa feição. O uso da imagem no infravermelho, nesse caso, é fundamental, tendo em vista a necessidade de se definir com a maior precisão possível o contorno das margens. O uso de outras bandas espectrais pode dificultar o processo de

interpretação, uma vez que a resposta espectral da água pode confundir com os elementos localizados na margem, como por exemplo, a mata ciliar.



Figura 5.2: Continuidade de drenagem em uma imagem com 5 m de resolução espacial.

Por outro lado, a figura 5.3 ilustra o mesmo recorte geográfico, através de uma imagem com resolução de 10 metros, também na faixa do infravermelho próximo. Apesar de ser possível, reconhecer partes da drenagem na imagem, em alguns trechos a detecção fica prejudicada, principalmente nas áreas onde a largura do rio diminui para 10 metros ou menos. Dessa forma, a detecção desse elemento fica comprometida por conta da impossibilidade do traçado ser extraído de forma integral.



Figura 5.3: Descontinuidade da drenagem em uma imagem com 10 m de resolução espacial.

Sendo assim, é importante avaliar, por exemplo, o percentual de feições que deixam de ser extraídas (erro de omissão) ou extraídas de forma excedente (erro de comissão) por conta da ineficiência de interpretação de uma imagem.

Em termos de extração de feições a partir de imagens, os erros de omissão podem ocorrer em função de duas causas possíveis. A primeira é que as imagens geradas pelo sensor não foram capazes de detectar o alvo, e a solução é optar pelo uso de imagens mais detalhadas de outros sensores. A segunda causa está associada à algum problema no processamento do dado. Neste caso, a solução seria testar outras ferramentas e /ou parâmetros de filtragem para melhorar a capacidade de extração com a devida validação.

Considerando que os recursos operacionais se esgotaram e a única justificativa é a própria limitação do sensor, percebe-se que ocorre um problema de detecção, de forma que a delimitação do elemento não foi efetuada. Especificamente quando se trata da avaliação da omissão do dado cartográfico, há a necessidade de se considerarem as características específicas das estruturas linear e poligonal. No caso de extração de linhas, por exemplo, uma feição pode apresentar descontinuidades que gerem segmentos lineares separados. Por alguma razão, uma linha que represente um rio ou estrada pode apresentar descontinuidades em função da diminuição de suas larguras no terreno ou pela presença de obstáculos. Esse fato não é observado para estruturas poligonais, tendo em vista que os segmentos de linha que o formam o polígono devem estar obrigatoriamente conectados.

Além dos erros de omissão, é importante também uma avaliação dos elementos extraídos de forma excedente, ou seja, os erros de comissão. Dessa forma, considera-se que o traçado foi extraído, porém está associado à classe errada, contabilizado como um erro de classificação ou identificação. A proposta de um parâmetro de qualidade para quantificar os erros de comissão, será descrita no capítulo referente ao indicador de identificação.

Dessa forma, após a segmentação, pode-se ter uma apreciação mais específica do potencial de detecção das imagens a partir de uma análise quantitativa de todos os elementos extraídos, sejam linhas ou polígonos.

Para avaliar a omissão, duas abordagens podem ser estabelecidas. A primeira diz respeito a uma forma de avaliação das extensões efetivamente

177

detectadas, seja através do comprimento das linhas ou de extensões das áreas dos polígonos, cuja unidade de medida é estabelecida através de padrão métrico. Já a segunda abordagem pode ser analisada sob o enfoque da quantidade de elementos detectados, contabilizando-se o número de objetos presentes.

Na primeira abordagem, o objetivo é a criação de um parâmetro de qualidade de completude que considere a dimensão das feições extraídas e compará-las com a extensão das linhas e polígonos de uma base de referência, podendo ser o mapeamento topográfico, de preferência na escala mais detalhada possível, ou o *tracking* do levantamento de campo.

No caso da avaliação poligonal, o parâmetro de qualidade da extração pode ser obtido através da operação espacial de sobreposição formada entre a base cartográfica de referência e a base extraída. As áreas em comum entre as duas bases correspondem aos acertos da detecção estabelecida a partir das imagens a serem interpretadas. Os erros de omissão são calculados a partir das áreas dos fragmentos poligonais existentes na base de referência, porém ausentes na base extraída e vice-versa.

Já para as feições lineares, podem-se comparar os valores dos comprimentos das linhas de cada feição entre a base de referência e a base extraída. Sendo assim, uma das principais diferenças entre as formas de representação cartográfica, é que diferentemente do perímetro de um polígono, um segmento linear pode apresentar descontinuidades ao representar uma determinada feição geográfica. Essas falhas podem ser resultado do processo de extração insatisfatório em uma determinada imagem, onde a continuidade é prejudicada por barreiras que impedem uma interpretação contínua do dado ou a diminuição da extensão do objeto. No caso de trechos de drenagem, por exemplo, a largura dos rios fica menor na direção de montante, dificultando a extração principalmente nos trechos de alto curso. Há ainda a possibilidade de considerar a parametrização nos algoritmos ou o uso de determinados dados não ter sido suficiente para uma ótima extração, sendo necessários novos testes ou a seleção de novos dados.

Dessa forma, torna-se importante avaliar a extensão dos segmentos lineares, de forma a verificar se as linhas apresentam boa continuidade ou são muito descontinuas. No caso das feições poligonais os próprios operadores espaciais (interseção) facilitam o processo de comparação entre a base de referência e a extraída. No caso das linhas, não há interseção certa entre linhas que representam o mesmo elemento geográfico, como por exemplo, um canal fluvial, cujos traçados entre a base de referência e extraída podem seguir paralelamente. Por isso, a inspeção visual torna-se fundamental para identificar traçados representativos da mesma feição.

A equação 5.9 expressa a Qualidade da Detecção das Extensões (QDE), onde x é o total da extensão dos perímetros dos polígonos e comprimentos lineares para cada classe em um determinado recorte geográfico, enquanto y é o total da extensão dos perímetros e comprimentos lineares das classes na base cartográfica de referência.

$$QDE = \frac{\sum x}{\sum y}$$
 Equação 5.9

O resultado é um valor no intervalo entre 0 e 1, cujos valores mais altos se traduzem em bons resultados. Porém, mesmo que o valor seja igual ou maior que 1, não significa necessariamente que não existam erros de completude, já que os erros de comissão podem disfarçar os erros de omissão. Por isso, é fundamental também a avaliação dos erros de comissão, destacada no capítulo referente ao indicador de identificação.

A tabela 5.3 apresenta um exemplo com três sensores, para a avaliação da omissão para feições representativas das categorias hidrografia (HD) e sistema de transporte (ST). No caso das feições de hidrografia, por exemplo, o sensor de melhor resolução espacial permite detectar 50% do comprimento extraído, enquanto a imagem com pior resolução permitiria extrair apenas 20% das extensões.

	Extensão dos elementos (km)	Sensor	Extensão extraída (km)	QDE
Feições		A (5 m)	25	0.5
lineares	50	B (10m)	20	0.4
(HD)		C (15m)	10	0.2
Feições		A (5 m)	30	1
lineares	30	B (10m)	28	0.93
(ST)		C (15m)	25	0.83

Tabela 5.3 – Exemplo de elementos extraídos por feições.

Uma das vantagens da aplicação deste parâmetro é a possibilidade de análise sobre os comprimentos e as áreas mínimas de linhas e polígonos que podem ser extraídas e analisar o potencial de extração de cada sensor.

Para apoiar esse tipo de análise pode-se utilizar como referência a ET-AGDV (DSG, 2016), em sua segunda versão, que estabelece critérios de dimensões mínimas de aquisição das feições por escala. O documento informa para cada escala quais feições devem ser adquiridas, além de descrever os valores de comprimento, largura e área passíveis de aquisição.

A tabela 5.4 apresenta os valores dos comprimentos mínimos para aquisição das classes de traçado linear utilizados no estudo de caso. Observase que o trecho de drenagem deve apresentar comprimento maior ou igual a 20 mm, enquanto as feições de rodovias possuem o comprimento mínimo de 10 mm na carta. Nestes casos, apenas trechos de drenagem com comprimento maior que 500 metros e rodovias com comprimento maior que 250 metros são representados na escala 1:25.000. Para elementos de trecho ferroviário não há especificação mínima de aquisição.

Feição	Aquisição	Aquisição	Aquisição	Aquisição	Aquisição
		1:25.000	1:50.000	1:100.000	1:250.000
Trecho de	Comprimento	≥ 500 m	≥ 1.000 m	≥ 2.000 m	≥ 5.000 m
drenagem	≥ 20 mm				
Trecho	Comprimento	≥ 250 m	≥ 500 m	≥ 1.000 m	≥ 2.500 m
rodoviário	≥ 10 mm				
Arruamento	Comprimento	≥ 250 m	≥ 500 m	≥ 1.000 m	Não
(trecho)	≥ 10 mm				representável
Ferrovia	Não há	Não há	Não há	Não há	Não há

Tabela 5.4 - Comprimentos mínimos para aquisição. (Fonte: DSG, 2016)

Esta análise também pode ser estabelecida para associar o limite mínimo de áreas contempladas por escala com as dimensões extraídas a partir das imagens. A tabela 5.5 apresenta algumas classes de traçado poligonal definidas na ET-EDGV e sua especificação mínima para representação.

Tabela 5.5: Áreas mínimas para aquisição. (Fonte: DSG, 2016)

Feição	Aquisição	Aquisição	Aquisição	Aquisição	Aquisição
		1:25.000	1:50.000	1:100.000	1:250.000
Trecho de massa	Àrea ≥ 4 mm ²	≥ 2500 m ²	≥ 10000 m ²	≥ 40000 m ²	≥ 250000 m ²
d' água	Largura ≥8 mm	≥ 20 m	≥ 40 m	≥ 80 m	≥ 200 m
Massa d´água	Àrea ≥4 mm ²	≥ 2500 m ²	≥ 10000 m ²	≥ 40000 m ²	≥ 250000 m ²
Floresta	Área ≥25 mm²	≥ 15625 m ²	≥ 62500 m ²	≥ 250000 m ²	≥1562500 m ²
Campo	Área ≥25 mm²	≥ 15625 m ²	≥ 62500 m ²	≥ 250000 m ²	≥1562500 m ²
Cultivo	Área ≥25 mm²	≥ 15625 m ²	≥ 62500 m ²	≥ 250000 m ²	≥1562500 m ²
Cultivo	Área ≥25 mm²	≥ 15625 m ²	≥ 62500 m ²	≥ 250000 m ²	≥1562500 m ²

Utilizando o exemplo da tabela acima, se forem extraídas áreas de vegetação com dimensões próximas ao valor de 15.625 m², já se atenderia à escala 1:25.000 em termos de representação. Posteriormente serão discutidos

outros critérios para que possam auxiliar na avaliação de uma boa interpretabilidade para cada escala.

5.1.3 Qualidade da Detecção dos Objetos

A segunda forma de avaliação da omissão dos dados extraídos pode ser estabelecida através da contagem do número de linhas e polígonos extraídos com os respectivos objetos presentes na base cartográfica de referência. Isso permite ter uma ideia relativamente simples e geral da omissão de dados, cujo valor pode ser obtido através da exatidão do produtor ao se estabelecer a matriz de confusão. A exatidão do produtor e do usuário são formas de analisar a exatidão temática específica de cada classe ao invés de analisar a exatidão geral obtida através do índice Kappa (CONGALTON & GREEN, 2009). A exatidão o usuário é a relação entre o número de elementos detectados e classificados corretamente e o total de elementos classificados para cada classe, possibilitando conhecer os erros de comissão. Esse parâmetro será descrito no capítulo referente ao indicador de identificação.

A exatidão do produtor possibilita conhecer os erros de omissão, já que corresponde ao relacionamento entre o número de elementos detectados corretamente com a o valor total da base de referência de cada classe. O valor resultante corresponde ao percentual do número de linhas e polígonos detectados, diferentemente da avaliação da extensão em metros ou quilômetros do parâmetro de qualidade de detecção mencionado anteriormente. Por isso, esse parâmetro é denominado de Qualidade da Detecção dos Objetos (QDO), cuja equação é representada abaixo:

$$\text{QDO} = \frac{n_{jj}}{n_{+j}}$$
 Equação 5.10

Onde:

 n_{jj} é o número total de unidades de amostras detectadas n_{+j} é o número total de unidades de amostras da base de referência

Como o resultado será gerado através de um valor percentual, será possível fazer uma comparação com os outros parâmetros para a construção do Identificador de Identificação.

A tabela 5.6 abaixo apresenta um exemplo para o calculo desse parâmetro.

		Observação de campo							
ão		Floresta	Campo	Mangue	Cultivo	Total			
icaç	Floresta	65	4	22	24	115			
ssif	Campo	6	81	5	8	100			
Cla	Mangue	0	11	85	19	115			
	Cultivo	4	7	3	90	104			
	Total	75	103	115	141	434			

Tabela 5.6: Exemplo do cálculo da QDO.

Usado a floresta como exemplo, o valor da qualidade de objetos omitidos, ou índice do produtor, é de 0.86, resultado da divisão entre os valores de 65 e 75. Sendo assim, obtêm-se os valores de QDO de 0.79, 0.74 e 0.64 respectivamente para as classes campo, mangue e cultivo.

5.1.4 Qualidade da Forma

Além da avaliação da segmentação e da quantidade das linhas e polígonos extraídos, o terceiro parâmetro envolvido para a geração do Índice de detecção objetiva avaliar o contorno dos traçados. Para isso, busca-se analisar o vértice, unidade estruturante de qualquer segmento, seja linear ou poligonal.

Propõe-se nesse estudo a elaboração de um parâmetro, denominado de Qualidade da Forma (QF), cujo propósito é verificar se a forma do traçado extraído está aderente ao contorno da linha ou polígono de uma base cartográfica de referência, podendo ser um mapeamento mais detalhado possível da área ou um levantamento de campo. A quantidade dos vértices presentes na extensão de uma feição define a sua forma, ou seja, o seu traçado deve possuir um número de vértices adequado para uma boa representatividade da feição geográfica. Um baixo número de vértices ocasiona uma delimitação pouco precisa, enquanto um número excessivo de vértices apenas acarreta no aumento do tamanho do arquivo gerado, tendo em vista o armazenamento de cada vértice.

A figura 5.4 ilustra essa comparação entre dois segmentos sobre uma imagem orbital. O perímetro em azul claro mostra um contorno com mais vértices, enquanto o perímetro em azul escuro constitui o traçado com menos vértices e dessa forma parece representar a massa d'água de forma menos detalhada. Nesse exemplo, a quantidade de vértices presentes no contorno reflete a qualidade no processo de extração, já que um número reduzido afetaria diretamente a forma do elemento a ser representado. Porém, podem ocorrer casos onde a distância entre os vértices pode ser relativamente grande, ou seja, um maior número de vértices não implica na forma mais ajustada, como, por exemplo, nos canais fluviais retificados e as nos trechos retos de rodovias.



Figura 5.4: Extração de dois perímetros de massa d´água.

.A figura 5.5 mostra a forma dos traçados das bases cartográficas 1:25.000 (azul claro) e 1:50.000 (azul escuro). A extensão em azul claro mostra um contorno com mais vértices, enquanto a extensão em azul escuro constitui o traçado com menos vértices e, dessa forma, parece representar a massa d'água de forma menos detalhada.



Figura 5.5: Amostra de uma feição linear representada nas bases cartográficas.

Com o objetivo de descobrir se haveria alguma correlação entre o número de vértices com a escala cartográfica, foi feita uma análise com as bases cartográficas na escala 1:25.000 e 1:50.000, sendo coletadas 20 amostras de polígonos dentro da área de estudo, na bacia hidrográfica do Rio São João - RJ.

Foi feita uma amostragem controlada, tendo em vista a garantia de uma coleta de feições que tivessem mantido a sua forma geral. É de conhecimento que as duas bases foram produzidas em diferentes épocas, sendo comum a divergência de traçado por conta das mudanças ocorridas na paisagem na região. Alguns exemplos correspondem principalmente a alterações nos cursos d'água e criação de novas estradas. A base cartográfica 1:50.000 foi produzida antes das obras de drenagem e retificação do rio São João. Todas as folhas topográficas 1:50.000 foram elaboradas a partir de levantamentos aéreos no final da década de 1960 e início dos anos 70, enquanto a base 1:25.000 foi elaborada, principalmente, a partir de levantamentos aéreos no ano de 2005.

Também vale destacar que os métodos de trabalho para a produção das duas bases foram distintos. Os dados na escala 1:50.000 foram produzidos a partir de processos analógicos e usando como referência o *datum* horizontal Córrego Alegre, enquanto na outra base, foram usados procedimentos de fotogrametria digital e o SIRGAS 2000 como sistema geodésico de referência. Apesar das divergências, optou-se por fazer essa comparação por serem os

dois únicos mapeamentos topográficos em maior escala existente para o estado do Rio de Janeiro.

Ao invés de analisar simplesmente a quantidade total de vértices, optouse por analisar relacionamento entre a quantidade de vértices com o perímetro do polígono ou extensão da linha, denominado de distância média entre vértices (DMV). Para avaliar essa situação, em cada amostra foram medidas os perímetros e extensões e calculado o número de vértices para cada traçado. As tabelas 5.7 e 5.8 apresentam os valores de extensões lineares e perímetros poligonais, numero de vértices, média e desvio padrão entre as amostras coletadas nas duas bases.

	1:25.000							
Amostra	Perímetro (m)	Vértices	DMV (m)	Amostra	Perímetro (m)	Vértices	DMV (m)	
1	2146,8	82	26,18	21	2146,8	81	26,50	
2	11992,5	328	36,56	22	12040,8	328	36,71	
3	6849,72	230	29,78	23	6749,72	179	37,71	
4	15614,2	393	39,73	24	15614,2	393	39,73	
5	6114,69	454	13,47	25	6114,7	154	39,71	
6	350,91	22	15,95	26	350,914	18	19,50	
7	308,4	14	22,03	27	308,405	16	19,28	
8	5693,79	387	14,71	28	5693,79	346	16,46	
9	7009,42	498	14,08	29	7009,42	429	16,34	
10	223,48	25	8,94	30	223,485	21	10,64	
11	206,97	20	10,35	31	206,973	18	11,50	
12	530,79	45	11,80	32	530,791	46	11,54	
13	479,92	40	12,00	33	479,921	35	13,71	
14	224,87	22	10,22	34	224,874	22	10,22	
15	729,58	88	8,29	35	655,032	106	6,18	
16	753,78	107	7,04	36	753,787	108	6,98	
17	997,36	39	25,57	37	997,32	39	25,57	
18	4250,48	124	34,28	38	5050,58	194	26,03	
19	12034,2	369	32,61	39	11976,3	398	30,09	
20	3160,66	146	21,65	40	3160,67	146	21,65	
						Média	17,87	
						Desvio	10,65	

Tabela 5.7: Distância média entre vértices na base 1:25.000.

1:50.000							
Amostra	Perímetro (m)	Vértices	DMV (m)	Amostra	Perímetro (m)	Vértices	DMV (m)
1	2051,36	66	31,08	21	2346,8	65	36,10
2	11735,8	245	47,90	22	10040,8	254	39,53
3	6966	142	49,06	23	6949,72	140	49,64
4	15443,7	317	48,72	24	16732,2	298	56,15
5	5991,96	351	17,07	25	6434,7	123	52,31
6	330,14	17	19,42	26	338,914	10	33,89
7	240,87	10	24,09	27	301,405	7	43,06
8	4175,56	260	16,06	28	5543,79	198	28,00
9	5226,16	334	15,65	29	6893,42	247	27,91
10	215	21	10,24	30	235,485	13	18,11
11	204,09	17	12,01	31	199,973	11	18,18
12	518,93	31	16,74	32	503,791	31	16,25
13	352,71	25	14,11	33	478,921	19	25,21
14	200,89	15	13,39	34	221,874	13	17,07
15	655,03	35	18,72	35	659,032	65	10,14
16	638,34	47	13,58	36	759,787	62	12,25
17	765,37	28	27,33	37	983,32	25	39,33
18	5115,16	87	58,79	38	5350,58	135	39,63
19	11681,9	250	46,73	39	12001,3	199	60,31
20	3370,63	98	34,39	40	3030,67	81	37,42
						Média	27,62
						Desvio	15,28

Tabela 5.8: Distância média entre vértices na base 1:50.000.

Elaborando-se uma projeção para obter valores da distância média entre vértices (DMV) adequados para o mapeamento 1:100.000 e 1:250.000 aparece o cenário para as amostras apresentado na tabela 5.9. Para atingir a esse objetivo criada uma tabela com todas as amostras e seus respectivos valores de DMV nas escalas 1:25.000 e 1:50.000. Para cada amostra foi calculado o valor proporcional do incremento da DMV na medida na qual diminuiu a escala. Essa proporção foi aplicada nas escalas 1:100.000 e 1:250.000 respeitando também a razão entre as escalas.

Amostra	DMV 1:100.000 (m)	DMV 1:250.000 (m)	Amostra	DMV 1:100.000 (m)	DMV 1:250.000 (m)
1	35,98	42,11	21	45,71	57,71
2	59,24	73,41	22	42,35	45,88
3	68,33	92,42	23	61,57	76,49
4	57,71	68,94	24	72,57	93,09
5	20,67	25,18	25	64,92	80,68
6	22,89	27,23	26	48,29	66,28
7	26,15	28,72	27	66,84	96,57
8	17,41	19,09	28	39,54	53,97
9	17,22	19,18	29	39,48	53,94
10	11,54	13,16	30	25,59	34,93
11	13,66	15,73	31	24,86	33,21
12	21,68	27,86	32	20,96	26,85
13	16,22	18,86	33	36,70	51,07
14	16,56	20,53	34	23,91	32,47
15	29,14	42,17	35	14,10	19,05
16	20,12	28,29	36	17,53	24,12
17	29,10	31,30	37	53,09	70,29
18	83,31	113,96	38	53,23	70,23
19	60,84	78,49	39	90,52	128,30
20	47,14	63,07	40	53,18	72,89
			Média	39,25	50,94
			Desvio	21,25	29,33

Tabela 5.9: Projeção do número de vértices nas bases 1:100.000 e 1:250.000

Esses valores representam apenas uma primeira aproximação, principalmente considerando o valor elevado para desvio padrão e também porque é apenas uma estimativa para as outras escalas.

De qualquer forma, os resultados podem auxiliar no entendimento da melhor forma do traçado para uma determinada escala, realizando-se uma análise comparativa da distância média dos vértices presentes em mapeamentos topográficos em diferentes escalas com as bases extraídas, com o propósito de saber se há relação entre esses valores.

Para se conhecer a relação da forma existente entre a base extraída e de referência, algumas amostras de linhas e polígonos foram selecionadas na área de estudo de forma aleatória. Para cada elemento foram obtidos:

- Número de vértices e cálculo do perímetro do segmento de referência, sendo o x a sua distância média entre os vértices;
- Número de vértices e cálculo do perímetro do segmento extraído, sendo o valor z a sua distância média entre os vértices;

A equação 5.11 representa a relação de forma (RF), onde o valor de \overline{x} \mathbb{Z} é a distância média do número de vértices do perímetro dos polígonos e linhas de referência. Já \overline{z} \mathbb{Z} é razão entre a distância média do número de vértices do perímetro dos polígonos e linhas extraídas.

$$RF = \frac{\sum \overline{x}}{\sum \overline{z}}$$
 Equação 5.11

A equação estabelece a relação de forma existente, estabelecido a partir da razão entre o somatório das amostras de \bar{x} com o somatório das amostras de \bar{z} d. Caso o valor dessa equação seja igual a 1, significa que a distância médias dos vértices dos traçados extraídos e de referência são semelhantes. Valores menores que 1 traduzem que o número de vértices extraídos é menor que o número de vértices da base de referência. Nos casos onde o número de vértices extraídos é maior que o número de vértices da base de referência, o resultado é traduzido por valores maiores que 1. Dessa forma, considera-se que os valores próximos de 1 constituem um bom resultado.

A Qualidade de Forma (QF), proposta desse estudo para avaliar o grau de detecção é calculada a partir da normalização dos valores obtidos, de forma que os maiores valores representam os melhores resultados.

5.1.5 Qualidade Posicional

Segundo Santos (2015) existem vários métodos de controle de qualidade cartográfica que utilizam feições lineares, porém não são frequentes a sua divulgação, assim como o desenvolvimento de estudos mais aprofundados no Brasil. A grande maioria destes métodos foi criada com o objetivo de avaliar os resultados do processo de generalização cartográfica.

Para o autor, podem-se dividir os métodos que se baseiam em feições lineares em três grupos principais:

- Grupo de faixa de incerteza que utilizam uma abordagem determinística, como o método da Banda Épsilon ou Método das Áreas, Buffer Simples e Buffer Duplo;
- Grupo de faixa de incerteza utilizando uma abordagem estocástica, como a Banda Genérica e Modelo de Erros Estatístico por Simulação;
- Grupo de métodos determinísticos que realizam análises geométricas, como a Distância de Hausdorff, Influência do Vértice, Aproximação por Spline e Ponto Gerado.

Na avaliação da detecção, optou-se testar o método de Influência do Vértice, proposta por Mozas & Ariza (2011), tendo em vista que é uma complementação do Índice da Forma dos Polígonos (IFP), estabelecendo o vértice como elemento estruturante do traçado da linha. Enquanto no IFP o objetivo é avaliar se a quantidade de vértices é suficiente para um bom traçado, o Índice Posicional dos Polígonos possibilita avaliar a posição dos perímetros dos polígonos, ou seja, busca-se verificar se o perímetro do polígono extraído está aderente com o contorno do polígono de base de referência.

Segundo Santos (2015), o método denominado de Influência do Vértice baseia-se na medição da distância euclidiana a partir dos vértices da linha de referência (LR) para a linha teste (LT). Estas distâncias são ponderadas em função do comprimento dos segmentos adjacentes ao vértice aplicado. Dessa forma, obtém-se o valor ponderado das distâncias entre os vértices de referência para a linha teste.

Logo, propõe-se uma análise de um conjunto de amostras de perímetros da área de estudo, através do cálculo da média aritmética ponderada usando o comprimento dos perímetros (peso) para obter o valor da discrepância média (D) entre os dois segmentos lineares do perímetro, conforme é apresentado na figura 5.6 e equação 5.12.


Figura 5.6: Método da Influência do Vértice. Fonte: Adaptado de Mozas & Ariza (2011)

$$D_{i} = \frac{\left[\sum_{k=1}^{m} \left(dh_{k} * \left(l_{k}^{k-1} + l_{k}^{k+1}\right)\right)\right]_{i}}{2 * CL_{R_{i}}} \quad \text{Equação 5.12}$$

Onde:

m: número de vértices da linha de referência (LR); dhk: distância horizontal mínima entre o vértice k da LR para linha teste (LT); lk-1 e lk+1: comprimento dos segmentos adjacentes ao vértice k na LR; CLR: comprimento da linha de referência;

Santos (2015) aplica o método da Influência do Vértice, utilizando o padrão de acurácia posicional brasileiro. Para a avaliação, noventa por cento das linhas testadas devem apresentar valores de erros médios menores ou iguais ao valor do PEC e o erro padrão das amostras deve ser menor ou igual ao estabelecido no PEC para a classe e escala empregadas no processo de avaliação da acurácia posicional.

Propõe-se, neste estudo, dividir as classes do PEC de acordo com a qualidade do erro posicional esperado para cada escala. O valor da discrepância média é normalizado em um valor entre 0 e 1, sendo estabelecido o valor da Qualidade Posicional (QP), cuja referência está na associação com o intervalo da escala segundo o PEC. Serão consideradas as escalas mais usadas no contexto da cartografia de referência para a produção do mapeamento topográfico, ou seja, será feito um recorte entre as escalas 1:25.000 e 1:250.000. Caso fossem consideradas todas as escalas previstas na ET-EDGV, apenas as escalas voltadas para o mapeamento cadastral teriam valores do IEP alto. Dificilmente valores de tolerância dos erros encontrados nessa faixa de escala são encontrados quando se trabalha com insumos de imagens de média resolução espacial.

Dessa forma, a qualidade posicional (QP) igual a 1 será o intervalo de classe com tolerância menor que 7 metros, critério estabelecido a partir da classe A do PEC-PCD, documento que trata da revisão do PEC para produtos cartográficos digitais (PCD). Optou-se por utilizar um valor um pouco menor que 12,5 metros, limite para o enquadramento, segundo o PEC, para a escala 1:25.000 classe A.

Se considerar o valor de abaixo de 7 metros como perfeito para atendimento das escalas mais usuais e 200 metros como limite dentro desse intervalo, é possível estabelecer uma escala entre o perfeito, com valor da QP igual 1, e inadequado, com valor da QP igual a 0.

Dessa forma, são 11 classes da QP, com intervalos de 0,1. Para que a divisão não fosse estabelecida a partir de número decimais grandes (caso a divisão fosse por 12 classes), optou-se por limitar o valor mais alto em 200 metros, tolerância da escala 1:250.000 classe B, ao invés de 250 metros, tolerância da escala 1:250.000 classe C. Valores acima de 200 metros, o valor da QP é zero.

Utilizando um exemplo para ajudar no entendimento, se o valor de discrepância média fosse de 17,5 metros, o valor da QP seria de 0,8, atendendo de forma satisfatória à escala 1:25.000. Obviamente esse enquadramento só será válido se o erro padrão encontrado (desvio padrão) também estiver enquadrado. A tabela 5.10 apresenta os valores de discrepância média (DM) escalonados de acordo com as classes do PEC, de

forma que os menores valores correspondem aos maiores valores da QP para cada escala.

Escala	Classe	DM (m)	QP
≥1.10.000		[≤7)	1,0
1:25.000	А	[7 ≥ 12,5)	0,9
1:25.000	В	[12,5 ≥ 20)	0,8
1:25.000	С	[20 > 25)	0,7
1:50.000	А	[20 = 20)	
1:50.000	В	[25 ≥ 40)	0,6
1:50.000	С	[40 > 50)	0,5
1:100.000	A	[10 = 00)	
1:100.000	A	[50 ≥ 80)	0,4
1:100.000	В	[80 ≥ 100)	0,3
1:100.000	С	[100 ≥ 125)	0,2
1:250.000	A	[125 ≥ 200)	0,1
1:250.000	В	≥ 200)	0

Tabela 5.10: Valores da QP associados ao enquadramento do PEC.

Caso o resultado da discrepância média ficar entre 20 e 25 metros, o dado atenderia, do ponto de vista posicional, à escala 1:25.000 classe C ou 1:50.00 classe A, tendo o valor da QP igual a 0,7. Dessa forma, um dado detectado pode ser de boa qualidade para uma escala específica, mas não ser adequado para uma escala maior.

5.1.6 Indicador de Detecção

Para mensurar o grau de detecção das linhas e polígonos extraídos, propõe-se nesse estudo o Indicador de Detecção (IDET), integrando os quatro parâmetros apresentados: a Qualidade de Segmentação (QS), A Qualidade de de Detecção das Extensões (QDE), a Qualidade de Detecção dos Objetos (QDO), a Qualidade da Forma (QF) e a Qualidade Posicional (QP). Dessa forma, para uma avaliação do grau de detecção de um traçado é necessário:

- Avaliar se os segmentos extraídos para a delimitação das linhas e polígonos apresentam contornos próximos do que se considera ideal (QS);
- Avaliar a quantidade de elementos extraídos em termos da extensão extraída (QDE);
- Avaliar a quantidade de elementos extraídos em termos de contagem de objetos extraídos (QDO);
- Utilizar o vértice como estrutura básica para mensurar a forma que um determinado elemento possui (QF);
- Avaliar a exatidão posicional de uma determinada linha ou polígono, de forma a verificar se atende às especificações de Padrão de Exatidão Cartográfica (QP).

A equação 5.13 expressa o IDET, sendo a média aritmética dos cinco parâmetros estabelecidos como importantes para avaliar o grau de detecção, de forma que todos apresentam os mesmos pesos. Cada variável gera um resultado, cujo intervalo de valores varia obrigatoriamente entre zero e um, de maneira que os valores mais altos constituem os melhores resultados de detecção. Dessa forma, o resultado do IDET compreende valores entre 0 e 1.

IDET = (QS + QDE + QDO+ QF + QP) / 5 Equação 5.13

5.2 EXTRAÇÃO DAS FEIÇÕES CARTOGRÁFICAS NA BHRSJ

Conforme discutido anteriormente, os segmentadores podem ser baseados em similaridades ou descontinuidades, sendo usados, respectivamente, para extração de polígonos e linhas. Por isso, considerando as diferenças existentes nos processos de segmentação de todas as classes analisadas, foi necessário desmembrar a extração em diferentes abordagens. Para a delimitação dos polígonos e linhas representativas das categorias de hidrografia, sistema viário e vegetação foram testados parâmetros em segmentadores distintos para os seis recortes da área de estudo.

5.2.1 Extração do sistema de transporte

Para a extração das feições lineares do sistema de transporte foram utilizados os métodos de análise de imagens baseados na Morfologia Matemática como referência, enfatizando os filtros de caráter morfológicos. O primeiro processo foi buscar algoritmos de processamento digital de imagens contendo funções específicas de detecção de bordas e filtros, auxiliando no reconhecimento de formas específicas, como por exemplo, as rodovias, arruamentos e ferrovias. Todas essas feições possuem características próprias de traçado, cuja representação se dá através de uma estrutura linear.

Atualmente existem inúmeros estudos de extração de feições lineares utilizando imagens de alta e média resolução espacial (Bazan *et. al.* 2008; Dal Poz, 2015; Santiago, 2011). Um estudo de Braz e Miura (2014) descreve a utilização de morfologia matemática para extração de malha viária em imagens orbitais.

Dessa forma, o processamento digital das imagens foi realizado no *Software Erdas* Imagine 2014, onde foram testados diferentes filtros em cada banda espectral.

Os testes de segmentação do sistema viário com as imagens constituíram-se incialmente em testes para avaliação da melhor banda espectral e tipo de filtro cujos resultados de extração seriam mais satisfatórios.

A banda espectral do vermelho foi selecionada em todos os sensores, apresentando o melhor resultado através do filtro de convolução Sobel, tipo de filtro passa alta direcional, que detecta a descontinuidade dos pixels criando uma borda, no qual o valor de brilho dos pixels de maior número digital é aumentado e diminuído o valor dos menores. Ou seja, esse filtro tem a propriedade de realçar linhas verticais e horizontais mais escuras que o fundo, sem realçar pontos isolados.

Realizou-se, posteriormente, um realce linear nas imagens resultantes, onde os limites mínimo e máximo foram alterados para se obter maior discriminação visual dos objetos de interesse, no caso as rodovias, arruamentos e ferrovias. A partir da imagem realçada, converteu-se a imagem para o sistema binário, ou seja, apenas dois tons de cinza, etapa importante para o posterior processo de vetorização.

195

O processo seguinte foi a aplicação do filtro morfológico de dilatação, cujo objetivo é provocar efeitos de alargamento dos padrões claros e conectar padrões claros próximos, procedimento que corrige pequenas descontinuidades no raster. Nesse estudo, o elemento estruturante é uma matriz com dimensão de 3x3, ou seja, usou-se o valor mínimo para diminuir a possibilidade de junções indevidas. O realce linear e a dilatação também foram feitos no *Erdas* Imagine 2014.

No ambiente Arc Gis 10.2, a imagem resultante da filtragem morfológica foi submetida a um filtro de moda com janela de convolução de tamanho 3x3 pixels. Desta forma, a maioria dos elementos que não correspondiam a malha viária puderam ser eliminados de forma automática e o ruído restante foi limpo manualmente. Isto se deveu ao filtro de convolução Sobel ser mais sensível a ruídos, e quando aplicado o filtro morfológico esses ruídos se destacam junto com a malha viária (FISCHER *et al.*, 2003).

O processo seguinte, denominado de esqueletização, pode ser entendido como a identificação de segmentos de mesmas características que se unem, formando a base principal do elemento a ser detectado, sendo essa base chamada de esqueleto (SOUZA, 2002). Para a geração do esqueleto, foi necessária a limpeza dos ruídos, a vetorização semiautomática e ajuste topológico.

A vetorização semiautomática foi realizada através do módulo Arc Scan, do Arc Gis 10.2. Foram sobrepostas a imagem binária gerada pela segmentação e a imagem do respectivo sensor. A vetorização semiautomática é feita através da geração de *centerlines* sobre os segmentos extraídos, de forma que nos entroncamentos, o intérprete define se continua para algum trecho ou termina o segmento.

Ao final, as feições lineares extraídas serão comparadas com o sistema de transporte da base cartográfica 1:25.000 e com o *tracking* feito através do levantamento por GNSS. O propósito é realizar uma avaliação geral dos resultados gerados.

A figura 5.7 mostra o fluxograma das atividades da etapa da extração de feições do sistema de transporte.



Figura 5.7: Atividades de extração das feições do sistema viário

Os produtos da segmentação da banda do vermelho são os polígonos dos trechos rodoviários, ferroviários e arruamento extraídos nas imagens RapidEye, AVNIR-2/ALOS e OLI/LANDSAT-8 conforme ilustram, respectivamente, as figuras 5.8, 5.9 e 5.10.



Recorte 1

Recorte 2



Recorte 3

Recorte 4



Figura 5.8 Extração do sistema de transporte na imagens RapidEye.



Figura 5.9: Extração do sistema de transporte na imagens AVNIR-2.



Figura 5.10: Extração do sistema de transporte nas imagens OLI/LANDSAT-8.

Através de análise visual e de dados levantados em campo, foram excluídos os caminhos inseridos em propriedades particulares, principalmente no recorte 4, onde há o predomínio de cultivo de cana-de-açúcar. Nessas áreas são frequentes os trechos de circulação de caminhões e tratores e apenas a análise do contexto da região permite distingui-los dos trechos de circulação pública.

Apesar de em termos quantitativos não haver uma diferença significativa entre os dados gerados das imagens RapidEye e AVNIR-2 /ALOS, percebeuse que o raster do sistema de transporte produzido a partir das imagens AVNIR-2 /ALOS apresentou uma "espessura" mais fina e com maiores descontinuidades, o que dificultou um pouco a vetorização e a necessidade de uma inspeção visual mais rigorosa.

5.2.2 Extração da vegetação

Para a extração da vegetação foi utilizada a plataforma computacional eCogintion®, versão 8.0, desenvolvida pela empresa *Trimble Geospatial Imaging*. O programa é um ambiente de desenvolvimento para análise de imagens baseada em objetos (GEOBIA), e que se tornou uma referência em estudos de classificação em imagens para atender a diferentes finalidades, como por exemplo, na Geomorfologia (Tedesco & Antunes, 2015), análise intra-urbana (dos Anjos *et al.*, 2015) e gestão ambiental (Seabra, 2012).

O Ecogintion se baseia em um conjunto de regras que permitem análises automáticas de dados de sensoriamento remoto, desde as imagens de média resolução espacial até os dados de alta resolução. Para isso, o *software* disponibiliza um grande conjunto de funções e parametrizações de segmentação e classificação, sendo possível ainda criar novos algoritmos em sua ampla árvore de processos. Cada processo corresponde a uma regra a ser executada e a ideia de árvore determina uma sequência de processos estabelecida pelo usuário. Em uma árvore de decisões convencional, por exemplo, a segmentação é um processo anterior à classificação, onde em cada regra é possível testar diversos parâmetros, o que permite uma avaliação do melhor resultado. Na criação dos projetos no e*Cogntion*, foram importadas seis imagens recortadas de cada sensor, representando as unidades de amostragem. Foram importadas todas as bandas espectrais com suas resoluções espaciais originais e com as correções geométricas e atmosféricas aplicadas.

O e*Cogntion* fornece diferentes métodos de segmentação, variando de algoritmos simples, como o *chessboard* e *quadtree*, até métodos complexos baseados nas segmentações *multiresolution* (multiresolução) ou *contrast split* (DEFINIENS, 2010), sendo os dois últimos tipos os mais detalhados nesse estudo.

A multiresolução constitui o algoritmo de segmentação mais usado em estudos de classificação baseada em objeto, tendo em vista a possibilidade do processamento em diferentes níveis de escala, utilizando a hereditariedade entre níveis e/ou classes através de análise fractal.

As duas principais variáveis da segmentação multiresolução são a escala e a homogeneidade. Segundo *Definiens* (2010), a escala corresponde ao número adimensional que descreve a heterogeneidade máxima permitida, estando relacionada à resolução espacial do sensor e ao tamanho dos objetos. Quanto maior o valor da escala, maior será a área dos segmentos gerados. Já a similaridade é um parâmetro para definir o grau de homogeneidade entre os segmentos, sendo dividido em cor e forma. A cor é o resultado da soma ponderada dos desvios-padrões de cada banda para cada segmento, enquanto a forma é dividida em dois aspectos: Compacidade, resultado da razão entre o perímetro do objeto pela raiz quadrada do seu número de pixels, e a suavidade, resultado da razão entre o perímetro.

Nesse estudo, foram testados diversos valores de forma e compacidade, porém será enfatizada a variação de escala, cujo objetivo é gerar uma segmentação considerada ideal para a extração dos diferentes tipos de cobertura vegetal.

Os testes de segmentação se baseiam em duas abordagens:

 Inserir valores nos parâmetros de escala e homogeneidade do segmentador e, após a análise visual de cada resultado, estabelecer uma segmentação visualmente mais adequada. É o procedimento mais usado entre os usuários de sensoriamento remoto. Usar o algoritmo Estimation Scale Parameter (ESP) para auxiliar na escolha da parametrização da segmentação. Essa ferramenta funciona no ambiente Ecogintion e serve para estimar os melhores valores de escala (*Drăguţ* et al. ,2010).

Sendo assim, foram criados projetos no Ecognition para a extração da vegetação nas imagens dos três sensores estudados. Poderia ser criado um projeto que integrasse a segmentação das imagens com diferentes resoluções, porém, como o principal objetivo do estudo é analisar o potencial de interpretação específico para cada sensor, optou-se por trabalhar de forma independente.

Após a importação das imagens foram estabelecidas algumas classes que refletem as categorias de informação abordadas nesse estudo e que possuem classes poligonais a serem identificadas posteriormente.

Para o processo de segmentação, foram estabelecidos três níveis hierárquicos do tipo *top-down*, ou seja, a partir de segmentos maiores ocorre a divisão em segmentos menores. Sendo assim, denominou-se de nível 1 a segmentação mais abrangente, o nível 2 para a segmentação intermediária e o nível 3 para a mais detalhada. No capítulo referente à identificação será descrita a estrutura hierárquica das classes adotada nesse estudo.

Um dos principais descritores usados são os Índices de Vegetação (IV), cujos valores são bastante empregados na avaliação da taxa de cobertura vegetal no terreno, com base na densidade da biomassa foliar. Esses índices são calculados, na maioria das vezes, por operações aritméticas envolvendo níveis de cinza de duas ou mais bandas dos sistemas sensores orbitais, sendo definidas pelas diferenças espectrais existentes entre a luz refletida pela vegetação e a luz refletida pelo solo exposto.

O IV utilizado nesse estudo é o de diferença normalizada (NDVI -Normalized Difference Vegetation Index), que relaciona as bandas do vermelho e do infravermelho através da equação 5.14:

203

NDVI =
$$(\rho_{INV} - \rho_{VER}) / (\rho_{INV} + \rho_{VER})$$
 Equação 5.14

Onde:

 ρ_{INV} = reflectância do pixel na faixa do infravermelho.

 ρ_{VER} = reflectância do pixel na faixa do vermelho.

O princípio do NDVI está na diferença de resposta nas faixas espectrais, enquanto na faixa do vermelho a clorofila absorve grande quantidade da luz, no infravermelho a estrutura da folha cria uma reflectância considerável. A assinatura espectral característica de uma vegetação verde e sadia mostra um evidente contraste entre a região do visível, especificamente o vermelho, e do infravermelho próximo. Em geral, pode-se considerar que quanto maior o contraste entre as assinaturas espectrais na região do vermelho e infravermelho próximo, maior será o vigor vegetativo na área imageada.

Para imagens de todos os sensores estudados, foram selecionadas as bandas do vermelho e infravermelho-próximo no ambiente e*Cogntion*, que possui uma ferramenta para customizar o cálculo do NDVI.

O resultado do cálculo do NDVI pode variar de –1 até 1, sendo que os valores mais altos representam áreas com maior quantidade de biomassa. Áreas com valores de NDVI também positivos, mas próximos de zero, estão associadas à baixa densidade de biomassa foliar, enquanto valores negativos correspondem a áreas sem vegetação, como, por exemplo, os corpos d´água.

Para auxiliar na segmentação, foi gerado o NDVI dos seis recortes das imagens RapidEye, AVNIR-2 /ALOS e OLI/LANDSAT-8 da área de estudo, sendo apresentados, respectivamente, nas figura 5.11, 5.12 e 5.13. Os tons esverdeados mostram as áreas com presença significativa de biomassa foliar, com valores maiores que 0,61. Os tons amarelados ressaltam as áreas com média presença de biomassa foliar, com valores de NDVI entre 0,34 e 0,61. Por último, destacam-se as áreas em tons avermelhados, com valores de NDVI abaixo de 0,34, ou seja, com ausência ou baixíssima presença de biomassa.



Figura 5.11: NDVI dos recortes das imagens RapidEye.



Figura 5.12: NDVI dos recortes das imagens AVNIR-2.





É possível atribuir pesos diferentes em cada banda espectral inserida no projeto para o cálculo da segmentação. Inicialmente foram testados, para a segmentação de áreas verdes, pesos maiores para as bandas do infravermelho e vermelho e, posteriormente, foi testado o mesmo valor de peso para todas as bandas espectrais. Os resultados gerados foram semelhantes, não sendo possível estabelecer uma diferença visual, optando-se pela manutenção dessa última configuração.

Outros parâmetros da segmentação multiresolução testados foram os critérios de compacidade e suavidade (estabelecimento da homogeneidade dos objetos), cujos melhores resultados foram obtidos, respectivamente, com os valores de 0,1 e 0,5.

Foram testados, através de forma empírica, ou seja, usando a tentativaerro, diferentes valores do parâmetro de escala na segmentação multiresolução para os três níveis hierárquicos, do mais abrangente (nível 1) até o mais detalhado (nível 3). Na verdade os três níveis não são independentes, havendo uma ligação estrutural entre eles, ou seja, a segmentação do nível 3 é construída a partir da segmentação do nível 2 e os segmentos do nível 1 gerados a partir do nível 2. Esse processo garante uma ordenação topológica entre os segmentos gerados nos dois níveis.

A figura 5.14 apresenta uma comparação entre os três níveis de segmentações com a imagem Rapideye, onde a imagem (A) ilustra a segmentação com parâmetros de escala igual a 80 (nível 1), na imagem (B) o valor de escala foi definido como 40 (nível 2) e na imagem (C) está o nível 3, cujo valor de escala é de 20. Dessa forma, nota-se uma divisão maior à medida que se aumenta o seu nível.

No caso da segmentação das imagens AVNIR-2 /ALOS os parâmetros de escala foram 100 (nível 1), 60 (nível 2) e 40 (nível 3). No caso das segmentações das imagens OLI/LANDSAT-8 os parâmetros de escala foram 200 (nível 1), 100 (nível 2) e 50 (nível 3).

208



Figura: 5.14: Exemplo de três níveis de segmentação top-down.

Uma segmentação ideal envolve o limiar entre uma boa separação entre objetos diferentes e uma boa agregação de objetos semelhantes. No caso dos valores de escala serem muito reduzidos, ocorre a geração de uma grande quantidade de segmentos, ou seja, há uma separação demasiada de segmentos que prejudicam o processo de classificação posteriormente. Por outro lado, a inserção de valores altos de escala ocasiona a agregação de elementos que não deveriam ser unidos. Por isso, o estabelecimento de um limiar adequado não é uma tarefa trivial.

Além da inserção de valores nos parâmetros de escala e homogeneidade do segmentador após a análise visual de cada resultado de segmentação, foi testado o algoritmo *Estimation Scale Parameter* (ESP) para auxiliar na escolha da parametrização da segmentação (Dragut *et al.*, 2010)

A ferramenta ESP calcula a variância local dos valores radiométricos de uma determinada imagem, permitindo gerar segmentações em um (sem hierarquia entre classes) ou múltiplos níveis hierárquicos em uma abordagem *bottom-up*, calculando a variação local para cada escala. A variação da heterogeneidade é interpretada pelo usuário através da plotagem de um gráfico com os valores de variação local e da taxa de mudança. Segundo os autores, a taxa de mudança (ROC) é o indicador para avaliar a dinâmica da variação local entre os objetos para outro nível na abordagem *top-down*, sendo expresso a partir da equação 5.15.

$$ROC = \left[\frac{L-(L-1)}{L-1}\right] * 100$$
 Equação 5.15

Onde:

L = variância local do nível de referência

L-1 = variância local do nível imediatamente abaixo ao de referência

A figura 5.15 apresenta um exemplo de um gráfico gerado a partir do algoritmo ESP, com a plotagem dos valores de variância global (sigla VL com a curva vermelha) e da taxa de mudança (sigla TM com a curva azul).



Figura 5.15: Exemplo de saída gráfica do algoritmo ESP (adaptado de Alves, 2012)

Analisando o gráfico, percebe-se que o incremento do parâmetro de escala aumenta variância local (VL). A partir de um determinado valor de escala, há uma tendência de estabilização da variância local ao longo da curva, indicando valores de escalas onde os objetos atingiram níveis significativos de organização em termos de variação de sua homogeneidade. No entanto, é uma tarefa difícil separar limiares de variância significativos sobre esta curva, por isso os desenvolvedores do ESP introduziram a curva da taxa de mudança (TM), que representa a alteração da variância de um nível de escala em relação ao seu anterior. Utilizando o gráfico como exemplo, nota-se 50 valores de escala, cujos picos das curvas da taxa de mudança correspondem à 21, 31, 37, 43 e 47. Esses valores correspondem à valores significativos do parâmetro de escala para a segmentação da imagem. Dessa forma os limiares nas taxas de mudança da variância local (ROC) indicam os níveis de escala na qual a imagem pode ser segmentado da forma mais adequada, em relação às propriedades radiométricas dos dados.

Sendo assim, foram criados projetos no *eCognition* para efetuar a segmentação nas imagens dos três sensores estudados. Poderia ser criado um projeto que integrasse a segmentação das imagens com diferentes resoluções, porém, como o principal objetivo do estudo é analisar o potencial de interpretação específico para cada sensor, optou-se por trabalhar se forma independente.

No caso das imagens RapidEye, foram calculados a estimativa dos parâmetros de escala para cada recorte. Dessa forma, cada imagem teria um valor de escala para segmentação estabelecida a partir da análise da taxa de mudança da variância local. A figura 5.16 apresenta um exemplo do gráfico gerado para recorte 1 da imagem RapidEye.



Figura 5.16: Saída gráfica do algoritmo ESP para a imagem do recorte 1 do RapidEye

Percebe-se que o gráfico da variância local, curva vermelha, aumenta com o valor de escala, porém em determinados pontos a variância se mantem ou diminui. Nesses pontos o gráfico da taxa de mudança muda de padrão, apresentando picos. Esses valores são estabelecidos para a segmentação ideal para os três níveis da segmentação multiresolução, indicando, no caso do gráfico acima, os valores de 25, 65 e 110 respectivamente para os níveis 3,2 e 1.

A tabela 5.11 apresenta os valores de escala definidos para os seis recortes das imagens RapidEye, AVNIR-2 /ALOS e OLI/LANDSAT-8 estabelecidos a partir da análise da ferramenta de estimativa de escala.

Para a avaliação da interpretabilidade foram analisados os dados gerados a partir da parametrização do valor de escala do algoritmo ESP e da segmentação a partir da análise visual.

		Escala		
Recorte	Nível	RapidEye	AVNIR-2/ALOS	OLI/LANDSAT-8
	1	110	129	240
1	2	65	78	176
	3	25	35	71
	1	102	125	259
2	2	58	68	186
	3	29	31	91
	1	105	140	280
3	2	60	65	168
	3	23	26	65
	1	115	139	259
4	2	57	66	191
	3	30	35	70
	1	103	127	275
5	2	55	60	181
	3	24	29	76
6	1	109	140	271
	2	55	59	181
	3	23	25	101
Média		63,78	76,50	174,50
Desvio padrão		34,74	44,39	78,72

Tabela 5.11: Valores de escala usando como referência o algoritmoEstimation Scale Parameter.

5.2.3 Extração da hidrografia

Também foi utilizada a plataforma computacional E*cogintion* versão 8.0 para a segmentação de feições de hidrografia. Para a delimitação dos polígonos representativos das categorias de hidrografia foram testados parâmetros do segmentador *Contrast Split* para os seis recortes da área de estudo.

Segundo *Definiens* (2010), a segmentação denominada de *Contrast Split*, tem como objetivo separar objetos claros e escuros usando um limiar que maximiza o contraste do brilho dos objetos. Ao se estabelecer um determinado intervalo de valores entre os pixels, o programa aperfeiçoa a separação dos objetos mais claros e mais escuros.

Para fins de comparação, foram testados os segmentadores multiresolução e o de divisão de contraste (Contrast Split) no Ecognition para os elementos de hidrografia. Sendo assim, foi feita uma avaliação da extração de corpos d'água nas imagens, principalmente na sua resposta espectral na banda do infravermelho, cuja visualização é bastante contrastante quando comparada com os outros objetos. Após alguns testes com diferentes limiares, estabeleceu-se um limiar padrão para os seis recortes de imagens da área de estudo. Após a segmentação, foi realizada uma inspeção visual da segmentação com a imagem para eliminar alguns ruídos, ou seja, áreas segmentadas que não eram corpos d'água. Para a definição da classe água no projeto, utilizou-se como principal descritor o NDVI, selecionando-se os valores menores que zero e a média da banda do infravermelho.

A figura 5.17 apresenta uma comparação entre a segmentação multiresolução (A) e o contraste Split (B) em imagens RapidEye nas proximidades do rio Bananeira, localizado no recorte 2. Nota-se na primeira imagem que o segmentador não delimitou de forma tão precisa como na segunda imagem.

Na segunda imagem, o contorno em azul claro representa a área usando o segmentador *constrast Split*, enquanto as linhas em azul escuro representam os trechos de drenagem da base 1:25.000 do IBGE. Ao norte e à leste da imagem estão duas áreas onde a largura dos rios atingem mais de 20 metros, de forma que o segmentador consegue delimitar os corpos d´água.

Para a extração dos trechos de drenagem, optou-se pelo uso dos polígonos gerados no segmentador *Constrat Split* no *Ecognition* para traçar a linha representativa dos canais fluviais e outros elementos hidrográficos que tenham fluxo.

De certa forma, os resultados gerados foram visualmente consistentes com a base cartográfica de hidrografia do IBGE, com algumas pequenas exceções. As avaliações mais detalhadas da qualidade dos dados extraídos serão discutidas no próximo capítulo.

Dessa forma, foi possível usar os polígonos gerados no segmentador *Contrast Split* como referência para a geração dos chamados eixos de drenagem, que segundo a DSG (2016) representa a calha principal do objeto trecho de massa d´água. Caso a largura do rio seja menor do que o especificado na escala, simplesmente o polígono não é representado, apenas a linha do trecho de drenagem.



Figura 5.17: Segmentadores Multiresolução (A) e Contrast Split (B).

Os produtos da segmentação da banda do infravermelho são os polígonos dos trechos de massa d'água e massa d'água extraídas nas imagens RapidEye, AVNIR-2 /ALOS e OLI/LANDSAT-8, respectivamente apresentados figuras 5.18, 5.19 e 5.20.



Recorte 1

Recorte 2



Recorte 3

Recorte 4



Figura 5.18: Extração da hidrografia na imagens RapidEye.



Figura 5.19: Extração da hidrografia na imagens AVNIR-2.



Figura 5.20: Extração da hidrografia nas imagens OLI.

Os testes de segmentação da hidrografia com as imagens RapidEye, AVNIR-2 e OLI/LANDSAT-8 constituíram na inserção de valores nos parâmetros do segmentador *Contrast Split* e após a análise visual de cada resultado, estabeleceu-se uma segmentação visualmente mais adequada. No segmentador existe a possibilidade de associar os objetos claros e escuros a determinadas classes, sendo assim, os objetos escuros na banda do infravermelho foram classificados como água e os objetos claros como outros. Alguns segmentos de rodovias pavimentadas, que também aparecem um pouco escuras na banda do infravermelho, foram separados através de análise visual. A necessidade de análise visual é fundamental porque apenas um pequeno trecho de um curso d´água pode ser extraído e análise do contexto ajuda a diferenciá-lo de uma massa d´água.

Nota-se nas imagens que as áreas destacadas em azul correspondem às regiões com presença de água. Em praticamente todas existem fluxos de água, com exceção apenas no recorte 3, onde foram extraídas apenas pequenas massas d'água. Nesse recorte existem apenas rios com pequena largura, que em épocas de baixa pluviosidade tornam-se secos, conforme ilustra a figura 5.21.



Figura 5.21: Foto da calha de um canal fluvial seco na área do recorte 3.

Para realizar o trabalho de vetorização foi necessário, inicialmente, exportar a segmentação como uma imagem classificada no Ecognition, sendo

convertido posteriormente para uma estrutura binária, ou seja, convertidos para 1 bit, além da realização de um aumento linear de contraste.

Posteriormente, foi realizado o processo de esqueletização similar ao sistema viário. No ambiente Arc Gis 10.2, foi realizada uma limpeza dos ruídos e a vetorização semiautomática a partir do módulo *Arc Scan*. Foram sobrepostas a imagem binária gerada pela segmentação e a imagem do respectivo sensor. Visualmente tentou-se fazer uma seleção visual dos trechos de massa d'agua, distinguindo-os das massas d'água, onde o trecho de drenagem não é representado. A vetorização torna-se automática sobre os segmentos extraídos e nas partes onde há bifurcação, o intérprete define se continua para algum trecho ou termina o segmento. Seguindo a recomendação da ET-EDGV, a vetorização iniciava-se de montante.

A figura 5.22 apresenta o fluxograma das atividades da etapa da extração de feições da hidrografia.



Figura 5.22: Atividades de extração das feições lineares de hidrografia

5.3 GERAÇÃO DO INDICADOR DE DETECÇÃO NA BHRSJ

5.3.1 Avaliação da qualidade da segmentação

O primeiro processo para a geração do Indicador de Detecção é avaliar as segmentações geradas para o mapeamento das classes a partir do parâmetro Qualidade da Segmentação (QS). Para a classificação da vegetação foi avaliada a qualidade da segmentação multiresolução, baseada em crescimento de regiões, enquanto que para as classes de hidrografia e sistema de transporte foi analisada a segmentação baseada em descontinuidades. Para as classes de hidrografia, foi usado o algoritmo *Constrast Split* na plataforma e*Cogntion*, enquanto que para as classes de sistema de transporte foi usado o filtro de Sobel no software *Erdas*.

Para a geração do parâmetro QS foram coletadas amostras de polígonos e linhas extraídas de forma aleatória nos seis recortes da área de estudo.

Para auxiliar na avaliação, foram selecionadas de forma aleatória 20% do total de elementos para cada classe como amostras para as análises. No caso de feições poligonais de vegetação e hidrografia, foram selecionados polígonos extraídos, respectivamente, das segmentações multiresolução e constrast Split. Para as feições lineares do sistema de transporte e hidrografia, extraiu-se as bordas das áreas segmentadas (oultines).

A figura 5.23 ilustra dois exemplos de amostras das áreas segmentadas. A figura A ilustra um exemplo de segmentação multiresolução onde foram coletadas amostras de vegetação. Já a figura B mostra um exemplo de segmentação por descontinuidade para a extração do sistema viário. Nota-se que a área que envolve as rodovias correspondem à exemplos de amostras para avaliação da segmentação.



Figura 5.23 Exemplos de amostras de polígonos para avaliação de segmentação.

A seguir são descritos dois parâmetros de qualidade usados para a avaliação da segmentação: a Qualidade da Homogenidade Interna e a Qualidade da Separabilidade entre Segmentos Vizinhos, propostos por Espindola (2006).

Neste estudo, como existe um grande número de parâmetros para serem calculados, utilizou-se um padrão de nomenclatura para facilitar o entendimento. Dessa forma, há uma ordenação hierárquica entre Índice, Indicador e variáveis (Qualidade), representando do mais abrangente até o mais específico, respectivamente. Porém, para a elaboração da Qualidade da Segmentação (variável do Indicador de Detecção) foram usados dois cálculos construídos por outro autor que usa a expressão índice. Optou-se por substituir o termo índice pela denominação qualidade, alterando-se o termo da autora. Porém, ressalta-se que as expressões matemáticas usadas são rigorosamente iguais.

5.3.1.1 Qualidade de Homogenidade Interna

Para avaliar o comportamento radiométrico da parte interna dos segmentos, utilizou-se a Qualidade de Homogenidade Interna (QHI), originalmente denominado de índice de Homogenidade Interna por Espindola (2006).

Conforme mencionado anteriormente, para segmentar as classes de vegetação, foi usado o segmentador Multiresolução na plataforma e*Cogntion*. A parametrização se baseou em duas abordagens. A primeira é através da inserção de valores de escala de segmentação até encontrar um resultado visualmente adequado, isto é, através de forma empírica, enquanto a segunda foi através do uso da função *Estimate Scale Parameter* (ESP), algoritmo no Ecognitin que permite, através de análise do gráfico de variância, identificar os melhores valores para a parametrização da segmentação. A figura 5.24 apresenta uma comparação entre a segmentação usando a ferramenta ESP e tentativa-erro para os três sensores. Quanto maior o valor da QHI, melhor é o resultado.









Os resultados mostram que, de forma geral, os polígonos das classes de vegetação apresentaram maior homogeneidade interna usando como referência a parametrização através do ESP. Para as áreas de campo, nota-se que os valores de QHI para as duas técnicas são muito semelhantes. Apenas

para a segmentação da classe campo nas imagens RapidEye apresenta o valor de QHI através de tentativa-erro menor do que usando o algoritmo ESP.

A tabela 5.12 apresenta os valores de QHI por classe. No caso da vegetação foram considerados os dados da segmentação usando o ESP, cujos resultados se mostraram melhores do que através da técnica de tentativa-erro para a segmentação. Não foi extraído nenhum elemento da classe arruamento no sensor OLI.

	Sensor			
Classe	RE	AVNIR-2	OLI	
Arruamento	14,21	25,82	-	
Campo	28,83	52,39	65,21	
Cultivo	44,10	57,69	108,67	
Ferrovia	22,73	38,94	42,83	
Floresta	49,20	57,80	64,09	
Mangue	22,97	42,83	80,88	
Massa d´água	30,52	38,43	48,85	
Rodovia LN	7,84	13,94	19,93	
Rodovia pavimentada	5,73	7,94	15,94	
Trecho de drenagem	20,10	22,12	34,10	
Trecho de Massa d´água	17,23	19,23	28,87	

1 abela J. 12. Valuies de Qi II das classes	Tabela 5.12:	Valores	de QHI	das c	lasses
---	--------------	---------	--------	-------	--------

Os valores indicam que as classes geradas através da segmentação por descontinuidade (arruamento, rodovias, ferrovia e trechos de drenagem e massa d água) apresentaram áreas internamente mais homogêneas do ponto de vista radiométrico, constatado pelos valores mais baixos em relação às outras classes nos três sensores avaliados. Geralmente, no processo de interpretação, são feições que apresentam delimitação mais precisa quando comparadas com as classes de vegetação, por exemplo.

Geralmente as áreas de vegetação possuem, em seu interior, elementos que podem se diferenciar um pouco do comportamento espectral esperado. No caso de floresta, por exemplo, existe a possibilidade de inclusão de pequenas áreas de sombras em virtude da sua localização em áreas com maior declividade. Isso talvez justifique a diferença do QHI entre a floresta e o mangue, cujo resultado foi melhor. As áreas de cultivo também constituem paisagens onde podem haver grandes diferenças radiométricas, em função do tipo de cultivo ou o fato da área estar sendo preparada para o plantio.

Os elementos de hidrografia apresentaram resultados considerados bons quando comparados com a vegetação. Porém, apesar da segmentação ser estabelecida pela diferença de contraste como na extração das rodovias, as massas d´água podem não apresentar uma boa homogeneidade interna, em virtude, principalmente, do processo de sedimentação fluvial.

Todos os valores foram normalizados em uma escala entre zero e um, para que fosse uma comparação com as outras variáveis. A tabela 5.13 apresenta o conjunto de valores normalizados a partir das amostras de todas as classes dos três sensores. Quanto maior o valor do QHI normalizado, melhor é o resultado.

Classo	Sensor			
Classe	RE	AVNIR-2	OLI	
Arruamento	0,92	0,80	-	
Campo	0,78	0,55	0,42	
Cultivo	0,63	0,50	0	
Ferrovia	0,83	0,68	0,64	
Floresta	0,58	0,49	0,43	
Mangue	0,83	0,64	0,27	
Massa d´água	0,76	0,68	0,58	
Rodovia LN	0,98	0,92	0,86	
Rodovia pavimentada	1,00	0,98	0,90	
Trecho de drenagem	0,86	0,84	0,72	
Trecho de Massa d´água	0,89	0,87	0,78	

Tabela 5.13: Valores de QHI normalizados

5.3.1.2 Qualidade da Separabilidade entre Segmentos Vizinhos

A figura 5.25 mostra uma comparação entre os valores da Qualidade da Separabilidade entre Segmentos Vizinhos (QSSV) entre as segmentações de vegetação usando o algoritmo ESP e através do modo empírico. Quanto menor o valor de QSSV, melhor é o resultado. De forma geral, nota-se pouca diferença entre as duas técnicas, com exceção da classe campo nas imagens AVNIR-2 e OLI, onde a diferença foi um pouco mais expressiva.



Figura: 5.25: Gráficos que comparam os valores de QSSV usando ESP e o modo empírico.
De qualquer forma, os resultados mostram que os polígonos das classes de vegetação apresentaram maior heterogeneidade externa usando como referência a parametrização através do ESP.

Nota-se, também, que as classes cultivo e campo apresentam os resultados menos satisfatórios em termos de diferenciação radiométrica de um polígono com seus vizinhos. Muitas vezes, essas classes são rodeadas por outras com características semelhantes, refletindo na baixa diferenciação externa.

A tabela 5.14 mostra os valores de QSSV por classe. No caso da vegetação foram considerados os dados da segmentação usando o ESP, cujos resultados se mostraram melhores do que através da técnica de tentativa-erro para a segmentação. Não foi extraído nenhum elemento da classe arruamento no sensor OLI.

	Sensor			
Classe	RE	AVNIR-2	OLI	
Arruamento	0,19	0,51	-	
Campo	0,19	0,21	0,44	
Cultivo	0,67	0,65	0,63	
Ferrovia	0,61	0,63	0,98	
Floresta	0,12	0,17	0,22	
Mangue	0,09	0,10	0,15	
Massa d´água	0,10	0,09	0,1	
Rodovia LN	0,09	0,12	0,15	
Rodovia pavimentada	0,12	0,14	0,15	
Trecho de drenagem	0,17	0,22	0,38	
Trecho de Massa d´água	0,11	0,10	0,13	

Tabela 5.14: Valores de QSSV por classe e sensor

Os valores indicam que as classes cultivo e ferrovia apresentaram os resultados menos satisfatórios em termos de heterogeneidade do polígono da classe em relação aos seus vizinhos. No caso da classe cultivo, tal fato pode ser explicado pela presença de outros tipos de cobertura semelhantes que cercam os plantios, como por exemplo, o campo. No caso da ferrovia, vale a

pena destacar que, apesar da presença dos trilhos na área de estudo, o local encontra-se sem atividade de circulação de trens, formando-se uma vegetação de gramíneas e pequenos arbustos em sus estrutura em parte do trecho ferroviário.

Vale destacar que as demais classes analisadas apresentaram bom resultado de QSSV, tanto os polígonos gerados pela segmentação de crescimento de regiões, quanto a delimitação das bordas estabelecidas pela segmentação por descontinuidade.

A tabela 5.15 mostra o conjunto de valores normalizados a partir das amostras d todas as classes dos três sensores, servindo como base para a construção do índice de interpretabilidade. Quanto maior o valor do QSSV normalizado, melhor é o resultado.

	Sensor			
Classe	RE	AVNIR-2	OLI	
Arruamento	0,88	0,52	-	
Campo	0,87	0,85	0,59	
Cultivo	0,34	0,37	0,39	
Ferrovia	0,42	0,39	0	
Floresta	0,94	0,90	0,84	
Mangue	0,98	0,98	0,91	
Massa d´água	0,98	1	0,98	
Rodovia LN	0,98	0,95	0,91	
Rodovia pavimentada	0,95	0,93	0,91	
Trecho de drenagem	0,90	0,84	0,66	
Trecho de Massa d´água	0,96	0,96	0,94	

Tabela 5.15: Valores de QSSV normalizados.

5.3.1.3 Qualidade da Segmentação

O índice final que contempla a integração entre o QHI e QSSV denomina-se de Qualidade da Segmentação (QS), adaptado da proposta de Espíndola (2006) que o denominou de Função Objetivo.

A figura 5.26 ilustra uma comparação entre os valores da Qualidade da Segmentação (QS) das segmentações de vegetação usando o algoritmo ESP e através de forma empírica. Quanto maior o valor de QS, melhor é o resultado.



Figura: 5.26: Gráficos que comparam os valores da QS usando ESP e o modo empírico.

Os resultados evidenciam que o QS para a segmentação usando a ferramenta ESP mostra-se ligeiramente melhor do que apenas através da análise visual, com exceção da classe cultivo nas imagens AVNIR-2 e OLI.

229

Sendo assim, a segmentação usando o algoritmo ESP foi usada como referência para a criação do índice de detecção e, consequentemente, para a geração do índice de interpretabilidade.

A tabela 5.16 apresenta os valores do índice da Qualidade de Segmentação para as classes analisadas. Os dados do sensor RapidEye apresentaram melhores resultados, principalmente as rodovias, trecho de massa d´água e arruamento. Porém, vale destacar os bons resultados dessas classes para os sensores AVNIR-2 e OLI.

~~

QS								
Classo	Sensor			Classa	Sensor			
Classe	RE	AVNIR-2	OLI	Classe	RE	AVNIR-2	OLI	
Arruamento	0,90	0,66	-	Massa d´água	0,87	0,84	0,79	
Campo	0,82	0,70	0,51	Rodovia Leito natural	0,98	0,94	0,89	
Cultivo	0,49	0,43	0,19	Rodovia pavimentada	0,98	0,95	0,90	
Ferrovia	0,63	0,54	0,32	Trecho de drenagem	0,88	0,84	0,69	
Floresta	0,76	0,70	0,64	Trecho de Massa d´água	0,93	0,92	0,86	
Mangue	0,91	0,81	0,59					

Tabela 5.16: Valores da QS por classe

Vale ser ressaltado que os valores de normalização estabelecidos devem considerar a necessidade da correção atmosférica das imagens, tendo em vista que as imagens que cobrem a área de estudo apresentam valores de reflectância distintos em funções das condições do sensor e da atmosfera no momento da aquisição.

5.3.2 Avaliação da Qualidade da Detecção das Extensões

A proposta da Qualidade da Detecção das Extensões (QDE) é mensurar, em termos gerais, a quantidade de elementos extraídos das imagens expresso através dos comprimentos, no caso de feições lineares, e perímetros, no caso de feições poligonais.

Para a elaboração e edição dos dados extraídos, incialmente foram consideradas as extrações geradas após a segmentação, com a presença de

todos os polígonos, independente da dimensão das áreas extraídas. Pretendese, pelo menos de forma parcial, avaliar a dimensão mínima extraída, para cada classe e conhecer o potencial, em termos de tamanho do objeto, que pode ser estabelecido em termos de interpretabilidade.

Para uma avaliação mais completa da capacidade de detecção de elementos pequenos, comparou-se o tamanho dos traçados completos extraídos, com os mesmos trechos da base de referência, separando em classes de acordo com as dimensões mínimas para o atendimento à determinada escala.

Vale ser ressaltado que a escolha da base 1:25.000, elaborada pelo IBGE, para ser a referência não tem como objetivo avaliar se as feições extraídas podem atingir a essa escala. O objetivo seria comparar com o mundo real, mas não sendo possível, optou-se por uma base cartográfica com maior detalhamento possível e porque se entende que os sensores estudados se prestam para escalas menores do que esta em termos de cartografia de referência. Por isso, a base 1:25.000 foi usada como se fosse o mundo real. Ainda sim, foram realizados *trackings* onde foi possível, além da validação da classificação no campo, ficando bastante semelhante com a base de referência.

A tabela 5.17 apresenta o percentual do número de traçados para as dimensões mínimas da classe massa d´água de cada escala.

		1:25.000	1:50.000	1:100.000	1:250.000
Classe	Sensor	$(10000 m^2)$	≥ 10000 m ²	≥ 40000 m ²	$> 250000 \text{ m}^2$
		<10000111	<40000 m ²	$< 250000 m^2$	2 20000 m
massa d'água	RE	89,47 %	94,44 %	-	100%
massa a agaa	AVNIR-2	78,94 %	88,88 %	-	100%
	OLI	0 %	5,55%	-	100%

Tabela 5.17: Percentual de elementos de massa d´água extraídos completos por dimensão de área.

A avaliação dessa classe ficou um pouco comprometida em virtude da falta de elementos com dimensões entre 40.000 e 250.000 m², de forma que a

única massa d'água maior que 250.000 m² representa o oceano. Mas, de qualquer forma, há um bom resultado para as massas d'água extraídas no RapidEye, já que foi possível extrair uma quantidade significativa de elementos com dimensões menores que 10.000 m² Nesse estudo, o critério de qualidade para a adequação à uma determinada escala foi estabelecido a partir do valor percentual mínimo de 90 %, considerado como resultado satisfatório. Dessa forma, apenas o RapiEye atenderia ao percentual para a escala 1:50.000, enquanto os dados do AVNIR-2 e OLI estariam adequados à escala 1:250.000.

A tabela 5.18 apresenta o percentual do número de traçados para as dimensões mínimas das classes de vegetação para cada escala. Nota-se que os valores de representações mínimas são diferentes em relação à massa d'água.

		1:25.000	1:50.000	1:100.000	1:250.000
Classe	Sensor	< 62500 m ²	≥ 62500 m ²	≥ 250000 m ²	≥ 1562050m ²
			< 250000 m ²	< 1562050m ²	
Campo	RE	86,66 %	100 %	100 %	100%
Campo	AVNIR-2	85,71%	100 %	100 %	100%
	OLI	85,71%	100 %	100 %	100%
	RE	0 %	100 %	100%	100%
Cultivo	AVNIR-2	0 %	100%	100 %	100%
	OLI	0 %	100 %	100 %	100%
	RE	90,47 %	95,45 %	100 %	100%
Floresta	AVNIR-2	90,47 %	95,45 %	100 %	100%
	OLI	85,71%	100 %	100 %	100%
	RE	100 %	100 %	100%	100 %
Mangue	AVNIR-2	100 %	100 %	100%	100%
	OLI	100 %	100 %	100%	100%

Tabela 5.18: Percentual de elementos da classe vegetação extraído	os
completos por dimensão de área.	

Percebe-se que para as extrações dos polígonos das classes de vegetação, as imagens dos três sensores atenderiam de forma plena as

dimensões mínimas extraídas para a especificação na escala 1:50.000, assim como a classe mangue, nos três sensores, atenderia também à escala 1:25.000, escala onde se observa uma diferença entre as imagens dos sensores. A classe floresta extraída nas imagens RapidEye e AVINIR-2, por exemplo, possui 90,47 % das áreas abaixo de 62.500 m² extraídas completamente, enquanto 9,53 % não foram extraídas. Considerando a faixa de 90 % como valor ideal, pode-se considerar apenas essas extrações como adequadas para a escala 1:25.000. Já os segmentos de floresta extraídas a partir do sensor OLI atenderiam à escala 1:50.000, assim como a classe cultivo extraída nos sensores RapidEye, AVNIR-2 e OLI. Mas é na classe campo que estão os resultados menos satisfatórios, já que nas imagens dos três sensores, o percentual de polígonos extraídos cuja área é de até 62.500 m² não ultrapassa 90 %. Ou seja, a classe seria adequada apenas para a escala 1:50.000.

A tabela 5.19 apresenta a mesma análise para a classe trecho de massa d'água, que apesar de ser uma classe poligonal, existe uma especificação em termos de comprimento mínimo para cada escala.

Classe	Sensor	1:25.000	1:50.000	1:100.000	1:250.000
		< 250 m	≥ 250 m	≥500 m	≥ 1250 m
		< 200 m	< 500 m	< 1250 m	
Trecho de massa	RE	66 %	73,33 %	100%	100%
d´água	AVNIR-2	56,66 %	66 %	100%	100%
	OLI	36,66 %	66 %	100%	100%

Tabela 5.19: Percentual de elementos de trecho de massa d´água extraídos completos por comprimento.

Os resultados mostram que apenas a partir dos elementos com comprimentos maiores que 500 metros há um bom percentual de elementos extraídos completamente. Abaixo desse valor, o percentual de elementos extraídos diminui para 73,33 % na imagem RapidEye e 66% nos outros dois sensores. A tabela 5.20 apresenta o percentual de elementos de trecho de drenagem extraídos completos por comprimento mínimo extraído.

		1:25.000	1:50.000	1:100.000	1:250.000
Classe	Sensor	<1000 m	≥ 1000	≥ 2000	> 5000 m
			< 2000 m	< 5000 m	
	RE	20 %	47,22%	90,08 %	-
Trecho de drenagem	AVNIR-2	10,66 %	33,33 %	70,05 %	-
	OLI	0%	16,66 %	60,73 %	-

Tabela 5.20: Percentual de elementos de trecho de drenagem extraídos completos por comprimento mínimo extraído.

Para os trechos de drenagem, os resultados mostram que para as extensões menores que 2000 metros, os percentuais de elementos extraídos de forma completa são baixos, não atingindo a metade no caso da extração do RapidEye. Para os trechos maiores que 2000 metros, esse percentual aumenta para 90%, podendo ser considerado satisfatório, porém próximo do limite do que está se considerando como ideal. A extração das imagens do AVNIR-2 e OLI não estariam adequadas para a escala 1:100.000 em termos de representação mínima. Poderia avaliar as dimensões para 1:250.000, mas não foram encontrados elementos com 5000 metros, valor de extensão mínima para essa escala.

No caso de feições lineares, como existem trechos descontínuos na maioria das classes, os valores com as dimensões mínimas representadas podem apresentar apenas partes de um elemento. No caso da ferrovia, por exemplo, a extração foi interrompida em várias partes. Por isso, foram considerados os segmentos lineares de arruamento e rodovia de leito natural, onde foram encontrados elementos completos comparados com a base de referência, No caso das rodovias pavimentadas, geralmente os trechos são bastante longos, o que não ajuda nessa avaliação da dimensão mínima dos elementos. A tabela 5.21 apresenta o percentual de elementos de rodovia de leito natural extraídos de forma completo, considerando o comprimento mínimo extraído.

Tabela 5.21: Percentual de elementos de rodovia de leito natural extraíd	los
completos por extensão mínima.	

		1:25.000	1:50.000	1:100.000	1:250.000
Classe	Sensor	<1000 m	≥ 1000	≥ 2000	> 5000 m
			< 2000 m	< 5000 m	
	RE	57,35 %	82,33 %	92,66 %	-
Rodovia de	AVNIR-2	43,33 %	80,03 %	90,09 %	-
leito natural	OLI	29,66 %	72,23 %	90,09 %	-

Nota-se que os percentuais das extensões mínimas extraídas para rodovia de leito natural nas imagens dos três sensores ultrapassam 90 % dos trechos extraídos com mais de 2000 metros de extensão, considerado como referência de extensão mínima para representação na escala 1:100.000. Comprimentos menores que 2000 metros também são extraídos, porém existe um percentual maior de elementos extraídos parcialmente.

A tabela 5.22 apresenta o percentual de elementos de arruamento extraídos de forma completo considerando o comprimento mínimo extraído. Vale destacar que os valores não se referem à malha de ruas, mas aos trechos de arruamento.

Tabela 5.22: Percentual de elementos de arruamento extraídos completos por extensão mínima.

		1:25.000	1:50.000	1:100.000	1:250.000
Classe	Sensor	<250 m	≥ 250	≥ 500	> 1000 m
			< 500 m	< 1000 m	
	RE	37,36 %	0 %	-	-
Arruamento	AVNIR-2	9,89 %	0 %	-	-
	OLI	0 %	0 %	-	-

No caso do arruamento, todos os elementos da base de referência possuem extensões menores que 500 metros. Foram extraídas completamente apenas um pequeno percentual de ruas com até 250 metros, que formam a maioria da rede de arruamentos. Nenhuma rua entre 250 e 500 metros foi extraída de forma completa nos três sensores.

Para a avaliação da interpretabilidade e para realizar uma análise comparativa com a base cartográfica 1:25.000, foi necessária a fusão de polígonos próximos, conforme apresentado na figura 5.27.

Originalmente foram extraídos todos os polígonos e linhas passíveis de extração. Porém, quando duas ou mais massas d'água estiverem separadas por uma distância inferior a 12,5m (valor adaptado segundo especificação técnica do IBGE na escala 1:100.000) essas foram fundidas em uma única.



Figura 5.27: Exemplo de fusão entre polígonos.

Esse caso ocorre, por exemplo, quando existe um trecho rodoviário ou ferroviário interceptando uma classe de vegetação. O ideal seria manter os dois polígonos, porém para manter o mesmo padrão de comparação com a base 1:25.000 optou-se por seguir esse procedimento, cuja execução altera as características de forma e posição, parâmetros usados como referência para avaliação a detecção. Além disso, ao ser feita a contagem do número de polígonos identificados e das áreas mapeadas, em Km², há de se considerar certa diferença.

Dessa forma, foram somadas as extensões de todos os elementos extraídos nos seis recortes da área de estudo e comparadas com as feições correspondentes na base cartográfica usada como referência.

A tabela 5.23 mostra o percentual de omissão por classe e por sensor, ou seja, a quantidade de elementos não extraídos nas imagens orbitais que existem na base de referência.

Classe	RE	AVNIR-2	OLI
Arruamento	65,06	92,22	100,00
Campo	15,18	11,50	11,63
Cultivo	8,94	15,04	11,99
Ferrovia	12,19	41,40	57,58
Floresta	7,81	8,04	6,41
Mangue	0,26	1,30	3,51
Massa d´água	1,89	6,48	8,77
Rodovia leito natural	5,02	12,99	34,34
Rodovia pavimentada	3,59	14,63	18,71
Trecho de drenagem	67,16	84,18	90,84
Trecho de massa d´água	6,32	4,71	10,34

Tabela: 5.23: Percentual de erros de omissão das classes por sensor.

Os valores foram padronizados entre o intervalo de 0 e 1 considerando a taxa de acerto, ou seja, do que não foi omitido. Esse procedimento serve para o cálculo da QDE, um dos parâmetros para a geração do índice de detecção. A tabela 5.24 mostra o resultado final do QDE.

Classo	QDE					
Classe	RE	AVNIR-2	OLI			
Arruamento	0,35	0,08	0,00			
Campo	0,85	0,89	0,89			
Cultivo	0,91	0,85	0,88			
Ferrovia	0,88	0,59	0,43			
Floresta	0,92	0,92	0,94			
Mangue	1,00	0,99	0,97			
Massa d´água	0,98	0,94	0,91			
Rodovia leito natural	0,95	0,87	0,71			
Rodovia pavimentada	0,97	0,86	0,81			
Trecho de drenagem	0,33	0,16	0,09			
Trecho de massa d´água	0,94	0,96	0,90			

Tabela 5.24: Valores da Qualidade da Detecção de Extensões

A tabela mostra que as classes de vegetação apresentam bons resultados, sendo omitidas poucas áreas em relação à base de referência, com destaque para a área de mangue na imagem RapidEye, onde tudo o que foi extraído constituiu efetivamente como mangue na base de referência.

Os piores resultados apareceram na classe trecho de drenagem, ou seja, existem muitos canais que não foram extraídos. Vale salientar que os trechos de drenagem são representados como linhas e não necessariamente estão topologicamente relacionados ao respectivo trecho de massa d'água. A maioria dos rios da bacia de drenagem apresentam larguras pouco expressivas, incapazes de sensibilizar os pixels nas imagens. Por isso, o trecho de massa d'água e a massa d'água possuem resultados melhores, uma vez que tendem a apresentar dimensões mais significativas.

Outra classe com baixo aproveitamento em termos de quantidade de comprimento extraído foi o arruamento, que em imagens de média resolução não foram detectadas de forma clara, em função do contexto do urbano. De qualquer forma, os melhores resultados foram em áreas áreas urbanas isoladas, onde não existem grandes estruturas e construções que dificultam a detecção dessas vias.

5.3.3 Avaliação da Qualidade de Detecção dos Objetos

Com o mesmo propósito do parâmetro de qualidade anterior, o objetivo da Qualidade de Detecção dos Objetos (QDO) é quantificar os erros de omissão, porém quantificar em termos do número de objetos presentes, utilizando-se como referência o cálculo da exatidão do produtor, estabelecido através da relação entre o número de objetos extraídos por classe com seu respectivo número na base de referência. Para se obter o QDO de massa d'água extraída do RapidEye, por exemplo, divide-se o valor 18 (número de objetos extraídos) por 19 (número de objetos de referência), obtendo-se a exatidão do produtor, ou a QDO de 0,95.

A tabela 5.25 mostra as contagens do número dos objetos poligonais e lineares extraídos do sensor RapidEye, dos objetos da base de referência e o valor do QDO calculado.

238

Classe	Extraído	Referência	QDO
Arruamento	34	91	0,37
Campo	16	20	0,80
Cultivo	7	9	0,78
Ferrovia	1	1	1,00
Floresta	68	71	0,96
Mangue	16	17	0,94
massa d´água	18	19	0,95
rodovia leito natural	64	69	0,93
rodovia pavimentada	4	4	1,00
trecho de drenagem	41	80	0,34
Trecho de massa d´água	32	41	0,78

Tabela 5.25: Valores da Qualidade da Detecção dos Objetos das classes extraídas do sensor RapidEye.

Nota-se que os piores resultados para o RapidEye foram encontrados para as classes arruamento e trecho de drenagem, ambas feições lineares, confirmando-se os valores encontrados na Qualidade de Detecção das Extensões. Já as classes rodovia pavimentada e ferrovia apresentaram os melhores resultados, de forma que o número de elementos extraídos é o mesmo encontrado na base de referência. Confirmando-se o resultado da QDE, os valores obtidos na QDO foram altos, com exceção das duas classes mencionadas anteriormente.

A tabela 5.26 mostra as contagens do número de objetos poligonais e lineares extraídos do sensor AVNIR-2, dos objetos da base de referência e o valor do QDO calculado.

Classe	Extraído	Referência	QDO
Arruamento	9	91	0,10
Campo	18	20	0,90
Cultivo	7	9	0,78
Ferrovia	1	1	1,00
Floresta	68	71	0,96
Mangue	16	17	0,94
massa d´água	16	19	0,84
rodovia leito natural	52	69	0,75
rodovia pavimentada	4	4	1,00
trecho de drenagem	27	121	0,22
Trecho de massa d´água	27	41	0,66

Tabela 5.26: Valores da Qualidade da Detecção dos Objetos das classes extraídas do sensor AVNIR-2.

Comparando-se com os valores do RapidEye, os valores de QDO obtidos do AVNIR-2 foram praticamente mantidos para as classes de vegetação. Inclusive houve um aumento do número de objetos extraídos corretamente da classe cultivo, porém houve uma redução da extensão da área delimitadas para essa classe, como se observa no valor da QDE. Já para as classes de sistema de transporte (principalmente arruamento e rodovia de leito natural) e hidrografia as reduções dos valores foram significativas, confirmando-se o QDE.

A tabela 5.27 mostra as contagens do número de objetos poligonais e lineares extraídos do sensor OLI, dos objetos da base de referência e o valor do QDO calculado.

Classe	Extraído	Referência	QDO
Arruamento	0	91	0,00
Campo	18	20	0,90
Cultivo	6	9	0,67
Ferrovia	1	1	1,00
Floresta	65	71	0,92
Mangue	16	17	0,94
massa d´água	1	19	0,05
rodovia leito natural	44	69	0,64
rodovia pavimentada	4	4	1,00
trecho de drenagem	12	121	0,10
Trecho de massa d´água	21	41	0,51

Tabela 5.27: Valores da Qualidade da Detecção dos Objetos das classes extraídas do sensor OLI.

A classe que se destaca é a massa d´água que apresenta valores altos para as extrações no RapidEye e AVNIR-2, mas apresenta o valor de QDO bastante reduzido no OLI. Tal fato é explicado porque a maioria dos objetos possuem dimensões reduzidas, não sendo capazes de serem detectadas pelo sensor. A única massa d'água detectada corresponde ao oceano, com área bastante expressiva, por isso o valor da QDE foi bastante elevada.

5.3.4 Avaliação da Qualidade de Forma

Conforme mencionado anteriormente, a proposta da Qualidade de Forma (QF) é permitir uma avaliação mais adequada dos contornos dos elementos extraídos, a fim de saber se o seu traçado está próximo de uma representação considerada ideal. Para isso, será comparada a distância média entre os vértices dos traçados extraídos (DMVE) com a distância média dos vértices dos traçados da base cartográfica de referência (DMVR). A relação entre esses valores permite definir a relação de forma (RF) para cada classe e por sensor. Para a construção do cálculo foram selecionadas, de forma aleatória, amostras representativas das classes analisadas nesse estudo. O total de amostras correspondeu a, no mínimo, 20 % do total de elementos de cada classe.

Os valores de RF acima de 1 indicam uma menor distância média entre os vértices na base extraída do que na base de referência, o que significa um bom resultado. A tabela 5.28 apresenta a distância média calculada para as amostras dos elementos extraídos nos três sensores.

Classe	RE		AVNIR-2				OLI		
Chabbe	DMVR	DMVE	RF	DMVR	DMVE	RF	DMVR	DMVE	RF
Arruamento	24,82	17,78	1,40	20,13	18,81	1,07	-	-	-
Campo	21,92	15,81	1,39	20,01	23,06	0,87	22,32	28,34	0,79
Cultivo	28,36	35,07	0,81	28,35	39,90	0,71	36,40	44,96	0,81
Ferrovia	16,95	22,74	0,75	16,95	42,31	0,40	16,95	62,13	0,27
Floresta	25,29	15,82	1,60	26,40	23,33	1,13	28,04	26,10	1,07
Mangue	23,99	18,38	1,30	25,19	23,67	1,06	25,99	20,85	1,25
Massa d água	26,02	19,97	1,30	26,02	22,46	1,16	26,02	22,64	1,15
Rodovia leito									
natural	18,31	15,62	1,17	17,67	18,67	0,95	18,37	25,48	0,72
Rodovia									
pavimentada	21,41	19,88	1,08	21,41	24,15	0,89	21,41	28,78	0,74
Trecho de									
drenagem	19,68	25,21	0,78	22,40	24,14	0,93	19,46	28,03	0,69
Trecho de									
massa d´água	25,48	16,60	1,53	25,48	20,62	1,24	25,48	37,11	0,69

Tabela 5.28: Valores de distância média dos vértices da base de referência (DMVR), da base extraída (DMVE) e a relação da forma (RE).

Nota-se que na maioria das classes o valor de RF é maior que 1. A justificativa para isso está associada, principalmente, ao processo de segmentação onde os polígonos são gerados de forma automática, acompanhando o contorno dos pixels da imagem, sendo os casos da extração da vegetação e hidrografia. No caso das feições lineares do sistema de transporte, a aquisição das linhas é feita de forma semiautomática e os

elementos tendem a apresentar formas mais retilíneas, necessitando de menos vértices quando comparadas com as classes de vegetação e hidrografia.

Os valores obtidos podem ser comparados com o estudo sobre a relação entre distância média dos vértices em termos de escala. A tabela 5.29 mostra a distância média dos vértices (DMV) das bases cartográficas 1:25.000, 1:50.000, e dos valores projetados para a escala 1:100.00 e 250.000.

Tabela 5.29: Comparação da	distância	média	entre a	is bases	de referé	ència e
	projeta	adas				

	DMV Base	DMV Base	DMV Projeção	DMV Projeção
	1:25.000	1:50.000	1:100.000	1:250.000
Média	17,87	27,62	39,25	50,94
Desvio padrão	10,62	15,29	21,25	29,33

Comparando-se os valores das duas tabelas anteriores, nota-se que as distância médias dos vértices das classes arruamento, campo, floresta, rodovia de leito natural e trecho de massa d´água estão com valores abaixo da distância média encontrada na base 1:25.000 Já as classes ferrovia, mangue, massa d água, rodovia pavimentada e trecho de drenagem atenderiam ao valor médio encontrado para 1:50.000, enquanto o campo só estaria com valor abaixo da distância média abaixo para a projeção 1: 100.000. Para o AVNIR-2, nenhuma classe teria a distância média entre vértices dentro da tolerância na escala 1:25.000, enquanto a classe cultivo passaria para uma qualidade na escala 1:250.000. Para os dados extraídos do sensor OLI, há o aumento para quatro de classes atendendo somente 1:100.000.

Dessa forma, os dados de relação de forma foram normalizados para que fosse possível escalonar em intervalo entre zero e um, comparando-se com os outros parâmetros do índice de detecção. Tais valores correspondem ao Índice de forma (IF) e são mostrados na tabela 5.30.

Classe	QF		
	RE	AVNIR-2	OLI
Arruamento	0,85	0,60	-
Campo	0,84	0,45	0,39
Cultivo	0,84	0,33	0,41
Ferrovia	0,36	0,10	0,00
Floresta	1,00	0,65	0,60
Mangue	0,78	0,60	0,73
Massa d´água	0,78	0,67	0,66
Rodovia leito natural	0,68	0,51	0,34
Rodovia pavimentada	0,61	0,46	0,36
Trecho de drenagem	0,38	0,49	0,32
Trecho de massa d´água	0,95	0,73	0,31

Tabela 5.30: Valores de Qualidade de Forma

Os resultados mostram que as classes floresta e trecho de massa d'água apresentaram os melhores resultados para o sensor RE. No caso do AVNIR, a classe floresta não apresentou um valor tão expressivo como no sensor anterior. Os valores do AVNIR são razoáveis quando comparados com os resultados do RapidEye. No caso dos dados extraídos do OLI, os valores são mais baixos ainda, com destaque para a massa d'água e floresta.

5.3.5 Avaliação da Qualidade Posicional

Além de avaliar a forma dos elementos extraídos, outra característica importante para analisar a detecção é o posicionamento em relação ao que se considera com ideal. Nesse estudo, está sendo utilizada a base cartográfica do IBGE na escala 1:25.000 como dado de referência, associado ao trabalho de validação no campo. Uma das atividades desenvolvidas durante o campo foi o *tracking* das vias rodoviárias e arruamentos nos seis recortes na área de estudo.

Para se conhecer as características posicionais da base cartográfica de referência, foi feita uma comparação da discrepância média entre os elementos

extraídos nos três sensores com as linhas representativas na base cartográfica 1:25.000 e do *tracking*. A tabela 5.31 apresenta uma comparação entre as classes entre os valores de discrepância média das linhas testadas dos elementos extraídos com a base do IBGE e com o *tracking*.

	Discrepância média (m)					
	RE	RE AV		R-2	OI	_1
Classe		Base		Base		Base
	Tracking	IBGE	Tracking	IBGE	Tracking	IBGE
Arruamento	8,38	11,88	16,14	19,04	-	-
Rodovia Leito Natural	4,45	5,52	6,34	8,18	8,30	9,81

10.02

Rodovia pavimentada

8.31

Tabela 5.31: Discrepância média e	estre a base	extraída	com a ba	se do l	BGE e
	o tracking.				

Os resultados mostram que as diferenças entre as discrepâncias são relativamente pequenas para os três sensores, indicando uma boa confiabilidade com a base de referência para a análise da exatidão posicional. Dessa forma, realizou-se a avaliação posicional das bases extraídas com a base 1:25.000.

12,70

19,17

15.20

22,72

A figura 5.28 apresenta os valores de discrepância, a média dos erros e o desvio padrão para as classes avaliadas nos três sensores.









Figura 5. 28: Valores das discrepâncias médias das amostras para as classes extraídas nos três sensores.

	Discrepância (m)			
Classe	RE	AVNIR-2	OLI	
Arruamento	11,89	18,95	-	
campo	12,06	15,77	17,33	
cultivo	14,51	14,03	24,46	
ferrovia	10,23	13,67	20,30	
Floresta	15,10	21,29	20,38	
Mangue	19,30	30,68	36,15	
massa d água	8,15	12,62	15,32	
Rodovia Leito Natural	11,43	18,41	17,69	
rodovia pavimentada	13,42	22,93	25,80	
Trecho de drenagem	23,39	28,37	31,83	
Trecho de massa d água	16,89	24,08	27,87	

A tabela 5.32 apresenta os valores de CE90 para as classes extraídas. Tabela 5.32: valores de CE90 para as classes extraídas nos três sensores.

Dessa forma, considerando-se os valores acima mencionados, podemse associar as classes com seguintes escalas, considerando o Padrão de Exatidão Cartográfica (PEC), conforme mostra a tabela 5.33.

Classe	RE	AVNIR-2	OLI
Arruamento	1:25.000 A	1:25.000 B	-
Campo	1:25.000 A	1:25.000 B	1:25.000 B
Cultivo	1:25.000 B	1:25.000 B	1:25.000 C
Ferrovia	1:25.000 A	1:25.000 B	1:25.000 C
Floresta	1:25.000 B	1:25.000 C	1:25.000 C
Mangue	1:25.000 B	1:50.000 B	1:50.000 B
Massa d água	1:10.000 C	1:25.000 B	1:25.000 B
Rodovia Leito Natural	1:25.000 A	1:25.000 B	1:25.000 B
Rodovia pavimentada	1:25.000 B	1:25.000 C	1:50.000 B
Trecho de drenagem	1:25.000 C	1:50.000 B	1:50.000 B
Trecho de massa d água	1:25.000 B	1:25.000 C	1:50.000 B

Tabela 5.33: Classificação por escala segundo o PEC.

Enquadrando-se os valores de CE 90 para a formulação da Qualidade Posicional, obtêm-se os valores estabelecidos na tabela 5.34.

Classe	RE	AVNIR-2	OLI
Arruamento	0,5	0,45	0
Campo	0,5	0,45	0,45
Cultivo	0,45	0,45	0,4
Ferrovia	0,5	0,45	0,4
Floresta	0,45	0,4	0,4
Mangue	0,45	0,35	0,35
Massa d água	0,55	0,45	0,45
Rodovia Leito Natural	0,5	0,45	0,45
rodovia pavimentada	0,45	0,4	0,4
Trecho de drenagem	0,4	0,35	0,35
Trecho de massa d água	0,45	0,4	0,35

Tabela 5.34: valores da Qualidade Posicional por classe para os três sensores.

Nota-se que no caso do RapidEye o resultado menos satisfatório foi para o trecho de drenagem, que se se enquadrou na escala 1:25.000 classe C, enquanto a massa d'água apresentou o melhor resultado. Já para o AVNIR, além do trecho de drenagem, a classe mangue apresentou o resultado menos satisfatório, enquanto houve um equilíbrio entre as demais classes, a maioria sendo adequadas para a classe 1:25.000 B. Já para o sensor OLI os piores resultados constituem as classes mangue, trecho de drenagem e trecho de massa d água, enquanto o melhor resultado foi da classe campo.

5.3.6 Cálculo do Indicador de detecção

Para o cálculo do Indicador de detecção, foram integrados todos os parâmetros de qualidade, através do uso de uma média aritmética simples. A tabela 5.35 apresenta os valores dos parâmetros de detecção, separados por classe, para o sensor RapidEye.

Classes	QS	QDE	QDO	QF	QP	IDET
Arruamento	0,9	0,35	0,37	0,85	0,5	0,59
Campo	0,82	0,85	0,8	0,84	0,5	0,76
Cultivo	0,49	0,91	0,78	0,84	0,45	0,69
Ferrovia	0,63	0,88	1	0,36	0,5	0,67
Floresta	0,76	0,92	0,96	1	0,45	0,82
Mangue	0,91	1	0,94	0,78	0,45	0,82
Massa d água	0,87	0,98	0,95	0,78	0,55	0,83
Rodovia Leito Natural	0,98	0,95	0,93	0,68	0,5	0,81
Rodovia pavimentada	0,98	0,97	1	0,61	0,45	0,80
Trecho de drenagem	0,88	0,33	0,34	0,38	0,4	0,47
Trecho de massa d água	0,93	0,94	0,78	0,95	0,45	0,81
Média	0,83	0,83	0,80	0,73	0,47	0,73

Tabela 5.35: Indicador de detecção para as classes extraídas no RapidEye.

Os resultados mostram que a classe massa água apresentou melhor resultado, tanto no valor do indicador quanto na escala adequada para a exatidão posicional. Todas as variáveis de qualidade apresentaram resultados satisfatórios

Além disso, as classes de vegetação também apresentaram resultados bons, assim como o trecho de massa d´água.

A classe trecho de drenagem apresentou um valor um pouco abaixo das demais classes, principalmente porque apresentaram a qualidade de forma abaixo dos demais. Esse fato pode ser explicado pela menor quantidade de vértices oriunda da vetorização semiautomática, que acaba sendo comparada com uma base cartográfica de referência produzida através de processo manual.

A tabela 5.36 apresenta os valores dos Indicadores de detecção, por classe, para o sensor AVNIR-2.

Classe	QS	QDE	QDO	QF	QP	IDET
Arruamento	0,66	0,08	0,1	0,6	0,45	0,38
campo	0,7	0,89	0,9	0,45	0,45	0,68
cultivo	0,43	0,85	0,78	0,33	0,45	0,57
ferrovia	0,54	0,59	1	0,1	0,45	0,54
Floresta	0,7	0,92	0,96	0,65	0,4	0,73
Mangue	0,81	0,99	0,94	0,6	0,35	0,74
massa d água	0,84	0,94	0,84	0,67	0,45	0,75
Rodovia Leito Natural	0,94	0,87	0,75	0,51	0,45	0,70
rodovia pavimentada	0,95	0,86	1	0,46	0,4	0,73
Trecho de drenagem	0,84	0,16	0,22	0,49	0,35	0,41
Trecho de massa d água	0,92	0,96	0,66	0,73	0,4	0,73
Média	0,76	0,74	0,74	0,51	0,42	0,63

Tabela 5.36: Indicador de detecção para as classes extraídas no AVNIR-2

Apesar dos resultados, em termos quantitativos, serem menores que os valores do RapidEye, possuem as mesmas características em termos de detecção das classes. Ou seja, a massa d'água apresentou o melhor resultado, assim como os trechos de massa d'água também apresentaram valor do IDET acima das demais classes. O trecho de drenagem também apresentou resultado com valor mais baixo, sendo igual ao resultado do arruamento.

A tabela 5.37 apresenta os valores dos Indicadores de detecção, separados por classe, para o sensor OLI.

Classe	QS	QDE	QDO	QF	QP	IDET
Arruamento	0	0	0	0	0	0
Campo	0,51	0,89	0,90	0,39	0,45	0,63
Cultivo	0,19	0,88	0,67	0,41	0,4	0,51
Ferrovia	0,32	0,43	1,00	0,00	0,4	0,43
Floresta	0,64	0,94	0,92	0,60	0,4	0,7
Mangue	0,59	0,97	0,94	0,73	0,35	0,72
Massa d água	0,79	0,91	0,05	0,66	0,45	0,57
Rodovia Leito Natural	0,89	0,71	0,64	0,34	0,45	0,61
Rodovia pavimentada	0,90	0,81	1,00	0,36	0,4	0,69
Trecho de drenagem	0,69	0,09	0,10	0,32	0,35	0,31
Trecho de massa d água	0,86	0,9	0,51	0,31	0,35	0,70
Média	0,58	0,68	0,61	0,37	0,36	0,53

Tabela 5.37: Indicador de detecção para as classes extraídas no OLI.

Em relação aos dados do sensor OLI, nota-se que os valores do IDET são mais baixos em relação aos outros sensores. Porém, nota-se a mesma tendência de resultados melhores para a massa d´água, reflexo de um bom valor do índice de forma.

A média do Indicador de Detecção para as classes do RapidEye foi de 0,73, para o AVNIR foi de 0,63 e para o OLI foi de 0,53. Conforme esperado, os resultados mostram que o potencial de detecção do alvo possui uma relação direta com a resolução espacial do sensor. Imagens com maiores resoluções espaciais tendem a detectar mais objetos e de forma mais exata do ponto de vista posicional.

5.3.7 Conclusões

Os cinco parâmetros utilizados para a avaliação da detecção se mostraram apropriados para atender ao propósito de análise das características da representação espacial, estabelecidas através de estruturas linear ou poligonal. A Qualidade de Segmentação, primeiro parâmetro elaborado, refletiu principalmente o papel da radiometria no processo de construção dos traçados, ao se estabelecer um valor para mensurar a homogeneidade interna dos pixels do segmento e compará-los com os valores dos pixels dos segmentos vizinhos, quantificando a separabilidade existente entre os segmentos. No caso da segmentação multiresolução, foram comparadas duas técnicas: uma com a abordagem empírica, através de análise visual e testes de parametrização através de tentativa e erro, e outra através de uma função que fornece ao usuário o valor adequado para a segmentação. Esse último de mostrou bastante interessante, com resultados melhores do que o método empírico. De qualquer forma, são recomendados mais testes em virtude do pouco conhecimento das potencialidades desse algoritmo.

A Qualidade da Detecção das Extensões permitiu avaliar, principalmente, os erros de omissão durante o processo de extração, comparando as extensões lineares e áreas dos polígonos das classes extraídas com os elementos da base cartográfica de referência. Para cada classe foi gerado um valor que procura quantificar o grau de detecção em termos de dimensões dos elementos extraídos.

As dimensões dos elementos extraídos de forma completa foram classificadas de acordo com o tamanho mínimo de representação por escala, cujo objetivo é avaliar a adequação por escala. Os resultados permitiram verificar que cada classe possui uma adequação específica para cada escala.

Além da quantidade de elementos, as suas formas e posições em relação à base cartográfica de referência foram avaliadas, respectivamente através da Qualidade de Forma e Qualidade Posicional, cuja construção possibilitou uma reflexão sobre o potencial da detecção apropriado para cada escala.

É importante considerar que a Qualidade da Forma constitui o parâmetro mais instável, ainda não propiciando uma confiança plena na sua utilização. Houve tentativas de realizar projeções para escalas menores (1:100.000 e 1:250.000) de forma direta a partir das amostras, mas os resultados não foram bons. O melhor cenário ocorreu com o uso da média das amostras, porém ainda há a necessidade de realizar ajustes para o uso de uma metodologia que permita oferecer uma maior confiança. Percebe-se que o processo de detecção pode ser analisado em diferentes abordagens para atender a interpretabilidade de feições cartográficas em imagens orbitais.

Em termos posicionais, o traçado extraído pode ser adequado para uma determinada escala, mas em termo de representação do tamanho mínimo, essa expectativa não é atendida, já que a imagem do insumo não permite que se extraia um elemento que apresenta determinado tamanho. Além disso, a forma do elemento pode ser muito generalista para representação, necessitando adequá-la para uma menor escala. No capítulo referente à construção do índice de interpretabilidade, todos os parâmetros de qualidade de detecção e identificação serão analisados sob a ótica da qualidade posicional, da forma e da representação mínima.

6. INDICADOR DE IDENTIFICAÇÃO

Após a extração dos elementos de uma determinada classe, a próxima etapa para a construção do índice de interpretabilidade é a avaliação do processo de identificação, ou seja, confirmar se a partir da imagem é possível classificar corretamente as classes representativas para cada categoria. Uma feição de vegetação, por exemplo, pode ser uma área de cultivo ou um fragmento florestal, assim como um trecho de sistema de transporte pode ser uma rodovia ou ferrovia.

Dois princípios de qualidade são importantes para avaliar se um dado foi classificado de forma adequada: a completude e a exatidão temática. Evidentemente, a escolha pelo critério de exatidão temática se deve ao fato da possiblidade de uso de métodos quantitativos de avaliação dos erros de classificação, cuja abordagem está diretamente associada ao segundo princípio da interpretabilidade: a identificação. Ou seja, após o elemento ser extraído, a questão é descobrir se a imagem oferece condições para a identificação correta do alvo. Eventualmente uma imagem pode oferecer boas condições para se extrair elementos de uma determinada classe, mas não ser adequada à sua identificação.

No caso da completude, são avaliados os erros de omissão e comissão. Foi destacado no capítulo anterior que os erros de omissão representam problemas de detecção, ou seja, o elemento ou seus trechos deixam de ser extraídos em virtude das limitações de resolução da imagem ou problemas no processamento.

Quando o elemento é extraído, porém classificado de forma errada, o erro passa a ser de identificação, tendo em vista que o traçado existe, porém está identificado inadequadamente. A outra possibilidade, nesse caso, é a ocorrência de erros durante a fase de classificação, por isso torna-se importante a necessidade de validação.

Assim, os erros de omissão e comissão, apesar de estarem relacionados em termos de interpretabilidade, possuem contextos diferentes. Estão relacionados porque um erro de comissão pode gerar um erro de omissão, porém cada tipo de erro indica se houve problemas na detecção ou identificação. Um exemplo de erro de comissão encontrado frequentemente é a duplicidade, constituindo um problema onde o traçado está posicionalmente coincidente sobre outro na mesma classe. A princípio, pode não constituir um erro de duplicidade quando dois traçados iguais estão em classes diferentes, como por exemplo, as classes de arruamento e rodovia, que devem apresentar obrigatoriamente a coincidência espacial. Porém, há uma necessidade de avaliação caso a caso, pois um ou mais traçados podem estar classificados de forma errada, constituindo erros de comissão e omissão.

Além da completude, outro parâmetro de controle de qualidade do dado em termos de identificação do elemento é a exatidão temática. Nas normas ISO, a completude e a exatidão temática são tratadas como critérios de avaliação de qualidade distintos, enquanto Congalton & Green (2009) tratam a avaliação de completude como um tipo de avaliação temática. De qualquer forma, em ambas as abordagens, o significado da exatidão temática está associado à proximidade de uma determinada medida ao seu valor considerado como verdadeiro, por isso, são usados procedimentos estatísticos para avaliar essa exatidão.

Desta forma, para se estabelecer o Indicador de Identificação (IIDE), optou-se por desmembrá-lo em parâmetros de qualidade para avaliação de feições lineares e poligonais, considerando as diferentes abordagens para o controle da delimitação dos objetos. Para se avaliar a qualidade da identificação foram estabelecidos os seguintes parâmetros:

- Qualidade da Identificação das Extensões (QIE);
- Qualidade de Identificação dos Objetos (QIO);
- Qualidade de Concordância (QC).

Para cada parâmetro de qualidade, será estabelecido um valor numérico, com intervalo entre zero e um, cuja associação permitirá obter o Indicador de Identificação, tendo como objetivo mensurar o potencial de classificação nas imagens de um determinado sensor.

6.1 CONSTRUÇÃO DO INDICADOR DE IDENTIFICAÇÃO

6.1.1 Qualidade de Identificação das Extensões

Comparando-se os Indicadores de Detecção e Identificação, percebe-se que foram estabelecidos dois parâmetros de qualidade para cada indicador que vise avaliar a completude do dado, sendo que para a identificação serão abordados os erros de comissão.

O primeiro parâmetro se refere a um procedimento de avaliação das extensões efetivamente classificadas, seja através do comprimento das linhas ou extensões das áreas dos polígonos, cuja unidade de medida é estabelecida através do padrão métrico, denominado de Qualidade de Identificação das Extensões (QIE). Esse parâmetro é semelhante ao critério para avaliar a Qualidade de Detecção das Extensões (QDE), descrito no capítulo anterior. Porém, nesse caso são quantificados os valores de áreas e extensão linear dos objetos classificados, ou seja, são considerados apenas os elementos detectados.

Já a segunda abordagem pode ser analisada sob o enfoque da quantidade de elementos classificados, contabilizando-se o número de objetos presentes, sendo denominado de Qualidade de Identificação dos Objetos (QIO), semelhante à Qualidade da Detecção dos Objetos (QDO), parâmetro descrito anteriormente.

São consideradas como elementos sem erros de comissão, as áreas e comprimentos classificados corretamente na base cartográfica usada como referência ou no levantamento de campo. Assim, para se ter uma noção geral do grau de comissão, pode-se comparar a extensão das linhas e áreas dos polígonos entre duas bases cartográficas, a de referência e a classificada.

Para realizar essa comparação em feições poligonais, pode-se fazer uma operação de sobreposição entre as duas bases e calcular a área de interseção dos elementos classificados. Para feições lineares, calculam-se as extensões lineares para cada classe nas duas bases cartográficas. Posteriormente, realiza-se um processo de inspeção visual para avaliar e comparar as diferenças encontradas. Vale ser destacado que parte das diferenças encontradas pode ser oriunda dos intervalos temporais das datas entre as imagens orbitais e as ortofotos usadas na restituição da base 1:25.000. Como não estão sendo consideradas estas diferenças, assume-se neste estudo que o problema existe.

Uma vez calculada a diferença de comissão, valor que representa o excesso de elementos na base cartográfica, calcula-se a porcentagem de comissão da base extraída em relação à de referência. A equação 6.1 expressa a taxa de comissão (TC) de extração, onde x é o total da extensão dos perímetros dos polígonos e comprimentos lineares com erros de comissão para cada classe em um determinado recorte geográfico, enquanto y é o total da extensão dos perímetros dos perímetros e comprimentos lineares das classes na base cartográfica de referência.

O excesso de elementos em uma determinada classe pode gerar redução de elementos em outras, criando também um erro de omissão, parâmetro de completude abordado no índice de detecção.

$$TC = \frac{\sum x}{\sum y}$$
 Equação 6.1

Através desse resultado, é possível saber o valor do comprimento e perímetro sem erros de comissão, expresso também em porcentagem, permitindo a geração da Qualidade de Identificação das Extensões (QIE), obtido através do percentual efetivamente classificado, expresso a partir da equação 6.2. Porém, pode ocorrer o cenário no qual todos os elementos detectados podem ser identificados, gerando um percentual de 100 % de QIE, distorcendo a realidade da interpretação.

Sendo assim, em algumas situações, pode-se ter um baixo valor de QDE, mas um alto QIE, o que poderia criar um falso panorama de boa interpretabilidade. Então, sugere-se ponderar também o valor da qualidade de detecção nesse parâmetro, a fim de dar peso mais significativo resultado do QIE, cuja equação final é expressa abaixo:

$$QIE = QDE * (100 - TC)$$
 Equação 6.2

260

O resultado é um valor no intervalo entre 0 e 1, cujos valores mais altos se traduzem em bons resultados, ou seja, quanto maior o valor associado a cada classe, maior é o potencial da imagem na identificação dos elementos extraídos em termos de suas extensões.

A tabela 6.1 abaixo apresenta um exemplo com três sensores, para a avaliação da completude para feições representativas das categorias hidrografia, vegetação e sistema de transporte. No caso das feições de massa d água, por exemplo, o sensor de melhor resolução espacial permite detectar 77% da área extraída dos elementos. Enquanto, a imagem com pior resolução permitiria extrair apenas 30% da área.

Classe	Área/perímetro	Sens	Comissão	тс	QDE	QIE
	extraído	or	(km2/Km)			
	(km2/Km)					
Massa água		A	2 km ²	0.96	0,8	0,77
	50 km ²	В	4 km ²	0.8	0,7	0,56
		С	25 km ²	0.5	0,6	0,3
		A	60 km ²	1	0,9	0,9
Floresta	60 km^2	В	55 km²	0.91	0,9	0,82
		C	50 km ²	0.83	0,9	0,75
Rodovia		A	5 km	1	0,9	0,9
pavimentada	5 Km	В	5 km	1	0,8	0,8
		С	2,5	0,5	0,7	0,35

Tabela 6.1: Exemplo da obtenção do QIE.

Esse tipo de avaliação é importante, mas analisado isoladamente não é suficiente para um resultado mais preciso da identificação correta dos elementos, uma vez que não é possível retratar espacialmente onde os erros estão ocorrendo. Por isso, para complementar este tipo de análise, propõe-se também uma avaliação quantitativa do número de objetos.

6.1.2 Qualidade de Identificação dos Objetos

Enquanto a exatidão do produtor possibilita conhecer os erros de omissão, a exatidão do usuário possibilita conhecer os erros de comissão, correspondendo à relação entre o número de elementos detectados e classificados corretamente com o valor total dos elementos classificados na base extraída.

Os valores resultantes correspondem ao número de linhas e polígonos identificados, ao invés da extensão em metros ou quilômetros do parâmetro de qualidade de detecção mencionado anteriormente, por isso, esse parâmetro é denominado de Qualidade de Identificação dos Objetos (QIO). Para sua construção é utilizada a exatidão do usuário para avaliação específica de cala classe, expressa na equação 6.3 abaixo:

$$j = rac{n_{jj}}{n_{+j}}$$
 Equação 6.3

Onde:

 n_{jj} é o número total de unidades de amostras classificadas corretamente.

 n_{+j} é o número total de unidades de amostras classificadas.

Através desse resultado, é possível saber o número de elementos sem erros de comissão, expresso também em porcentagem, permitindo a geração da Qualidade de Identificação de Objetos (QIO), obtido através do percentual efetivamente classificado, expresso a partir da equação 6.2.

Assim como na avaliação da completude por extensão, pode ocorrer o mesmo cenário que distorça a realidade da interpretação, ou seja, a possibilidade de todos os elementos detectados serem identificados, no qual se teria um percentual de 100 % de QIO. Podem ocorrer casos de classes com baixo valor de QDO, mas um alto QIO, acarretando também em um falso panorama de boa interpretabilidade. Então, torna-se importante ponderar também o valor da qualidade de detecção nesse parâmetro, a fim de dar peso mais significativo ao resultado do QIO, cuja equação final é expressa abaixo:
QIO = QOO * j Equação 6.2

O resultado é um valor no intervalo entre 0 e 1, cujos valores mais altos se traduzem em bons resultados, ou seja, quanto maior o valor associado a cada classe, maior é o potencial da imagem na identificação em ternos quantitativos em elementos extraídos.

A tabela 6.2 abaixo apresenta um exemplo com três sensores, para a avaliação da omissão por objetos para feições representativas das categorias hidrografia, vegetação e sistema de transporte. No caso das feições de massa d'água, por exemplo, o sensor de melhor resolução espacial permite detectar 80% da área extraída dos elementos. Enquanto, a imagem com pior resolução permitiria extrair apenas 54% da área.

Classe	Área/perímetro extraído (km2/Km)	Sensor	Comissão (km2/Km)	EU	QDO	QIO
Massa água		А	2 km ²	1	0,8	0,8
	50 km ²	В	4 km ²	1	0,7	0,7
		С	25 km ²	0,9	0,6	0,54
		A	60 km ²	1	0,9	0,9
Floresta	60 km ²	В	55 km ²	1	0,9	0,9
		С	50 km ²	0.8	0,9	0,72
Rodovia		A	5 km	1	0,9	0,9
	5 Km	В	5 km	1	0,8	0,8
Parmonada		С	2,5	0,5	0,7	0,35

Tabela 6.2: Exemplo da obtenção do QIO.

As duas avaliações de completude analisadas de forma conjunta apresentam maior eficiência, pois se obtém uma avaliação mais completa em termos de integridade do dado, tanto em termos gerais usando a QIE, quanto na avaliação mais específica, através do QIO.

Para complementar a análise de identificação, propõe-se também uma avaliação de concordância entre todas as classes do mapeamento. Dessa forma, ao invés de se obter um parâmetro específico para cada classe, pode-se gerar um parâmetro de qualidade que integre as classes.

6.1.3. Qualidade de Concordância

Geralmente, quando se trata de estipular processos de avaliação da exatidão temática em dados de sensoriamento remoto, recorre-se à coleta de um determinado número de amostras para serem analisadas pela matriz de confusão. Esse método possibilita o estabelecimento de diversas inferências estatísticas para uma avaliação quantitativa e, tradicionalmente, são utilizadas a Exatidão Global e o Índice Kappa, além das acurácias do usuário e do produtor.

No caso das feições lineares existe uma limitação inerente aos algoritmos de classificação, cujo foco é utilizar um agrupamento de pixels, regiões ou um objeto. Em todos os casos a referência geométrica é o polígono, ou seja, não é possível a partir do estabelecimento de um conjunto de linhas, realizar uma classificação automática de cada uma.

Dessa forma, pode-se optar por uma identificação visual, tendo em vista que o padrão de distribuição dos elementos favorece o olhar do operador. A extração de uma rede de drenagem ou uma rede viária (elementos lineares mais frequentes) é visualmente destacada no mapa, em virtude das conexões estabelecidas entre os elementos. Para a classificação de algumas feições lineares que representam construções (barragens, por exemplo), é necessária uma atenção especial do operador, porque podem se tratar de pequenos segmentos.

Durante o processo de extração, há a possibilidade de se estabelecer parâmetros de filtragem que separem determinadas classes. Por exemplo, o uso apenas da banda do infravermelho para separar trechos de drenagem das outras classes, enquanto a banda do vermelho tende a apresentar melhores resultados de extração de rodovias. Sendo assim, já ocorre uma separação de classes na parametrização da extração linear. Ainda assim, para identificar alguns tipos de classes, a inspeção visual ainda é necessária, por conta do contexto subjetivo presente, sendo um exemplo a classe de arruamento.

Nesse estudo, foram calculadas as inferências mais específicas para cada classe e o último parâmetro propõe uma visão mais abrangente, que possibilite uma comparação estatística de uma classe com as demais.

Na literatura específica, o índice Kappa é o método estatístico mais utilizado para a avaliação da exatidão temática (Foody, 2002; Congalton & Green, 2009; Figueiredo & Vieira, 2007). Por isso, esse estudo será baseado neste método, expresso na equação 5.13. A justificativa está associada ao fato de ser uma análise que envolve os elementos concordantes observados, Exatidão Global, e os elementos esperados.

$$k = rac{P_o - P_e}{1 - P_e}$$
 Equação 5.13

Onde:

K é uma estimativa do coeficiente Kappa. Po é a proporção de concordâncias observadas (exatidão global) Pe é a proporção de concordâncias esperadas

Para o cálculo da das proporções de concordância observadas e esperada, são usadas as respectivamente as equações 5.14 e 5.15.

$$P_o=rac{\sum_{i=1}^c x_{ii}}{N}$$
 Equação 5.14 $P_e=rac{\sum_{i=1}^c n_{i+*}n_{+i}}{N^2}$ Equação 5.15

Onde:

N é o número total de amostras c o número total de classes. x_{ii} é o valor na linha i e coluna i. n_{i+} é a soma da linha i.

n_{+i} é a soma da coluna i da matriz de confusão.

Quando todos os elementos da matriz de confusão fora da diagonal possuem valor nulo, o coeficiente Kappa possui valor 1, o que significa um

desempenho excelente. O coeficiente Kappa também pode assumir valores negativos indicando que o desempenho foi péssimo.

Neste estudo, as características dos processos de extração de feições poligonais e lineares são muito distintas, de forma que dificilmente as classes representadas através de áreas podem ser confundidas com os elementos geográficos representados através de linhas. Dessa forma, pode-se estabelecer uma matriz de erros específica para classes poligonais.

Partindo-se do total de linhas extraídas para cada sensor, pode-se quantificar a exatidão temática a partir da análise de algumas amostras, comparando-se o que foi efetivamente identificado corretamente com as feicões identificadas incorretamente ou não identificadas. conforme apresentada na tabela 6.3. A tabela, representada por uma matriz de confusão, destaca um exemplo com três feições do sistema de transporte: rodovia pavimentada, rodovia de leito natural e arruamento. Para doze rodovias pavimentadas observadas no campo, duas amostras foram identificadas na imagem como rodovias de leito natural. Enquanto das 20 rodovias de leito natural, duas foram identificadas na imagem como pavimentada. Além disso, de trinta e seis arruamentos, seis amostras foram identificadas em outras classes na imagem. A exatidão global, nesse exemplo, é de 85,71 % (60/70) e o índice kappa para as feições lineares é de 77,48 %.

		Observação de campo					
nagem		Rodovia pavimentada	Rodovia leito natural	Arruamento	Total		
cação ir	Rodovia pavimentada	10	2	5	17		
Classifi	Rodovia leito natural	2	20	1	23		
	Arruamento	0	0	30	30		
	Total	12	22	36	70		

Tabela 6.3: Matriz de confusão para avaliação temática de feições lineares.

No caso de feições poligonais, geralmente a natureza de sua identificação é realizada de forma automática a partir dos parâmetros inseridos pelo usuário no algoritmo classificador A própria matriz de confusão é gerada pelos softwares específicos de classificação de imagem. De qualquer forma, é possível realizar edições manuais em áreas onde se constatam erros de classificação. A tabela, representada por uma matriz de confusão, mostra um exemplo de quatro feições de vegetação: Floresta, Campo, Mangue e Cultivo. Para setenta e cinco áreas de floresta observadas, seis amostras foram identificadas na imagem como campo e quatro como cultivo. Já quatro áreas classificadas na imagem como floresta são, na realidade, áreas de campo. A exatidão global, nesse exemplo, é de 73,96 % e o índice kappa para feições poligonais é de 24,85 %. Apesar de haver um bom valor da concordância observada, houve um baixo valor da concordância esperada (altos erros de omissão), gerando um baixo valor do índice Kappa.

A tabela 6.4 abaixo apresenta uma matriz de confusão entre classes poligonais.

		Observação de campo						
ão		Floresta	Campo	Mangue	Cultivo	Total		
icaç	Floresta	65	4	22	24	115		
ssif	Campo	6	81	5	8	100		
Cla	Mangue	0	11	85	19	115		
	Cultivo	4	7	3	90	104		
	Total	75	103	115	141	434		

Tabela 6.4: Matriz de confusão para avaliação temática de feições poligonais.

6.1.4 Indicador de Identificação

Para obter o grau de identificação das linhas e polígonos extraídos, propõe-se nesse estudo o Indicador de Identificação (IIDE), integrando os três parâmetros apresentados: a Qualidade de Identificação das Extensões (QIE), a Qualidade de Identificação dos Objetos (QIO) e a Qualidade de Concordância (QC). Dessa forma, para uma avaliação do grau de identificação de um traçado é necessário:

- Avaliar a extensão dos elementos classificados corretamente (QIE)
- Avaliar o número de elementos classificados corretamente (QIO);
- Avaliar os erros de concordância entre as classes (QC);

A equação 5.12 expressa o IIDE, sendo a média aritmética dos três parâmetros estabelecidos para avaliar o grau de identificação, de forma que todos possuem o mesmo peso. Cada índice expressa um resultado cujo intervalo de valores varia entre zero e um, de forma que os valores mais altos constituem os melhores resultados da classificação.

IINT = (QIE + QIO + QC) / 3 Equação 5.12

6.2 CLASSIFICAÇÃO DAS FEIÇÕES CARTOGRÁFICAS

6.2.1 Classificação do sistema de transporte

Para a classificação do sistema de transporte, o primeiro procedimento foi discriminar todos os eixos viários, tarefa elaborada no processo de segmentação. O método escolhido para a extração permitiu a aquisição dos dados de forma semiautomática, apesar da necessidade na execução do filtro para limpeza de ruídos do arquivo raster. Além disso, a interpretação visual também é facilitada quando se usa uma composição colorida verdadeira. Geralmente, os eixos rodoviários apresentam uma coloração bastante clara nas bandas do visível, principalmente no vermelho.

No ambiente Arc Gis 10.2, o arquivo raster foi convertido para o formato vetorial (shapefile), permitindo a geração de objetos discretos representativos de cada eixo de transporte. Após a vetorização semiautomática das vias de transporte, foi necessária classificá-las em trechos rodoviários, ferroviários e arruamento, de forma que a origem de todas essas classes está associada ao arquivo raster binário oriundo do filtro de Sobel.

Apesar das imagens permitirem uma boa detecção de trechos ferroviários, a identificação desses elementos é uma tarefa bastante complexa, considerando que a resolução das imagens não permite identificar com detalhes os trilhos, sua principal característica. De uma forma, geral, a resposta espectral dos trechos ferroviários se assemelha com os trechos rodoviários.

Além disso, sua forma também é bastante semelhante, com formas retilíneas definidas nas imagens. Na área de estudo, acrescenta-se também o fato da ferrovia percorrer de forma quase paralela à principal rodovia da região, com a presença de arruamentos que se cruzam e cujo traçado, às vezes, está junto à ferrovia. Acrescenta-se a esses fatores, a presença de gramíneas e uma vegetação arbustiva ao lado da estrutura da ferrovia, impedindo uma visualização mais nítida das pedras que fazem parte de sua estrutura.

Dessa forma, para uma melhor identificação dos trechos ferroviários, três procedimentos foram adotados para diferenciá-los de outras classes: uma análise visual das imagens, o uso de outras fontes de informação, como a base 1:25.000,e o levantamento de campo para validação da classificação.

Para a classificação dos trechos rodoviários e arruamentos, realizou-se um procedimento específico para classificar os de leito natural e pavimentados nas imagens RapiEye. Na banda *red edge* as estradas de terra apresentam maior reflectância do que as estradas pavimentadas. A figura 6.1 ilustra uma comparação entre a banda do vermelho (A) e a borda do vermelho (*Red edge*) (B).



Figura 6.1: Comparação entre as bandas do vermelho (A) e a borda do Vermelho (B)

Percebe-se que apenas algumas rodovias sobressaem na banda *Red Edge*, não se destacando a via que cruza diagonalmente a imagem em (A), cujo piso é pavimentado.

Por isso, realizou-se um procedimento semiautomático para classificar esses dois tipos de pavimentação. A tarefa foi gerar um novo arquivo raster binário a partir de imagens processadas a partir do filtro de Sobel, ou seja, repetir o procedimento de extração, porém nessa atividade somente foram processados os dados do *Red Edge*. O resultado foi a geração de uma rede de sistema viário, onde não aparecem as estradas pavimentadas. A ferrovia que apareceu foi excluída através de análise visual, ficando somente as estradas de leito natural. A partir dessa etapa sobrepôs-se o novo arquivo raster binário com as linhas do arquivo vetor incialmente criado com todos os eixos. Dessa forma, identificaram-se somente os trechos rodoviários e arruamentos de leito natural. As vias extraídas incialmente, mas excluídas no segundo processamento foram identificadas como trechos pavimentados, sejam rodovias ou arruamentos.

A identificação dos trechos pavimentados e de leito natural com esse procedimento não foi possível para as imagens do AVNIR-2 e OLI, já que as respostas espectrais dessas classes nas bandas disponíveis são muito similares. A ausência de uma banda entre as faixas do vermelho e infravermelho próximo impede uma boa distinção. Dessa forma, para as imagens desses sensores, o processo de identificação foi realizado através de uma análise visual das imagens, especificamente quando visualizados em composição colorida em cor verdadeira em alguns trechos na AVNIR-2. No caso das imagens OLI, a classificação depende exclusivamente de outras fontes, tendo em vista que não é possível distinguir as classes apenas usando as imagens.

Os arruamentos também foram extraídos usando os mesmos métodos dos trechos rodoviários, sejam pavimentados ou de leito natural. Para sua identificação foram usados os limites das áreas urbanas, classificadas a partir das imagens originais, como referência para a sua delimitação. Alguns trechos de arruamentos ficaram incompletos na extração automática, porém na interpretação visual foi possível delimitá-los em pequenas partes. As figuras 6.2, 6.3 e 6.4 ilustram os resultados da extração do sistema de transporte para os três sensores.

270







Figura 6.3: Classificação do sistema de transportes nas imagens AVNIR-2



Figura 6.4: Classificação do sistema de transportes nas imagens OLI.

Vale ressaltar que os trechos rodoviários inseridos nas áreas urbanas têm esse segmento duplicado, onde um traçado corresponde à rodovia e o outro representa a classe arruamento. Nos mapas, os trechos rodoviários se sobrepõem às ruas.

6.2.2. Classificação da hidrografia

Para a classificação da hidrografia, o primeiro procedimento foi discriminar todos os corpos d'água, tendo sido elaborado no processo de segmentação. Dois descritores foram fundamentais para essa tarefa: o uso do NDVI, selecionando-se os valores menores que zero e a média da banda do infravermelho. A introdução desses parâmetros no *Ecognition* permite uma extração automática que apresenta uma boa delimitação. Além disso, a interpretação visual também é facilitada quando se usa uma composição colorida com a presença do infravermelho. Geralmente, os corpos d'água apresentam uma coloração bastante escura, podendo atingir padrões azulados em virtude da presença de sedimentos em suspensão (NOVO, 2010).

Após o uso do segmentador c*onstrast split*, detectaram-se as áreas com presença de água, sendo necessário classificá-las em massa d´água, trecho de massa d´água e trecho de drenagem.

No ambiente Arc Gis 10.2, o arquivo raster foi convertido para o formato vetorial (shapefile), permitindo a geração de objetos discretos representativos de cada corpo d'água.

Incialmente realizou-se um procedimento automático para classificar as massas d'água e trechos de massa d'água. Tal tarefa foi realizada a partir de uma seleção espacial dos polígonos que tocam dois trechos de drenagem, à montante e jusante. Os resultados dessa consulta são identificados como trecho de massa d'água, enquanto os polígonos não selecionados ou com apenas um ponto de vizinhança com o trecho de drenagem seriam identificados como massa d'água. Essa regra vale, por exemplo, para o oceano, considerada como massa d'água, onde apenas um ponto do trecho de drenagem toca o local referente à foz.

Um dos problemas encontrados é que existem trechos de drenagem extraídos com descontinuidades, podendo haver trechos de massa d'água

identificados incorretamente. Por isso, foi feita a validação para a classificação correta dos trechos de massa d'água, utilizando-se a base cartográfica 1.25.000 e o levantamento de campo. A figura 6.5 ilustra essa situação, onde as linhas representam a drenagem na base 1:25.000 e os polígonos constituem a extração na imagem RapiEye ao fundo. As linhas de drenagem não são detectadas na imagem orbital, por isso, os polígonos são classificados como massa d'água erroneamente. Porém, somente adicionando a informação de que há uma drenagem conectando as áreas, essas são classificadas como trechos de massa d'água.



Figura 6.5: Sobreposição entre a drenagem da base 1:25.000 trechos de massa d´água extraídas da imagem RapiEye.

Por isso, após o procedimento automático, foi realizada uma análise visual para a conexão entre os trechos para identificar os polígonos representativos dos trechos de massa d´água e massa d´agua. No capítulo referente ao estudo de caso da interpretabilidade, estes erros de classificação serão discutidos.

A figura 6.6 mostra um esquema com as tarefas desenvolvidas.



Figura 6.6: Tarefas para identificação dos trechos de massa d'água e massa d'água.

No caso dos trechos de drenagem, poderia ser utilizada uma função automática para a identificação dos elementos a partir do arquivo raster binário extraído da segmentação. Porém, todos os polígonos teriam linhas centrais (*centerline*) em seu interior e essa inserção nas massas d´água geraria erros. Por isso, houve a necessidade de uma análise visual para identificar elementos que possuem fluxo d´água (trecho de massa d´agua), diferenciando dos que não possuem (massa d´água).

Apesar de ser um processo semiautomático, a avaliação visual acaba tendo um peso significativo na identificação dessas classes. Por isso, durante a construção do traçado durante a vetorização no *Arc Scan*, o atributo referente ao trecho de drenagem já é inserido.

As figuras 6.7, 6.8 e 6.9 ilustram, respectivamente a identificação das massas d'águas, dos trechos de massa d'água nas imagens RapiEye, AVNIRe e LANDSAT-8 para os seis recortes da área de estudo.



Figura 6.7: Classificação da hidrografia nas imagens RapidEye.



Figura 6.8: Classificação da hidrografia nas imagens AVNIR-2





Recorte 3

Recorte 4



Figura 6.9: Classificação da hidrografia nas imagens OLI.

6.2.3 Classificação da vegetação

A classificação da vegetação foi realizada utilizando a modelagem *fuzzy* com o auxílio da análise do comportamento espectral de alvos. Foram coletadas áreas de treinamento obtidas em campo de forma a agrupar objetos similares. A abordagem utilizada foi a *top-down*, em três níveis de segmentação. O primeiro, usando a segmentação c*ontrast Split* para diferenciar água do que não é agua. Nesse nível, separaram-se também as áreas de sombras, usando como descritores o brilho e contraste.

Para a segmentação no segundo nível foi usado o NDVI para, dentro das áreas sem água, diferenciar as áreas verdes das áreas sem presença de biomassa como, por exemplo, as áreas de solo exposto, urbanas e eixos viários.

Para a segmentação no terceiro nível foram incluídas todas as bandas espectrais para o detalhamento das classes relacionadas às áreas verdes, através de uma estrutura hierárquica que garantisse a herança entre os diferentes níveis.

Sendo assim, cada classe foi analisada e caracterizada por diferentes descritores no projeto *Ecognition*.

Além do índice de vegetação e de outros operadores matemáticos, o *Ecognition* disponibiliza uma série de descritores para auxiliar na classificação das imagens. O quadro 6.1 apresenta a utilidade de alguns descritores usados nesse estudo.

Quadro 6.1: Utilidade de alguns descritores. (DEFINTIENS, 2010)

Descritor	Utilidade
Brilho	Soma do valor médio dos níveis de cinza de todas as bandas
	espectrais, dividido pelo número de bandas espectrais que
	formam um objeto.
Contraste	Média do valor mínimo de nível de cinza do objeto subtraído
	da média do seu valor máximo. Para obter o valor máximo e
	mínimo, para cada objeto é efetuada a comparação de todas
	as bandas umas com as outras e o resultado é dividido pelo
	valor do brilho.
Média	Valor médio dos níveis de cinza calculado a partir de todos os
	pixels em uma determinada banda, dividido pelo somatório
	dos pixels que formam um polígono.
Desvio padrão	Desvio padrão dos níveis de cinza calculado a partir de todos
	os pixels em uma determinada banda, dividido pelo somatório
	dos pixels que formam um polígono.
Razão	Razão de uma banda é o valor médio dos níveis de cinza
	desta banda, dividido pela soma dos valores médios de todas
	as bandas espectrais que formam um polígono. Ela descreve
	a predominância de uma determinada banda em relação às
	demais.
Diferença	Média da diferença entre o valor médio dos níveis de cinza do
média	polígono e os seus vizinhos de uma classe selecionada. Para
	cálculo, os valores são ponderados pela área dos respectivos
	polígonos.

Para a segmentação da vegetação foi criada uma estrutura hierárquica de classes para a identificação das feições cartográficas. A hierarquia de classes ficou da seguinte forma:

- Água (nível 1)
- Sombra (nível 1)
- Não água (nível 1)
 - Áreas verdes (nível 2)
 - Floresta (nível 3)
 - Campo (nível 3)
 - Cultivo 1 (nível 3)
 - Mangue (nível 3)
 - Áreas não verdes (nível 2)
 - Áreas urbanas (nível 3)
 - Cultivos 2 (nível 3)
 - Outros (nível 3)

No nível mais abrangente (nível 1) foram separados os segmentos de água na parte terrestre. Para isso, usou-se como referência a segmentação *Contrast Split* na banda do infravermelho para extrair as massas d'água e trechos de massa d'água. Após o uso desse segmentador, executou-se o algoritmo *Assign Class* no *Ecognition*, que permitiu separar o que não foi classificado como água e classificado como áreas de "não água".

No nível 2 procurou-se detalhar a classificação nas áreas de "não água", separando-se as áreas verdes das áreas não verdes. Para realizar essa distinção, o principal descritor usado foi o NDVI, estabelecendo-se como parâmetro o intervalo entre os valores de 0,34 e 1. No caso da classificação das áreas verdes, foi dada ênfase, exclusivamente, à modelagem *Fuzzy* sobre descritores espectrais apoiada na seleção de áreas de treinamento obtidas em campo. A análise *Fuzzy* fornece o grau de participação (pertinência) de um objeto para todas as classes definidas na legenda, cujos valores podem ser inseridos em novos contextos de classificação (Cruz *et. al*, 2009). Ocasionalmente a distribuição da cobertura vegetal ocorre de forma de transição entre as classes, e a modelagem Fuzzy pode trazer respostas mais

eficientes para essas características. A figura 6.10 ilustra o uso do NDVI como descritor para classificação de áreas verdes.



Figura 6.10: NDVI como descritor usando lógica fuzzy.

A classificação no nível 2 serviu para identificar as áreas verdes das áreas não verdes, sendo que os melhores resultados da classificação foram apresentados com os seguintes valores de NDVI:

- Áreas verdes: NDVI a partir de 0,34 até 1.
- Áreas não verdes: NDVI de -1 até 0,3399.

As áreas verdes foram divididas em: floresta, campo, mangue e cultivo 1. As características das classes floresta, campo e mangue foram descritas no início desse capítulo. A criação da classe cultivo 1 serve para representar as áreas agrícolas com resposta espectral que demonstre a presença da biomassa foliar.

No nível 3, para discriminar as classes vinculadas às áreas verdes, foram utilizados os valores de NDVI entre 0,72 e 1 para as florestas e mangues, além de usar média da banda do verde como descritor. Para classificar os mangues, utilizou-se o modelo digital de elevação disponibilizado pelo IBGE, com tamanho de pixel de 20 metros, além da linha de costa extraída das imagens orbitais. Tais informações auxiliaram na contextualização do ambiente de domínio dos manguezais. Já para as áreas de campo, os descritores utilizados foram o intervalo de NDVI entre 0,34 e 0,719 e a média da banda do verde. Para a classe cultivo 1, os descritores usados foram o intervalo de NDVI entre 0,34 e 1, a média da banda verde a razão da banda infravermelha.

Já a classe áreas não verdes está dividida em áreas urbanas, cultivo 2 e outros. Apesar da classe áreas urbana não ser objeto principal do mapeamento desse estudo, optou-se por separá-los por serem importantes para a classificação, tendo em vista que ajudaram na classificação de arruamentos. Para a classificação das áreas urbanas os principais descritores foram a razão da banda do vermelho e a diferença média do infravermelho.

A classe cultivo 2 está associada às áreas agrícolas sem cobertura foliar, como por exemplo, as áreas de pousio. Os descritores usados para a classificação foram: a média da banda vermelho e a razão da banda infravermelho.

Já a classe "outros" integra outros tipos de cobertura do solo sem a presença de áreas verdes, como os eixos viários e solos expostos. Para diferenciar o cultivo 2 do solo exposto analisou-se o contexto e localização de cada região. No caso da área de estudo, as áreas de cultivo detectadas constituem grandes propriedades agropecuárias concentradas na porção sudeste da bacia. As pequenas propriedades não foram identificadas nas imagens. Para separar o cultivo 2 dos eixos viários, cuja extração e classificação ocorreram fora do ambiente *Ecognition*, foram usados os arquivos vetoriais do sistema de transporte como critério para a segmentação.

O quadro 6.2 apresenta os principais descritores usados para a classificação nos níveis 1, 2 e 3.

Classe	Descritores
Sombra	Brilho
Água	NDVI
	Média da banda infravermelho
Não água	Exclusão de água
Áreas verdes	NDVI
Floresta	NDVI
	Média da banda verde
Campo	NDVI
	Média da banda verde
Mangue	NDVI
	Média da banda verde
	Análise de distância da linha de costa
	Modelo Digital de Elevação
Cultivo 1	NDVI
	Média da banda verde
	Razão da banda infravermelho
Áreas não verdes	NDVI
Áreas urbanas	Razão da banda do vermelho
	Diferença média do infravermelho
Outros	Razão da banda do vermelho
	Vetor de hidrografia criado pelo filtro de Sobel
Cultivo 2	Média da banda vermelho
	Razão da banda infravermelho

Quadro 6.2: Principais descritores para a classificação

Para a interpretação visual e coleta das amostras das áreas de treinamento, as chaves de interpretação correspondem em instrumentos importantes para a classificação. A figura 6.11 ilustra as chaves de interpretação das imagens de forma a auxiliar na leitura visual das feições cartográficas.



Figura 6.11: Chaves de interpretação para análise visual.

Os resultados da classificação nas imagens RapiEye, AVNIR-2 e OLI são mostrados respectivamente nas figuras 6.12, 6.13 e 6.14.

A partir da segmentação *Contrast Split*, com a vegetação, elaborada a partir da segmentação Multiresolução, foi realizado um procedimento de ajuste topológico entre as feições cartográficas. Para isso, ajustaram-se os vértices dos polígonos da vegetação para aderirem aos vértices dos trechos de massa d'água e massa d'água.



Figura 6.12: Classificação da vegetação nas imagens RapidEye.



Figura 6.13: Classificação da vegetação nas imagens AVNIR-2



Figura 6.14: Classificação da vegetação nas imagens OLI.

6.2.4 Validação da classificação

Após a classificação, foi feita a validação dos dados gerados através de análise comparativa entre a base de referência e as bases cartográficas classificadas. Em algumas situações, as transformações temporais acabaram ocasionando erros de comissão entre as classes, observados principalmente na categoria de vegetação. Através de uma checagem no campo, constatou-se que as classificações realizadas, a partir das imagens dos três sensores, ficaram aderentes ao observado. Além disso, a maioria dos traçados apresentou consistência temática com a base de referência, com algumas exceções. A seguir são descritas alguns exemplos desses erros que refletem os problemas do intervalo temporal entre os insumos utilizados. O valor total dos erros de comissão está apresentado no final do capítulo, observando os valores de exatidão do usuário para as classes analisadas.

Em relação ao RapidEye, a figura 6.15 ilustra a primeira situação da diferença de classificação existente entre a base de referência e a classificada. Na base cartográfica de referência, na escala 1:25.000, o polígono foi classificado como campo, enquanto na classificação da imagem Rapideye o traçado foi identificado como cultivo. Através de observação no campo, constatou-se que toda a região possui grandes áreas de cultivo e pasto. Como a ortofoto apresenta uma diferença temporal de aproximadamente sete anos em relação à imagem orbital, essas diferenças de classificação podem ocorrer ocasionalmente.



Ortofoto

RapidEye

Figura 6.15: Diferença de classificação entre a ortofoto (campo) e a imagem RapidEye (cultivo). No levantamento aéreo, provavelmente já existia a propriedade para fins agropecuários, porém com há o predomínio de uma cobertura tipicamente de vegetação rasteira, o intérprete classificou a área como campo.

Uma segunda situação de divergência encontrada constitui outra representação poligonal que na base 1:25.000 foi classificada como campo, enquanto na base gerada na RapiEye foi identificada como cultivo. De fato, toda a área no entorno representa uma grande região agropecuária, com presença de fragmentos florestais compondo parte da paisagem, conforme ilustra a figura 6.16.



Figura 6.16: Diferença de classificação entre a ortofoto (campo) e a imagem RapidEye (cultivo).

Como era esperado, a classe cultivo tende a apresentar maior dinâmica de mudança em relação às outras classes, até mesmo em períodos relativamente curtos. Também aparecerem divergências na classificação das imagens AVNIR-2 com a base de referência, cuja diferença no intervalo de tempo em relação à ortofoto é de dois anos, comforme ilustra a figura 6.17.



Figura 6.17: Diferença de classificação entre a ortofoto (campo) e a imagem AVNIR-2 (cultivo).

No caso da classificação no sensor OLI, ocorreram situações semelhantes, também com a divergência nas classes campo (ortofoto) e cultivo (OLI), conforme ilustra a figura 6.18.

De certa forma, a possibilidade de erro envolvendo essas classes é bastante significativa, já que se trata de coberturas vegetais que podem apresentar características bastante semelhantes. O reconhecimento no terreno é o procedimento ideal para esclarecer esses tipos de dúvidas de classificação.



Figura 6.18: Diferença de classificação entre a ortofoto (campo) e a imagem OLI (cultivo).

6.3 GERAÇÃO DO INDICADOR DE IDENTIFICAÇÃO NA BHRSJ

6.3.1 Qualidade de Identificação das Extensões

A proposta do parâmetro de Qualidade de Identificação das Extensões (QIE) é mensurar, em termos gerais, a quantidade de elementos com erros de comissão das imagens, sendo expresso através dos comprimentos, no caso de feições lineares, e perímetros, no caso de feições poligonais.

Foram somadas as extensões de todos os elementos extraídos nos seis recortes da área de estudo e comparadas com as feições correspondentes na base cartográfica usada como referência.

A tabela 6.5 apresenta o percentual de erros de comissão por classe e por sensor, ou seja, elementos extraídos e classificados erroneamente nas imagens orbitais em relação ao verificado na base de referência.

Classe	RE	AVNIR-2	OLI
Arruamento	0,00	0,00	-
Campo	12,89	16,68	16,34
Cultivo	21,67	19,20	27,47
Ferrovia	0,00	0,39	1,09
Floresta	14,40	16,00	22,21
Mangue	1,29	1,39	1,03
Massa d´água	3,28	4,45	2,53
Rodovia leito natural	4,15	6,94	7,58
Rodovia pavimentada	0,00	0,00	0,00
Trecho de drenagem	0,00	0,00	0,00
Trecho de massa d´água	0,00	0,00	0,00

Tabela: 6.5: Percentual de erros de	comissão das	classes por	sensor.
-------------------------------------	--------------	-------------	---------

A partir destes valores estabeleceu-se a taxa de acerto, ou seja, o percentual de elementos extraídos classificados corretamente. Esse procedimento serve para o cálculo do QIE, um dos parâmetros para a geração do indicador de identificação, no qual os valores mais altos (menor taxa de comissão) representam os melhores resultados. A tabela 6.6 mostra a

Qualidade de Detecção das Extensões (QDE), a taxa de elementos sem erros de comissão e o resultado final do QIE, que representa o produto da multiplicação entre a taxa de acerto da comissão com qualidade de Detecção das Extensões.

Classe	QDE	Taxa de elementos sem erro de comissão	QIE
Arruamento	0,35	1,00	0,35
Campo	0,85	0,87	0,74
Cultivo	0,91	0,78	0,71
Ferrovia	0,88	1,00	0,88
Floresta	0,92	0,86	0,79
Mangue	1,00	0,99	0,99
Massa d´água	0,98	0,97	0,95
Rodovia leito natural	0,95	0,96	0,91
Rodovia pavimentada	0,97	1,00	0,97
Trecho de drenagem	0,33	1,00	0,33
Trecho de massa d´água	0,94	1,00	0,94

Tabela: 6.6: Valores de QIE das classes para o RapidEye

Nota-se que houve uma grande redução nos valores de QIE nas classes arruamento e trecho de drenagem quando comparado com a taxa de elementos sem erros de comissão. A justificativa é que a Qualidade de Detecção das Extensões foi baixa, acarretando na diminuição do QIE. Caso essa razão não fosse estabelecida o valor de QIE seria alto, não refletindo o grau de interpretabilidade mais adequado. Isso mostra que a tarefa de identificação depende de uma boa detecção dos objetos para atingir uma interpretabilidade satisfatória. Esse cenário se repete com o AVNIR, sendo apresentado na tabela 6.7.

Em relação ao RapidEye, nota-se que as maiores diferenças estão das feições lineares, de forma que o arruamento e o trecho de drenagem apresentam valores muito baixos da qualidade desse tipo de comissão. Além disso, a ferrovia apresenta maiores trechos com descontinuidades, interferindo diretamente no valor do resultado.

Classe	QDE	Taxa de elementos sem erros de comissão	QIE
Arruamento	0,08	1,00	0,08
Campo	0,89	0,83	0,74
Cultivo	0,85	0,81	0,69
Ferrovia	0,59	1,00	0,59
Floresta	0,92	0,84	0,77
Mangue	0,99	0,99	0,98
Massa d´água	0,94	0,96	0,90
Rodovia leito natural	0,87	0,93	0,81
Rodovia pavimentada	0,86	1,00	0,86
Trecho de drenagem	0,16	1,00	0,16
Trecho de massa d´água	0,96	1,00	0,96

Tabela: 6.7: Valores de QIE das classes para o AVNIR-2.

As áreas de vegetação e as feições poligonais de hidrografia apresentaram valores bastante semelhantes. Resultado parecido com os valores da QIE dos dados extraídos do sensor OLI, apresentado na tabela 6.8.

Tabela: 6.8: Valores de QIE das classes para o OLI

Classe	QDE	Taxa de elementos sem erros de comissão	QIE
Arruamento	0,00	0,00	0,00
Campo	0,89	0,84	0,74
Cultivo	0,88	0,73	0,64
Ferrovia	0,43	0,99	0,43
Floresta	0,94	0,78	0,73
Mangue	0,97	0,99	0,96
Massa d´água	0,91	0,97	0,89
Rodovia leito natural	0,71	0,92	0,66
Rodovia pavimentada	0,81	1,00	0,81
Trecho de drenagem	0,09	1,00	0,09
Trecho de massa d´água	0,90	1,00	0,90

A principal diferença em relação aos sensores anteriores é que a classe rodovia de leito natural apresentou um declínio significativo, fato não observado com a rodovia pavimentada, cujo valor se manteve acima de 0,8.

Os resultados mostram que de forma geral, houve poucos erros de comissão para as classes poligonais, no qual os resultados menos satisfatórios foram encontrados na classe cultivo, fato esperado em função da diversidade de características que envolvem esse tipo de classe e da diferença de tempo entre as imagens e as ortofotos usadas na geração da base 1:25.000.

Porém, vale destacar que as classes oriundas da vetorização semiautomática apresentaram baixos erros de comissão, mesmo as classes arruamento e trecho de drenagem. Ou seja, uma vez extraídos, o processo de identificação dessas classes não é uma tarefa difícil. O principal problema está relacionado aos baixos valores de QDE, ou seja, alta porcentagem de omissão.

As médias da QIE para o RapidEye, AVNIR-2 e OLI foram, respectivamente de 0,78, 0,69 e 0,62, mostrando uma relação direta entre as resoluções espaciais dos sensores e o potencial de classificação. Considerando os resultados obtidos, pode-se concluir que quanto maior a resolução espacial, menor é a possibilidade de erros de comissão em ternos de extensão dos elementos. Isto é verdade desde que se disponha das bandas espectrais adequadas à detecção e identificação dos alvos desejados.

6.3.2 Qualidade de Identificação dos Objetos

O segundo indicador para a obtenção do Indicador de Identificação é a Qualidade de Identificação dos Objetos (QIO), obtida através da multiplicação entre a exatidão do usuário e a Qualidade de Detecção dos Objetos (QDO),

Pela mesma razão de se ponderar os valores da QIE pela QDE para refletir de forma mais satisfatória a interpretabilidade envolvida, tona-se necessário também ponderar o valor da exatidão do usuário pela exatidão do produtor, ou seja, condicionar o valor da QIO pelo resultado do parâmetro de qualidade da omissão. Isso porque podem acontecer casos, nos quais a omissão tenha sido alta, ou seja, baixa detecção, e a comissão baixa, ou seja, alta identificação. Esse panorama pode mascarar um resultado de interpretabilidade que não reflete a situação real. A tabela 6.9 apresenta os valores da Exatidão do Produtor, da Exatidão do Usuário e o QIO, valor final da Qualidade de Completude de Objetos para os dados gerados para o RapidEye.

Classe	Exatidão do produtor	Exatidão do usuário	QIO
Arruamento	0,37	1,00	0,37
Campo	0,80	1,00	0,80
Cultivo	0,78	0,88	0,68
Ferrovia	1,00	1,00	1,00
Floresta	0,96	0,99	0,95
Mangue	0,94	0,94	0,88
Massa d´água	0,95	1,00	0,95
Rodovia leito natural	0,93	1,00	0,93
Rodovia pavimentada	1,00	1,00	1,00
Trecho de drenagem	0,34	1,00	0,34
Trecho de massa d'água	0,95	1,00	0,95

Tabela 6.9: Qualidade de Identificação dos Objetos para o sensor RapiEye.

Assim como ocorreu na avaliação anterior, nota-se que houve uma redução significativa dos valores nas classes arruamento e trecho de drenagem, cuja exatidão do produtor apresentou valor baixo, gerando uma diminuição nos valores do QIO em relação ao Índice do Usuário. Este cenário se repete com o AVNIR, apresentado na tabela 6.10.

O cenário ideal é quando os valores da QIE e QIO são altos, significando que a base extraída e a de referência possuem aproximadamente as mesmas características.

Quando o valor da QIO é alto e a QIE é baixa significa que número de objetos entre a extração e a referência é semelhante ou igual, porém existem problemas na extração, como por exemplo, a classe ferrovia, feição extraída parcialmente. Apesar do valor da QIO ser alta, já que foi possível extrair o único elemento da classe, o valor da QIE é um pouco mais baixo, refletindo a parcialidade da extração.
Classe	Exatidão do produtor	Exatidão do usuário	QIO
Arruamento	0,10	1,00	0,10
Campo	0,90	0,95	0,85
Cultivo	0,78	0,70	0,55
Ferrovia	1,00	1,00	1,00
Floresta	0,96	0,99	0,95
Mangue	0,94	1,00	0,94
Massa d´água	0,84	1,00	0,84
Rodovia leito natural	0,75	0,98	0,74
Rodovia pavimentada	1	1,00	1,00
Trecho de drenagem	0,22	1,00	0,22
Trecho de massa d'água	0,90	1,00	0,90

Tabela 6.10: Qualidade de Identificação de Objetos para o sensor AVNIR-2.

Quando ocorre o inverso, isto é, a QIE é alta e a QIO é baixa significa que as extensões são aproximadamente iguais, porém, o número de objetos detectados e classificados é bastante diferente entre as bases extraídas e de referência. É o caso, por exemplo, dos dados da classe massa d'água interpretados a partir do sensor OLI, conforme apresentado na tabela 6.11. Existem 19 massas d'água, porém um traçado apresenta dimensões significativas, constituído pelo recorte do oceano, único polígono extraído dessa classe nesse sensor. Os outros polígonos foram ignorados, gerando um baixo valor de ICO.

Por isso, as duas formas de avaliação de completude se tornam complementares, de forma a auxiliar o diagnóstico da interpretabilidade em imagens.

Em todas as análises de comissão, a classe cultivo foi a que apresentou valores mais baixos em relação às outras classes de vegetação, fato esperado em virtude da dinâmica temporal e radiométrica desse tipo de classe, que pode apresentar uma diversidade de resposta espectral bastante ampla.

Classe	Exatidão do produtor	Exatidão do usuário	QIO
Arruamento	0,00	0,00	0,00
Campo	0,90	0,95	0,85
Cultivo	0,67	0,86	0,57
Ferrovia	1,00	1,00	1,00
Floresta	0,92	0,98	0,91
Mangue	0,94	0,94	0,88
Massa d´água	0,05	1,00	0,05
Rodovia leito natural	0,64	1,00	0,64
Rodovia pavimentada	1,00	1,00	1,00
Trecho de drenagem	0,10	1,00	0,10
Trecho de massa d'água	0,51	1,00	0,51

Tabela 6.11: Qualidade de Identificação de Objetos para o sensor OLI.

6.3.3 Qualidade de Concordância

O terceiro e último parâmetro calculado para se atingir o Indicador de Identificação corresponde ao índice Kappa, denominado neste estudo de Qualidade de Concordância. A tabela 6.12 apresenta a matriz de confusão para os elementos poligonais do RapiEye.

Tabela 6.12: Matriz de confusão entre as classes poligonais do sensor RapiEye.

				Refe	rência				
e/e	Classes	MA	TMA	Ca	F	М	С	NC	Total
ц	MA	18	0	0	0	0	0	0	18
apic	TMA	0	32	0	0	0	0	0	39
Ř	Ca	0	0	16	0	0	0	0	16
ĩão	F	0	0	0	68	0	1	0	69
caç	М	0	0	0	0	16	1	0	17
sifi	С	0	0	1	0	0	7	0	8
las	NC	1	9	3	3	1	0	0	10
S	Total	19	41	20	71	17	9	0	177

MA= Massa d'água; TMA = Trecho de massa d'água; Ca = Campo; F = Floresta; M = Mangue; C = Cultivo; NC = Não classificado.

O valor da proporção de concordância observada, ou exatidão global, foi de 0,89, enquanto a proporção de concordância esperada foi de 0,23. O índice Kappa calculado para as classes poligonais extraídas do sensor RapiEye foi de 0,90.

A tabela 6.13 apresenta a matriz de confusão para elementos lineares do RapidEye.

		Referência						
	Classes	RLN	RP	А	F	TD	NC	Total
0	RLN	64	0	0	0	0	0	64
ção	RP	0	4	0	0	0	0	4
ica iEy	А	0	0	34	0	0	0	34
ssif	F	0	0	0	1	0	0	1
ы С	TD	0	0	0	0	41	0	41
0	NC	5	0	57	0	80	0	142
	Total	69	4	91	1	121	0	286

Tabela 6.13: Matriz de confusão entre as classes lineares do sensor RapiEye.

RLN= rodovia Leito natural; RP= Rodovia Pavimentada; A = Arruamento; F = Ferrovia; TD = Trecho de drenagem; NC = Não classificado.

O valor da proporção de concordância observada foi de 0,50, enquanto a proporção de concordância esperada foi de 0,15. Dessa forma, o índice Kappa calculado para as classes poligonais extraídas do sensor RapiEye foi de 0,41.

A tabela 6.14 apresenta a matriz de confusão para elementos poligonais para AVNIR.

Tabela 6.14: Matriz de confusão entre as classes poligonais do sensor AVNIR-2.

				Refe	rência				
2	Classes	MA	TMA	Ca	F	М	С	NC	Total
ц Ч	MA	16	0	0	0	0	0	0	16
Ż	TMA	0	27	0	0	0	0	0	37
A'	Ca	0	0	18	0	0	1	0	19
çãc	F	0	0	0	68	0	1	0	69
cac	М	0	0	0	0	16	0	0	16
sifi	С	0	0	2	0	1	7	0	10
las	NC	3	14	0	3	0	0	0	10
0	Total	19	41	20	71	17	9	0	177

MA= Massa d'água; TMA = Trecho de massa d'água; Ca = Campo; F = Floresta; M = Mangue; C = Cultivo; NC = Não classificado.

O valor da proporção de concordância observada, ou exatidão global, foi de 0,89, enquanto a proporção de concordância esperada foi de 0,23. Dessa forma, o índice Kappa calculado para as classes poligonais extraídas do sensor RapiEye foi de 0,82.A tabela 6.15 apresenta a matriz de confusão para elementos lineares para AVNIR-2.

			Referência					
Ņ	Classes							
Ř		RLN	RP	A	F	TD	NC	Total
Ź	RLN	52	1	0	0	0	0	53
A	RP	0	3	0	0	0	0	3
ção	А	0	0	9	0	0	0	9
caç	F	0	0	0	1	0	0	1
sifi	TD	0	0	0	0	27	0	27
las	NC	17	0	82	0	94	0	193
S	Total	69	4	91	1	121	0	286

Tabela 6.15: Matriz de confusão entre as classes lineares do sensor AVNIR-2.

RLN= rodovia Leito natural; RP= Rodovia Pavimentada; A = Arruamento; F = Ferrovia; TD = Trecho de drenagem; NC = Não classificado.

O valor da proporção de concordância observada, ou exatidão global, foi de 0,32, enquanto a proporção de concordância esperada foi de 0,09. Dessa forma, o índice Kappa calculado para as classes poligonais extraídas do sensor RapiEye foi de 0,25. A tabela 6.16 apresenta a matriz de confusão para elementos poligonais para OLI.

				Refer	ência				
	Classes	MA	TMA	Ca	F	М	С	NC	Total
Ļ	MA	1	0	0	0	0	0	0	1
0	TMA	0	21	0	0	0	0	0	21
çãc	Ca	0	0	18	0	0	1	0	19
ica	F	0	0	0	65	0	1	0	66
ssif	М	0	0	0	0	16	1	0	17
Clas	С	0	0	1	0	0	6	0	7
0	NC	18	20	1	6	1	0	0	46
	Total	19	41	20	71	17	9	0	177

Tabela 6.16: Matriz de confusão entre as classes poligonais do sensor OLI.;

MA= Massa d'água; TMA = Trecho de massa d'água; Ca = Campo; F = Floresta; M = Mangue; C = Cultivo; NC = Não classificado.

O valor da proporção de concordância observada, ou exatidão global, foi de 0,72, enquanto a proporção de concordância esperada foi de 0,20. Dessa forma, o índice Kappa calculado para as classes poligonais extraídas do sensor OLI foi de 0,65. A tabela 6.17 apresenta a matriz de confusão para elementos lineares para OLI.

	Referência							
	Classes	RLN	RP	А	F	TD	NC	Total
	RLN	44	0	0	0	0	0	44
0	RP	0	4	0	0	0	0	4
açã	А	0	0	0	0	0	0	0
fice	F	0	0	0	1	0	0	1
ISSI	TD	0	0	0	0	12	0	12
Cla	NC	25	0	91	0	109	0	225
	Total	69	4	91	1	121	0	286

Tabela 6.17: Matriz de confusão entre as classes lineares do sensor OLI.

RLN= rodovia Leito natural; RP= Rodovia Pavimentada; A = Arruamento; F = Ferrovia; TD = Trecho de drenagem; NC = Não classificado.

O valor da proporção de concordância observada, ou exatidão global, foi de 0,21, enquanto a proporção de concordância esperada foi de 0,06. Dessa forma, o índice Kappa calculado para as classes poligonais extraídas do sensor RapiEye foi de 0,17.

De uma forma geral, nota-se que os valores do índice Kappa são mais baixos para as feições lineares, onde a concordância observada é baixa quando comparada com a concordância das feições poligonais. Porém, a concordância esperada é extremamente baixa, principalmente no AVNIR-2 e OLI. A justificativa se baseia pela baixa exatidão do produtor, que avalia os erros de omissão e parâmetro para a obtenção da concordância esperada. O resultado da exatidão do produtor, que nesse estudo denominou-se de Qualidade de Detecção dos Objetos é obtido através da divisão do número total de unidades de amostras corretas na classe, pelo número total de amostras da classe indicada pelo dado de referência. Os baixos valores de arruamento e trechos de drenagem contribuíram para esse resultado.

6.3.4 Cálculo do Indicador de Identificação

Para o cálculo do índice de detecção, foram integrados os parâmetros de qualidade citados, através da média aritmética simples. A tabela 6.18 apresenta o valor do Indicador de Identificação para o sensor RapiEye.

Classe	QIE	QIO	QC	IIND
Arruamento	0,35	0,37	0,41	0,38
Campo	0,74	0,8	0,90	0,81
Cultivo	0,71	0,68	0,90	0,77
Ferrovia	0,88	1	0,41	0,76
Floresta	0,79	0,95	0,90	0,88
Mangue	0,99	0,88	0,90	0,93
Massa d água	0,95	0,95	0,90	0,93
Rodovia Leito Natural	0,91	0,93	0,41	0,75
Rodovia pavimentada	0,97	1	0,41	0,79
Trecho de drenagem	0,33	0,34	0,41	0,36
Trecho de massa d água	0,94	0,95	0,85	0,91
Média	0,78	0,80	0,68	0,75

Tabela 6.18: Indicador de Identificação para as classes extraídas no RapiEye.

Os resultados mostram valores elevados para as classes trecho de massa d'água, massa d'água, mangue, floresta e campo, cujos valores do indicador de identificação ficaram acima de 0,8. Depois aparecem algumas classes com valores do Indicador de Identificação ligeiramente inferiores, sendo os casos do cultivo, ferrovia e as classes das rodovias. E, por último, aparecem as classes arruamento e trecho de drenagem, com valores inferiores a 0,4.

Nota-se que o desempenho insatisfatório da detecção influenciou nos resultados do arruamento e trecho de drenagem, mas afetou também o resultado de outras feições lineares, principalmente se considerar o resultado da Qualidade de Concordância, no qual o baixo valor do índice Kappa para as feições lineares influenciou negativamente os seus respectivos Indicadores de

Identificação. Por isso, as classes poligonais apresentaram melhores valores de identificação.

Esses fatos também foram observados na construção do Indicador de identificação das classes extraídas a partir dos sensores AVNIR-2, conforme apresentado na tabela 6.19.

Classe	QIE	QIO	QC	IIND
Arruamento	0,08	0,1	0,25	0,14
Campo	0,74	0,85	0,89	0,83
Cultivo	0,69	0,55	0,89	0,71
Ferrovia	0,59	1	0,25	0,61
Floresta	0,77	0,95	0,89	0,87
Mangue	0,98	0,94	0,89	0,93
Massa d água	0,9	0,84	0,89	0,88
Rodovia Leito Natural	0,81	0,74	0,25	0,60
Rodovia pavimentada	0,86	1	0,25	0,70
Trecho de drenagem	0,16	0,22	0,25	0,21
Trecho de massa d água	0,96	0,9	0,82	0,89
Média	0,69	0,73	0,59	0,67

Tabela 6.19: Indicador de Identificação para as classes extraídas no AVNIR-2.

Nota-se que os parâmetros de qualidade associados diretamente com a completude (QIE e QIO) também apresentam valores reduzidos nas classes arruamento e trecho de drenagem, afetados diretamente pelo desempenho ruim na detecção.

Os resultados do AVNIR-2 mostram uma coerência com os valores encontrados para o RapidEye, ou seja, os indicadores de identificação são mais elevados para as classes trecho de massa d'água, massa d'água, mangue, floresta e campo, ficando acima de 0,8. Depois aparecem algumas classes com valores do Indicador de Identificação ligeiramente inferiores, sendo os casos do cultivo, ferrovia e as classes das rodovias. E, por último, aparecem as classes arruamento e trecho de drenagem, com valores inferiores a 0,3.

Para completar a avaliação do potencial de identificação, a tabela 6.20 apresenta os valores dos parâmetros de qualidade obtidos para o sensor OLI.

Classe	QIE	QIO	QC	IIND
Arruamento	0	0	0,17	0,00
Campo	0,74	0,85	0,65	0,75
Cultivo	0,64	0,57	0,65	0,62
Ferrovia	0,43	1	0,17	0,53
Floresta	0,73	0,91	0,65	0,76
Mangue	0,96	0,88	0,65	0,83
Massa d água	0,89	0,05	0,65	0,53
Rodovia Leito Natural	0,66	0,64	0,17	0,49
Rodovia pavimentada	0,81	1	0,17	0,66
Trecho de drenagem	0,09	0,1	0,17	0,12
Trecho de massa d água	0,9	0,51	0,65	0,69
Média	0,62	0,59	0,41	0,54

Tabela 6.20: Indicador de Identificação para as classes extraídas no OLI.

Nesse caso, houve uma diferença nas classes de hidrografia, com uma diminuição significativa do trecho de massa d´água e massa água, classes que apresentavam bons resultados para o AVNIR-2 e RapiEye. As classes de vegetação continuaram com valores bons, principalmente o mangue.

A média do índice de Identificação para as classes do RapidEye foi de 0,75, para o AVNIR foi de 0,67 e para o OLI foi de 0,54. Conforme esperado, os resultados mostram que o potencial de identificação do alvo possui uma relação direta com a resolução espacial do sensor. Imagens com maiores resoluções espaciais tendem, além de detectarem mais objetos, possibilitam a identificação mais exata dos mesmos. Porém, isso não significa que sensores com resolução acima de 10 metros não sejam importantes. Os resultados de identificação do OLI não ficaram muito abaixo dos outros dois sensores, mostrando que pode ser bastante útil, principalmente para vegetação.

6.3.5 Conclusões

De uma forma geral, as classes de vegetação e as feições poligonais de hidrografia apresentaram resultados satisfatórios, confirmando uma expectativa estabelecida através de análise empírica. Porém, vale destacar que os trechos rodoviários apresentaram valores um pouco abaixo do esperado, principalmente em função do baixo índice kappa, parâmetro que considera, além do número de concordâncias observadas (exatidão global), o número de concordâncias esperadas, valor baixo em função do baixo número de feições lineares extraídas.

O uso dos parâmetros para a construção do índice de identificação se mostrou adequada para quantificar o potencial de identificação dos elementos extraídos. A ideia principal foi estabelecer parâmetros que pudessem auxiliar em uma avaliação em termos de extensão linear e das áreas dos polígonos com o número de elementos. No primeiro caso, a proposta da Qualidade de Identificação das Extensões é mensurar os erros de comissão expressos em medida métrica, enquanto a Qualidade da Identificação dos Objetos e a Qualidade de Concordância tentam expressar os erros envolvidos na classificação através da contagem de feições e de sua concordância.

Todos os parâmetros, de certa maneira, representam uma análise continuada da avaliação da detecção, ou seja, não sendo trabalhado de forma isolada. Além disso, foi possível a aplicação de métodos de avaliação tradicionalmente usados para avaliação de dados de sensoriamento remoto para a composição do indicador, o que facilita a sua replicação em outros tipos de estudo.

7. ÍNDICE DE INTERPRETABILIDADE

7.1 CONSTRUÇÃO DO ÍNDICE DE INTERPRETABILIDADE

Considerando a integração entre os indicadores de detecção e identificação em todas as imagens avaliadas, a proposta desse estudo é estabelecer o Índice de Interpretabilidade, ou seja, cada classe, categoria ou imagem como um todo de um determinado sensor teria um atributo quantitativo e qualitativo indicando a qualidade e atendimento das tarefas a serem estabelecidas. O objetivo final é apresentar um parâmetro que sirva como referência para se estimar o que se pode esperar de cada imagem. Além disso, é importante conhecer também para quais escalas os dados são mais adequados.

Para a obtenção do Índice de Interpretabilidade propõe-se nesse estudo uma análise conjunta dos Indicadores de Detecção e identificação

O Indicador de Detecção constitui a média aritmética de quatro parâmetros: a Qualidade da Segmentação (QS), a Qualidade de Detecção das Extensões (QDE), a Qualidade de Detecção dos Objetos (QDO), a Qualidade de Forma (QF) e a Qualidade Posicional (QP).

Já o Indicador de Identificação, corresponde à média aritmética de três parâmetros: a Qualidade de Identificação das Extensões (QIE), a Qualidade de Identificação dos Objetos (QIO) e a Qualidade de Concordância.

Em todos os parâmetros, seja de detecção ou de identificação, os valores se concentram em intervalo que varia de 0 a 1. Dessa forma, propõese nesse estudo desenvolver a ideia de Interpretabilidade de forma quantitativa, a partir da média aritmética entre os indicadores de detecção e identificação, cujos valores sejam estabelecidos através deste intervalo. Assim, a detecção e identificação têm o mesmo peso na avaliação do potencial de interpretação de uma determinada imagem para a obtenção de uma classe cartográfica. A figura 7.1 mostra um esquema com a composição dos indicadores que compõem o índice de interpretabilidade.



Figura 7.1: Esquema com a composição dos indicadores para a composição do índice de interpretabilidade.

Além disso, para facilitar o entendimento sobre o grau de interpretabilidade envolvido, sugere-se atribuir um adjetivo que sintetize as tarefas de detecção e identificação, estabelecidas de forma quantitativa. Dessa forma, é apresentada uma classificação qualitativa de desempenho de interpretabilidade que integre detecção e identificação;

Embora o coeficiente Kappa seja muito utilizado na avaliação da exatidão de mapeamento, não existe uma fundamentação teórica para recomendar quais os níveis mínimos aceitáveis deste coeficiente numa classificação. Entretanto, existem algumas tentativas de uma transformação de uma avaliação quantitativa para qualitativa, A tabela 7.1 apresenta níveis de desempenho da classificação para o valor de Kappa obtido, normalmente aceitos pela comunidade científica, citado por Fonseca (2000).

Índice Kappa	Desempenho da classificação
0,8 < k > 1,0	Excelente
0,6 < k > 0,8	Muito bom
0,4 < k > 0,6	Bom
0,2 < k > 0,4	Razoável
0< k > 0,2	Fraco

Tabela 7.1: Índice do coeficiente Kappa e o correspondente conceito do desempenho da classificação. (FONSECA, 2000)

Como o valor do Índice de Interpretabilidade varia no mesmo intervalo do índice Kappa, essa divisão qualitativa do desempenho pode ser utilizada como referência para a classificação da interpretabilidade, conforme é apresentado na tabela 7.2. Porém, propõem-se uma adaptação desta proposta, sendo alterada a posição do desempenho denominado razoável, que não estaria associado ao intervalo entre 0,2 e 0,4, mas entre 0,4 e 0,6. A classe cujo intervalo do índice de interpretabilidade está situado entre 0,2 até 0,4 passaria a ser denominada de ruim. Então, o desempenho da interpretabilidade varia entre excelente até fraca, de forma que cada classe estaria associada ao seu respectivo intervalo do Índice de Interpretabilidade. A justificativa se baseia na falta de necessidade de incluir os desempenhos excelente e muito bom, já que estão associados à uma qualidade acima do bom. Além disso, classificar valores de interpretabilidade entre 0,2 e 0,4 como razoável não retrataria de forma mais fiel a qualidade da interpretação.

Usando um exemplo de uma feição que apresentou o valor do Índice de Interpretabilidade entre 0,8 e 1, a sua classe de interpretabilidade seria A e a sua qualidade de interpretabilidade poderia ser considerada excelente.

Dessa forma, integra-se através dos potenciais de detecção e identificação, um método para medir e comparar diferentes graus de interpretabilidade através de formas quantitativas e qualitativas.

Classe de Interpretabilidade	Qualidade da Interpretabilidade	Índice de Interpretabilidade
A	Excelente	0,80 a 1
В	Boa	0,60 a 0,79
С	Razoável	0,40 a 0,59
D	Ruim	0,20 a 0,39
E	Fraca	0 a 0,19

Tabela 7.2: Proposta do Índice de Interpretabilidade

Uma das vantagens da construção desse índice é a possibilidade da geração de resultados em vários níveis de análise, permitindo a avaliação desde a estrutura básica, constituída pela classe, até atingir a categoria de informação, correspondendo à análise sobre o potencial de interpretação pelo agrupamento das classes com as mesmas características.

Além disso, neste estudo procurou-se uma avaliação de imagens a partir de três sensores com características distintas, possibilitando análises da interpretabilidade a partir do agrupamento das categorias extraídas de cada sensor, obtendo-se assim, o grau de interpretabilidade por sensor.

7.1.1 Interpretabilidade por feição cartográfica, categoria e sensor

Para cada conjunto de elementos de uma classe é mensurado o seu potencial de ser detectado e identificado para uma determinada imagem. Nesse estudo, estabeleceu-se que cada feição poligonal ou linear está associada a um intervalo de valores entre 0 e 1, refletindo o seu indicador de detecção e identificação. Se um dos indicadores for baixo, a interpretabilidade da classe será reduzida.

É importante ressaltar que independentemente do traçado possuir características lineares ou poligonais, as classes avaliadas possuem os mesmos parâmetros para uma avaliação comparativa em termos de interpretabilidade. Pode-se usar como exemplo a extração de elementos da classe arruamento a partir de um determinado sensor. Para a obtenção do Índice de Interpretabilidade da classe arruamento, cujo traçado é linear, calcula-se a média dos valores gerados através dos Indicadores de Detecção (IDET) e Identificação (IIDEN). Se os valores forem, respectivamente, de 0,4 e 0,6, o índice de interpretabilidade do arruamento será de 0,5 para a imagem deste sensor, enquadrada na classe C, ou seja, a qualidade da interpretabilidade seria razoável.

Este procedimento foi realizado para as imagens dos outros sensores estudados, ou seja, através do calculo da média entre os indicadores de detecção e identificação para a obtenção da interpretabilidade para cada classe extraída.

Porém, ainda falta a contextualização dos valores dos índices de interpretabilidade para cada classe com o cenário de sua produção cartográfica mais adequada, principalmente no que se refere ao uso da escala cartográfica para qual esse índice é válido e que contenha algum sentido.

Por exemplo, pode-se chegar à conclusão que interpretabilidade de uma classe para a imagem de um determinado sensor é boa, mas torna-se indispensável relacionar com características específicas de cada tipo de mapeamento, considerando: a qualidade posicional, a qualidade da forma e a representação mínima extraída. Para cada um, é possível encontrar adequações de escalas distintas.

Ao final, pode-se dizer que a interpretabilidade é ótima, boa, razoável, ruim ou fraca usando como referência o valor da escala, permitindo o auxílio na escolha de insumos mais adequados para o mapeamento.

Sendo assim, considerando que a interpretabilidade pode variar entre as classes de mapeamento, propõe-se um índice de interpretabilidade para cada feição, conforme é apresentado no exemplo do quadro 7.1 com a composição do índice de interpretabilidade.

312

Feição	Geometria	Indicador de	Indicador de	Índice de
		detecção	identificação	interpretabilidade
Trecho de	Linha	IDET _{Trecho de}	IIDE _{Trecho de}	INT Trecho de drenagem
drenagem		drenagem	drenagem	
Rodovia	Linha	IDET _{Rodovia}	IIDE _{Rodovia}	INT Rodovia pavimentada
pavimentada		pavimentada	pavimentada	
Rodovia	Linha	IDET _{Rodovia}	IINT Rodovia leito	INT Rodovia leito natural
leito natural		leito natural	natural	
Floresta	Polígono	IDET Floresta	IINT Floresta	INT _{Floresta}
Campo	Polígono	IDET Campo	IINT _{Campo}	IINT _{Campo}

Quadro 7.1: Exemplo de geração do índice de Interpretabilidade por feição.

Sendo assim, a criação de um índice de interpretabilidade para cada feição permite uma concepção mais concreta de quais feições cartográficas possuem a melhor interpretabilidade para cada tipo de imagem. Por isso, ao final das análises, tabelas são elaboradas com os valores do índice de interpretabilidade com suas respectivas classes e qualidade de interpretabilidade para um determinado sensor.

Esse tipo de avaliação auxilia no planejamento sobre os tipos de insumos mais adequados para o mapeamento de determinadas feições cartográficas. Uma imagem pode ser bastante útil para a extração de determinados tipos de feições e não corresponder às expectativas de extração para outras feições. Porém, essa abordagem de criação do índice não significa o afastamento das experiências práticas dos intérpretes, cujo acúmulo de conhecimento é de fundamental importância para auxiliar na tomada de decisões sobre a escolha das imagens.

Considerando que as feições cartográficas podem ser agrupadas em categorias de informações, propõe-se nesse estudo realizar também uma análise da interpretabilidade a partir da agregação de feições que possuem aspecto funcional em comum. Isso permite ter uma visão do potencial de interpretação mais abrangente do ponto de vista taxonômico. A análise de interpretabilidade por categoria necessita da integração dos indicadores de detecção e identificação de todas as feições que fazem parte deste agrupamento. Dessa forma, pode-se estabelecer um valor que seja significativo para um conjunto de classes através da média aritmética simples entre os seus respectivos índices de interpretabilidade. A questão a ser destacada é que teoricamente cada classe possui quantidades diferentes de elementos, correndo-se o risco na atribuição de valores com pesos iguais para todas as classes. Dessa forma, um elemento extraído de trecho ferroviário teria o mesmo peso da quantidade de elementos extraídos de trechos rodoviários, por exemplo. Porém, vale ressaltar que as ponderações são feitas nos processos de construção do índice de interpretabilidade, a partir da obtenção dos valores de detecção e identificação.

Ao final, são comparados os valores obtidos com a tabela de classificação qualitativa de desempenho de interpretabilidade, proposta na tabela 7.2. Pode-se assim, fazer comparação entre categorias a fim de conhecer aquelas com melhores e piores desempenhos em termos de interpretação. O quadro 7.2 apresenta um exemplo da agregação entre as classes para a composição do índice de Interpretabilidade por categoria.

Categoria	Indicador de	Indicador de	Índice de
	detecção	identificação	interpretabilidade
Hidrografia	IDET Trecho de drenagem	IIDE Trecho de drenagem	INT _{hidrografia}
	IDET _{Massa d} 'água	IIDE Trecho de drenagem	
Sistema de	IDET Rodovia pavimentada	IIDE Rodovia pavimentada	INT sistema de transporte
Transporte	IDET Arruamento	IIDE Arruamento	
Vegetação	IDET _{Campo}	IIDE _{campo}	INT _{vegetação}
	IDET _{Cultivo}	IIDE _{cultivo}	

Quadro 7.2: Exem	plo de gerac	ão do índice de	Interpretabilidade	por categoria
	p.e ge.e.			· · · · · · · · · · · · · ·

Atualmente, há a possibilidade de acesso a imagens de sensoriamento remoto com diversas características espaciais, radiométricas e espectrais. Muitas vezes, o usuário desse tipo de informação fica na dúvida sobre as reais potencialidades envolvidas sobre o processo de interpretação. A avaliação do grau de detecção e identificação de feições cartográficas em um conjunto de imagens obtidas através de diferentes fontes possibilita obter uma análise da interpretabilidade para sensores. Há, assim, a possibilidade de responder alguns questionamentos, principalmente quando se começa a trabalhar com imagens com melhores resoluções. Não necessariamente a aquisição de uma imagem de alta resolução, e provavelmente com custo mais elevado, atenderia às necessidades de extração de algumas feições cartográficas,

Para ajudar a responder a essa e outras questões, propõe-se nesse estudo aplicar o índice de interpretabilidade para sensores, comparando-se o grau de interpretação das feições e categorias detectadas e identificadas para diferentes sensores remotos. Sendo assim, cada sensor pode ter um índice de interpretabilidade apropriado para cada uso, sendo utilizado como referência as análises de detecção e identificação das categorias e suas respectivas feições extraídas.

Para atingir o índice de interpretabilidade por sensor, pode-se calcular a media aritmética simples das categorias analisadas, sendo obtido um valor associado à imagem de um determinado sensor.

Os valores obtidos são comparados com a tabela de classificação qualitativa de desempenho de interpretabilidade, gerando como resultado final uma avaliação geral por sensor (quadro 7.3). Pode-se assim, fazer comparação entre sensores a fim de conhecer aqueles com melhores e piores desempenhos em termos de interpretação para a finalidade desse estudo.

Sensor	Indicador de	Indicador de	Índice de
	detecção	identificação	interpretabilidade
RapidEye	IDET hidrografia	IIDE hidrografia	INT _{RapidEye}
	IDET _{vegetação}	IIDE _{vegetação}	
AVNIR-2	IDET hidrografia	IIDE hidrografia	INT AVNIR-2
	IDET _{vegetação}	IIDE _{vegetação}	
OLI	IDET hidrografia	IIDE hidrografia	INT _{OLI}
	IDET _{vegetação}	IIDE _{vegetação}	

Quadro 7.3: Exemplo de geração do índice de Interpretabilidade por sensor.

7.2 GERAÇÃO DO ÍNDICE DE INTERPRETABILIDADE NA BHRSJ

A seguir, serão descritas as etapas para a elaboração do índice de interpretabilidade a partir das imagens usadas para o estudo. Uma vez estabelecidos os índices de detecção e identificação para todas as classes, tais valores serão analisados de forma a se estabelecer o potencial de interpretação envolvido.

7.2.1 Interpretabilidade por feição

A primeira forma de análise da interpretabilidade está associada às feições extraídas e classificadas a partir das imagens RapidEye, AVNIR-2 e OLI considerando três aspectos relacionados diretamente com a adequação com a escala cartográfica: exatidão posicional, as características da forma (medida pela distância média entre os vértices) e a dimensão mínima de representação de cada classe.

Dessa forma, antes de apresentar o índice de interpretabilidade para as classes do RapidEye, vale destacar que, em termos de exatidão posicional, todas as classes apresentam valores da discrepância médios adequados para a escala 1:25.000 classe B, incluindo as amostras de massa d´água, que apresentam valores de discrepância média igual a 8,15 metros, com desvio padrão igual a 2,24 metros, ou seja, atenderia à escala 1:10.000.

Já em relação à avaliação da forma dos traçados, no qual foi feita a comparação da distância média dos vértices extraídos do RapidEye com a

base 1:25.000, observou-se maior diferenciação entre as classes. As classes arruamento, campo, floresta, rodovia de leito natural e trecho de massa d água apresentaram a distância média entre os vértices compatível com a escala 1:25.000. Já as classes, ferrovia, mangue, massa d´água, rodovia pavimentada apresentaram valores compatíveis para 1:50.000, enquanto a classe cultivo o valor foi representativo para 1:100.000.

O último critério de adequação da interpretabilidade para as escalas cartográficas foi a associação entre os tamanhos mínimos extraídos e o que é considerado como representativo para cada escala. Como critério de qualidade para se estabelecer a adequação à determinada escala, foi definido o valor de 90 % do número de traçados extraídos dentro do intervalo de valores estabelecidos pela AT-EDGV. Tal valor foi estabelecido para manter o critério de probabilidade adotado para a avaliação posicional proposta no PEC.

Os resultados mostram que as classes floresta e mangue apresentaram resultados adequados à escala 1:25.000. Já as classes trecho de massa, trecho de drenagem e rodovia de leito natural apresentaram mais de 90 % dos elementos extraídos com dimensão mínima de representação para a escala 1:100.000, enquanto os resultados para massa d'água e campo se mostram adequados para 1:50.000.

A tabela 7.3 apresenta, de forma resumida, as escalas adequadas para cada classe considerando os três critérios: exatidão posicional, forma e dimensão mínima. Os campos com traço representam as classes onde não foi possível extrair elementos com as dimensões mínimas representativas para cada escala, já que o elemento possui grande extensão. No caso do arruamento, houve um baixo percentual de segmentos com dimensão suficiente para atender até a escala 1:50.000. Além disso, não houve amostras de feições de arruamento com extensão superior a 500 metros dimensão mínima para atendimento à escala 1:100.000, para uma avaliação mais completa para todas as escalas. Destaca-se novamente que essas distâncias se referem ao trecho de arruamento, não se referindo à malha de ruas. No caso dos trechos de drenagem, não foi possível obter amostras para a escala 1:250.000, porém houve um aproveitamento acima de 90% para a escala 1:100.000. No caso das massas d´água, não foi possível obter amostras na escala 100.000, mas há bom aproveitamento para 1:50.000.

317

Classe	Exatidão	Formo	Dimensão
Classe	posicional	гоппа	mínima
Arruamento	1:25.000	1:25.000	-
Campo	1:25.000	1:25.000	1:50.000
Cultivo	1:25.000	1:100.000	1:50.000
Ferrovia	1:25.000	1:50.000	-
Floresta	1:25.000	1:25.000	1:25.000
Mangue	1:25.000	1:50.000	1:25.000
Massa d água	1:10.000	1:50.000	1:50.000
Rodovia Leito Natural	1:25.000	1:25.000	1:100.000
Rodovia pavimentada	1:25.000	1:50.000	-
Trecho de drenagem	1:25.000	1:50.000	1:100.000
Trecho de massa d água	1:25.000	1:25.000	1:100.000

Tabela 7.3: Escalas adequadas para cada classe extraída no RapidEye.

De uma forma geral, os resultados mostram que o critério para avaliar a dimensão mínima é o mais rigoroso em termos de representação cartográfica, com exceção do mangue e cultivo, cujo parâmetro de forma é o mais exigente. A exatidão posicional apresenta menor rigor cartográfico para a representação das classes.

A tabela 7.4 apresenta os valores dos indicadores de detecção (IDET) e de identificação (IIDE) para as imagens RapidEye, além do Índice de Interpretabilidade, bem como seu enquadramento na classe de interpretabilidade proposta.

Classo	IDET		Índice de	Classe de
Classe			Interpretabilidade	Interpretabilidade
Arruamento	0,59	0,38	0,49	С
Campo	0,76	0,81	0,79	В
Cultivo	0,69	0,77	0,73	В
Ferrovia	0,67	0,76	0,72	В
Floresta	0,82	0,88	0,85	A
Mangue	0,82	0,93	0,87	A
Massa d água	0,83	0,93	0,88	A
Rodovia Leito Natural	0,81	0,75	0,78	В
Rodovia pavimentada	0,80	0,79	0,80	A
Trecho de drenagem	0,47	0,36	0,41	С
Trecho de massa d água	0,81	0,91	0,86	A

Tabela 7.4: Índice de Interpretabilidade para as classes extraídas no RapidEye.

A maioria das classes analisadas possui uma qualidade de interpretabilidade boa, fato esperado pelas características do sensor para atender ao mapeamento dos objetos da cartografia de referência. Apenas a massa d´água foi classificada como uma interpretabilidade excelente, já que seu IDET e IIND estão acima de 0,8.

As classes arruamento e trecho de drenagem apresentaram a interpretabilidade razoável, ocasionado pelo baixo índice de detecção. As duas primeiras classes tiveram os parâmetros de qualidade de omissão baixos, ou seja, poucos elementos, em termos de extensão e número de objetos, foram extraídos. Já a ferrovia, apesar de ter quase 90% de sua extensão extraída, apresentou um baixo valor da Qualidade de Forma (QF), parâmetro que compara a distância média dos vértices da base extraída com a base de referência. Provavelmente o fato de a ferrovia estar com parte de sua estrutura deteriorada seja uma explicação para esse baixo valor do QF. Outro aspecto observado no trabalho de campo foi a presença de caminhos para pedestres e arruamentos que passam paralelamente à ferrovia, prejudicando um traço mais preciso do trecho ferroviário.

Uma classe que apresentou uma boa interpretabilidade foi o trecho de massa d'água. Porém, é importante lembrar que na base cartográfica de referência, os elementos dessa classe correspondem aos rios com larguras superiores a 20 metros (0,8 mm na escala). Por isso houve um aproveitamento melhor em termos de detecção dessa classe, já que no caso do RapidEye precisaria de 4 pixels para a detecção. Já a detecção dos trechos de drenagem foi baixa, uma vez que engloba todos os rios. Porém, o valor do IDET ainda pode ser considerado razoável por conta da presença dos trechos de massa d'água, que obrigatoriamente devem ter o eixo do canal delimitado, correspondendo ao seu respectivo trecho de drenagem.

Combinando-se os resultados de detecção e identificação com os critérios de avaliação por escala, pode-se concluir que a maioria das feições extraídas das imagens RapidEye são adequadas para atendimento as escala 1:25.000 e 1:50.000 em termos de exatidão posicional e características da forma, ou seja, os índices de interprtebilidade para cada classe estaria relacionado com estas escalas.

Porém ao se analisar o resultado do critério de dimensão mínima se confirma que a imagem RapidEye não serviria para a produção de uma base cartográfica de sistema de transporte e hidrografia nas escalas de 1:25.000 ou 1:50.000, uma vez que essa base exigiria uma maior densidade de informações, principalmente de arruamentos e trechos de drenagem, sendo esta uma classe fundamental para o uso de análises topográficas. Nesse estudo, apenas 33% dos trechos de drenagem foram extraídos nas imagens RapidEye. Apenas nos canais fluviais com largura acima de 10 metros, foi possível uma extração (parcial ou integral) dessa classe. Drenagens com largura inferior a 10 metros, que correspondem a grande maioria dos canais, não foram extraídas. Dessa forma, percebe-se que apenas uma imagem com resolução espacial maior poderia atender a essa necessidade de mapeamento dos canais com larguras menores Como não há uma especificação em termos de largura mínima a ser adquirida, corre-se o risco grande de não se mapear os trechos de drenagem.

Para tornar os valores do índice de interpretabilidade um pouco contextualizadas com as escalas cartográficas, pode-se comparar esse valor com os resultados dos percentuais de elementos extraídos completos por

320

extensão mínima (tabelas 5.18 até 5.23). A tabela 7.5 mostra uma comparação entre o valor do Índice de Interpretabilidade com o percentual dos elementos extraídos por dimensão mínima para a escala 1:50.000. As classes ferrovia e rodovia pavimentada não puderam ser avaliadas pela ausência de amostras significativas com as dimensões mínimas de todas as escalas. Apesar de ser uma tentativa de associar o valor do índice de interretabilidade com algo que possa ser comparado cartograficamente (dimensão mínima), torna-se necessário um estudo mais específico com uma escala específica para a obtenção de resultados mais consistentes.

Classe	Índice de Interpretabilidade	Escala	Percentual extraído
Arruamento	0,49	1:50.000	0 %
Campo	0,79	1:50.000	100 %
Cultivo	0,73	1:50.000	100 %
Floresta	0,85	1:50.000	95,45 %
Mangue	0,87	1:50.000	100 %
Massa d água	0,88	1:50.000	94,44 %
Rodovia Leito Natural	0,78	1:50.000	82,33 %
Trecho de drenagem	0,41	1:50.000	47,22%
Trecho de massa d água	0,86	1:50.000	73,33 %

Tabela 7.5: Comparação entre o índice de Interpretabilidade das classes com os percentuais extraídos na RapidEye.

De certa forma, pode-se afirmar que o valor de 0,87 no IINT para o mangue possibilita a extração de 100% dos polígonos de mangue, enquanto o valor de 0,41 para o trecho de drenagem possibilita a extração de 47,22% das linhas.

Associando-se as classes de interpretabilidade com as escalas, pode-se estabelecer a adequação do Índice de Interpretabilidade das classes extraídas a partir das imagens RapidEye, apresentados na tabela 7.6. As avaliações incompletas de referem às classes que não tiveram amostras para avaliação da dimensão mínima para todas as escalas.

	Classe de		
Classe	interpretabilida	Escala	Observação
	de		
Arruamento	С	1:25.000	Avaliação incompleta
Campo	В	1:50.000	
Cultivo	В	1:100.000	
Ferrovia	В	1:50.000	Avaliação incompleta
Floresta	A	1:25.000	
Mangue	A	1:50.000	
Massa d água	A	1:50.000	
Rodovia Leito Natural	В	1:100.000	
Rodovia pavimentada	А	1:50.000	Avaliação incompleta
Trecho de drenagem	С	1:100.000	
Trecho de massa d água	A	1:100.000	

Tabela 7.6: Adequação do índice de Interpretabilidade das classes extraídas no RapidEye por escala.

Para o sensor AVNIR-2, a maioria das classes analisadas apresentou discrepância média compatível com a escala 1:25.000 em termos de exatidão posicional. Porém, as classes mangue e trecho de drenagem apresentaram valor da discrepância próximo de 30 metros, ou seja, adequadas somente para o atendimento para a escala 1:50.000 classe B.

Em termos das características de forma, a distância média dos vértices das linhas e polígonos extraídos foi compatível com a escala 1:50.000 em quase todas as classes analisadas, ou seja, os valores encontrados ficaram menores do que o valor da distância média estabelecida nessa escala. As exceções foram a ferrovia e o cultivo, cujos valores ficaram com valores da distância média projetada para 1:250.000.

Para a avaliação da representação mínima dos objetos, os resultados foram semelhantes ao RapidEye, com exceção da massa d'água, ou seja, as classes floresta e mangue apresentaram os melhores resultados, sendo adequados para a escala 1:25.000, enquanto as classes campo e cultivo atendem à escala 1:50.000. Já as classes campo, trecho de massa e rodovia de leito natural apresentaram valores acima de 90 % para os tamanhos mínimos de representação na escala 1:100.000, enquanto a massa d'água teve o tamanho mínimo extraído adequado para 1:250.000. Vale destacar que a massa d'água apresenta uma grande divergência e termos de área, já que existem muitos polígonos dom dimensões reduzidas (menores que a área mínima de mapeamento para 1:50.000) e uma área muito grande. Não foram encontradas áreas com tamanhos intermediários. Provavelmente se existissem massas d'água cujas áreas tivessem no intervalo entre 40.000 e 250.000 m², seria possível afirmar que atenderia o mapeamento 1:100.000. Isto é reforçado pelo fato de 88 % das áreas com dimensões para a representação 1:50.000 serem detectadas. Em relação aos trechos de drenagem, constatou-se o não atendimento para escalas maiores que 1:100.000. Não houve amostras para avaliação na escala 1:250.000, por isso a avaliação ficou incompleta.

A tabela 7.7 apresenta as escalas adequadas para cada classe considerando o critério posicional, de forma e dimensão mínima. Os campos com traço representam as classes onde não foi possível extrair elementos com as dimensões mínimas representativas para cada escala. -

Classe	Exatidão posicional	Forma	Dimensão mínima
Arruamento	1:25.000	1:50.000	-
Campo	1:25.000	1:50.000	1:50.000
Cultivo	1:25.000	1:250.000	1:50.000
Ferrovia	1:25.000	1:250.000	-
Floresta	1:25.000	1:50.000	1:25.000
Mangue	1:50.000	1:50.000	1:25.000
Massa d água	1:25.000	1:50.000	1:250.000
Rodovia Leito Natural	1:25.000	1:50.000	1:100.000
Rodovia pavimentada	1:25.000	1:50.000	-
Trecho de drenagem	1:50.000	1:50.000	-
Trecho de massa d água	1:25.000	1:25.000	1:100.000

Tabela 7.7: Escalas adequadas para cada classe extraída no AVNIR-2

Assim como na análise dos dados extraídos do RapidEye, nota-se que os elementos extraídos do AVNIR-2 não possuem as mesmas características em termos posicionais, de forma e de representação mínima, havendo uma transição entre as escalas 1:25.000 e 1:250.000.

A tabela 7.8 apresenta os valores de cada classe dos índices de detecção e identificação calculados para os dados das imagens AVNIR-2 e o seu respectivo índice de interpretabilidade.

Assim como na avaliação da interpretabilidade das imagens RapidEye, a maioria das classes analisadas da base cartográfica gerada a partir do AVNIR-8 está situada nas faixas classificadas como ótima e boa interpretabilidade, respectivamente notas A e B.

Classo	IDET		Índice de	Classe de
Classe			Interpretabilidade	interpretabilidade
Arruamento	0,38	0,14	0,26	D
Campo	0,68	0,83	0,75	В
Cultivo	0,57	0,71	0,64	В
Ferrovia	0,54	0,61	0,57	С
Floresta	0,73	0,87	0,80	A
Mangue	0,74	0,93	0,84	A
Massa d água	0,75	0,88	0,81	A
Rodovia Leito Natural	0,75	0,60	0,68	В
Rodovia pavimentada	0,68	0,70	0,69	В
Trecho de drenagem	0,41	0,21	0,31	D
Trecho de massa d água	0,73	0,89	0,81	В

Tabela 7.8: Índice de interpretabilidade para as classes extraídas no AVNIR-2.

A classe ferrovia aparece com interpretabilidade razoável (nota C), enquanto as classes arruamento e trecho de drenagem possuem interpretabilidade fraca (nota D), o que seria esperado. Todas possuem um baixíssimo valor do parâmetro de Qualidade de Detecção, mas possuem valores razoáveis da Qualidade de Forma, Qualidade Posicional e da Qualidade da Segmentação, aumentando um pouco o valor do IDET. No caso do arruamento, os poucos elementos extraídos estão localizados em áreas urbanas pouco densas, enquanto os trechos de drenagem extraídos constituem os eixos principais dos trechos de massa d´água extraídos, cujo valor do IDET foi bastante significativo.

A classe cultivo, apesar de possuir bom valor de IIDE, também possui baixo valor do IDET, notando-se a dificuldade na delimitação desse tipo de classe, que exige um conhecimento amplo sobre a diversidade de respostas espectrais possíveis dessa classe. Talvez esse valor possa ser melhorado com mais testes de segmentação.

Apesar da maioria das classes estarem na classe A e B, nota-se que houve uma redução geral nos Indicadores de Detecção e Identificação em relação aos elementos extraídos a partir das imagens RapidEye. A média dos valores do IDET e IIDE nas imagens RapidEye são, respectivamente de 0,73 e 0,75, enquanto no AVNIR tais valores são 0,63 e 0,67.

Combinando-se os resultados de detecção e identificação com os critérios de avaliação por escala, pode-se concluir que a maioria das feições extraídas das imagens AVNIR-2 são, em termos de exatidão posicional, adequadas para atendimento às escala 1:25.000 e 1:50.000. Os resultados são semelhantes quando comparados com as informações geradas no RapidEye.

Cenário parecido também, ao se analisar o resultado do critério de dimensão mínima, no qual se confirma que a imagem AVNIR-2 não serviria para a produção de uma base cartográfica de sistema de transporte e hidrografia nas escalas 1:25.000 ou 1:50.000, uma vez que essa base exigiria uma maior densidade de informações. Apenas nas classes campo, cultivo, mangue e floresta, a dimensão dos objetos detectados atenderia ao mapeamento até a escala 1:50.000. O trecho de drenagem, pelo menos, em termos de representação mínima, não atenderia à nenhuma escala.

Para tornar os valores do índice de interpretabilidade contextualizadas com as escalas cartográficas, comparou-se os valores com os resultados dos percentuais de elementos extraídos completos por extensão mínima (tabelas 5.18 até 5.23). A tabela 7.9 mostra uma comparação entre o valor do Índice de Interpretabilidade com o percentual dos elementos extraídos nas imagens AVNIR-2 para a dimensão mínima para cada escala. As classes arruamento, ferrovia e rodovia pavimentada não puderam ser avaliadas pela ausência de amostras significativas com as dimensões mínimas de todas as escalas.

	Índice de	Fecala	Percentual
Classe	Interpretabilidade	LSCala	extraído
Arruamento	0,26	1:50.000	0 %
Campo	0,75	1:50.000	100 %
Cultivo	0,64	1:50.000	100%
Floresta	0,80	1:50.000	95,45 %
Mangue	0,84	1:50.000	100 %
Massa d água	0,81	1:50.000	88,88 %
Rodovia Leito Natural	0,68	1:50.000	80,03 %
Trecho de drenagem	0,31	1:50.000	33,33 %
Trecho de massa d água	0,81	1:50.000	66 %

Tabela 7.9: Comparação entre o índice de Interpretabilidade das classes com os percentuais extraídos no sensor AVNIR-2.

Assim como foi observado na avaliação do RapidEye, nota-se uma correlação entre os valores do IINT e o percentual extraído. Quanto maior o valor do IINT, maior é a tendência do percentual extraído. Porém cada classe possui suas especificidades, como, por exemplo, a floresta e o trecho de drenagem, que apesar de apresentaram IINT semelhantes possuem percentuais extraídos diferentes. Reforça-se, então, a necessidade de um estudo mais detalhado para cada escala.

Foi na avaliação da forma que os resultados menos satisfatórios apareceram nas classes cultivo e ferrovia, já que a distância média entre os vértices só foi compatível para os valores projetados para a escala 1:250.000.

Associando-se as classes de interpretabilidade com as escalas, pode-se estabelecer os critérios apresentados na tabela 7.10.

Classe	Classe	Escala	Observação
Arruamento	D		Avaliação
		1:50.000	incompleta
Campo	В	1:50.000	
Cultivo	В	1:250.000	
Forrovia	С		Avaliação
Fellovia		1:250.000	incompleta
Floresta	А	1:50.000	
Mangue	А	1:50.000	
Massa d água	А	1:250.000	
Rodovia Leito Natural	В	1:100.000	
Podovia povimontada	В		Avaliação
Rouovia pavimentaua	_	1:50.000	incompleta
Trecho de drenagem	D		Avaliação
	_	1:50.000	incompleta
Trecho de massa d água	А	1:100.000	

Tabela 7.10: Adequação do Índice de Interpretabilidade das classes extraídas no AVNIR-2 por escala.

O último sensor avaliado, OLI, teve os parâmetros da Qualidade Posicional semelhantes ao AVNIR-2, ou seja, algumas classes apresentaram discrepância média compatível para a escala 1:50.000 classe B e outras para 1:25.000 classes B e C.

Em termos de análise de forma, a distância média dos vértices das linhas e polígonos para as classes floresta, mangue, massa d água e rodovia de leito natural foi compatível com a escala 1:50.000, enquanto as classes rodovia pavimentada, trecho de drenagem, trecho de massa d´água, e campo apresentaram valores de distância média dos vértices compatíveis com o especificado para a escala 1:100.000. Para o cultivo, a distância média dos vértices ficou na faixa projetada para 1:250.000. Já para ferrovia o valor ficou acima da distância média projetada para 1:250.000 (tabela 7.11).

Em termos de avaliação da representação mínima, as áreas de floresta, cultivo e campo tiveram mais de 90% de seus polígonos extraídos compatíveis com as dimensões mínimas na escala 1:50.000, enquanto na classe mangue a extensão mínima extraída está associada à escala 1:25.000. O pior resultado foi a massa d´água, cujo resultado se adequou para 1:250.000 (caso existentes

amostras para escalas maiores, haveria a possibilidade de adequação para 1:100.000).

Classe	Exatidão posicional	Forma	Dimensão mínima
Arruamento	-	-	-
Campo	1:25.000	1:100.000	1:50.000
Cultivo	1:25.000	1:250.000	1:50.000
Ferrovia	1:25.000	Não adequada	-
Floresta	1:25.000	1:50.000	1:50.000
Mangue	1:50.000	1:50.000	1:25.000
Massa d água	1:25.000	1:50.000	1:250.000
Rodovia Leito Natural	1:25.000	1:50.000	1:100.000
Rodovia pavimentada	1:50.000	1:100.000	-
Trecho de drenagem	1:50.000	1:100.000	-
Trecho de massa d água	1:50.000	1:100.000	1:100.000

Tabela 7.11: Escalas adequadas para cada classe extraída no OLI.

A tabela 7.12 apresenta os valores do índice de detecção e identificação calculados para os dados das imagens OLI e seu respectivo índice de interpretabilidade.

Como era esperado, nenhum elemento da classe arruamento foi extraído das imagens fusionadas do sensor OLI, se enquadrando na classe de interpretabilidade E. Outra classe considerada insatisfatória foi o trecho de drenagem, cujo valor do IINT foi de 0,21, fato semelhante com os resultados dos dados extraídos dos sensores anteriores. No caso dos trechos de massa d'água, apenas os canais com mais de 50 metros de largura foram detectados, que correspondem ao principal rio da bacia.

Classe	IDET	IIDE	IINT	Classe de interpretabilidade
Arruamento	0,00	0,00	0,00	E
Campo	0,63	0,75	0,69	В
Cultivo	0,51	0,62	0,56	C
Ferrovia	0,43	0,53	0,48	С
Floresta	0,70	0,76	0,73	В
Mangue	0,72	0,83	0,77	В
Massa d água	0,57	0,53	0,55	C
Rodovia Leito Natural	0,61	0,49	0,55	C
Rodovia pavimentada	0,69	0,66	0,68	В
Trecho de drenagem	0,31	0,12	0,21	D
Trecho de massa d água	0,70	0,69	0,69	В

Tabela 7.12: Índice de interpretabilidade para as classes extraídas no OLI.

Além disso, a classe cultivo, assim como ocorreu com os outros dois sensores testados, apresentou um baixo indicador de detecção, acarretando em uma qualidade de interpretabilidade apenas razoável. Esse cenário é semelhante ao resultado verificado com a feição ferrovia, cuja extração apresentou descontinuidades, e com a feição rodovia de leito natural, cuja qualidade da forma propiciou um valor médio no IDET, além da classe massa d'água, que apresentou baixo valor na Qualidade de Detecção dos Objetos.

As demais classes apresentaram IDET e IIDE acima de 0,6, constituindo classes com qualidade de interpretabilidade boa. Nessa faixa de interpretabilidade estão as classes de vegetação, com exceção do cultivo, do trecho de massa d´água e a rodovia pavimentada, cujos resultados podem ser considerados satisfatórios.

Combinando-se os resultados de detecção e identificação com os critérios de avaliação por escala, pode-se concluir que a maioria das feições extraídas das imagens OLI é adequada para atendimento às escala 1:25.000 e 1:50.000 em termos de exatidão posicional.

Porém, ao se analisar a forma dos traços, observa-se que a maioria das classes possuiu uma boa interpretabilidade para o atendimento na escala

1:50.000 (Floresta, mangue, massa d'água e rodovia de leito natural), 1:100.00 (campo, rodovia pavimentada, trecho de drenagem e trecho de massa d'água) e 1:250.000 (cultivo). No caso do cultivo, vale destacar que as extrações dos três sensores apresentaram interpretabilidade abaixo das demais classes de vegetação, podendo ser considerado um resultado ruim. Em algumas áreas, principalmente no recorte 2, há o predomínio de propriedades pequenas, o que torna o uso de sensores de média resolução pouco recomendado.

Já o resultado do critério de dimensão mínima confirma que a imagem OLI não serviria para a produção de uma base cartográfica de sistema, de transporte e hidrografia melhor que 1:100.000, diferente de todas as classes de vegetação, que atendem até a escala 1:50.000. O trecho de drenagem, pelo menos, em termos de representação mínima, não atenderia a nenhuma escala.

Foi realizada também uma comparação entre os valores do IINT com os resultados dos percentuais de elementos extraídos completos por extensão mínima (tabelas 5.17 até 5.22). A tabela 7.13 mostra compara o valor do Índice de Interpretabilidade com o percentual dos elementos extraídos nas imagens OLI para a dimensão mínima para cada escala. As classes arruamento, ferrovia e rodovia pavimentada não puderam ser avaliadas pela ausência de amostras significativas com as dimensões mínimas de todas as escalas.

Classa	Índice de	Ecolo	Percentual
Classe	Interpretabilidade	ESCAIA	extraído
Campo	0,69	1:50.000	100 %
Cultivo	0,56	1:50.000	100 %
Floresta	0,73	1:50.000	100 %
Mangue	0,77	1:50.000	100 %
Massa d água	0,55	1:50.000	-
Rodovia Leito Natural	0,55	1:50.000	72,23 %
Trecho de drenagem	0,21	1:50.000	16,66 %
Trecho de massa d água	0,69	1:50.000	66 %

Tabela 7.13: Comparação entre o índice de Interpretabilidade das classes com os percentuais extraídos do sensor OLI. Associando-se as classes de interpretabilidade com as escalas, podemse estabelecer os critérios apresentados na tabela 7.14.

Classe	Classe	Escala	Observação
Arruamento	E	-	Avaliação incompleta
Campo	В	1:100.000	
Cultivo	С	1:250.000	
Ferrovia	С	-	Restrição na forma
Floresta	В	1:50.000	
Mangue	В	1:50.000	
Massa d água	С	1:250.000	
Rodovia Leito Natural	С	1:100.000	
Rodovia pavimentada	В	1:100.000	
Trecho de drenagem	D	1:100.000	Avaliação incompleta
Trecho de massa d água	В	1:100.000	

Tabela 7.14: Adequação do índice de Interpretabilidade das classes extraídas no OLI por escala.

7.2.2 Interpretabilidade por categoria

Além da análise da interpretabilidade para cada classe, propõe-se nesse estudo, uma segunda abordagem da interpretabilidade, associada às categorias de informação, correspondendo ao agrupamento das feições extraídas e classificadas a partir das imagens RapidEye, AVNIR-2 e OLI.

Antes de apresentar o índice de interpretabilidade para as categorias do RapidEye, vale destacar que, em termos de exatidão posicional, todas as classes de hidrografia apresentam valores da discrepância médios adequados para a escala 1:25.000, com exceção da massa d´água que apresentou valores de discrepância média compatíveis à escala 1:10.000. Porém, como critério para o estabelecimento da melhor escala para cada categoria, escolhe-se a classe com menor escala de adequação para o objetivo. Nesse caso, por exemplo, a escala 1:25.000 será usada como referência para representar a exatidão posicional da hidrografia extraída na imagem RapidEye. Essa escala também pode ser estabelecida para as outras duas classes, já que todas as classes apresentaram o valor de discrepância média compatível.

Já em relação à avaliação da forma dos traçados, no qual foi feita a comparação da distância média dos vértices extraídos do RapidEye com a base 1:25.000, observou-se maior diferenciação entre as classes. A categoria hidrografia teve o trecho de drenagem como a classe com pior desempenho em termos posicionais, atendendo à escala 1:50.000, valor similar à categoria sistema de transporte (ferrovia e rodovia de leito natural). Já para vegetação, a classe campo apresentou discrepância média mais elevada, atendendo à escala 1:100.000.

Já em termos de comparação entre os tamanhos mínimos extraídos com o representativo para cada escala, os resultados mostram que nas três categorias houve a presença de alguma classe com compatibilidade para 1:100.00. Vale destacar a dificuldade de extração de traçados extensos na classe arruamento, de forma que não houve a possibilidade de uma avaliação completa pata todas as escalas, especificamente nas escalas 1:100.000 e 1:250.000. Foi possível extrair segmentos menores que 500 metros, mas não houve uma adequação a nenhuma escala, já que foram extraídos menos de 90% das feições com tamanho mínimo de representação para as escalas.

A tabela 7.15 apresenta, de forma resumida, as escalas adequadas para cada Categoria extraída das imagens RapidEye considerando os critérios de exatidão posicional, forma e dimensão mínima.

Classe	Exatidão posicional	Forma	Dimensão mínima
HD	1:25.000	1:50.000	1:100.000
ST	1:25.000	1:50.000	1:100.000
VG	1:25.000	1:100.000	1:50.000

Tabela 7.15: Escalas adequadas para cada classe extraída no RapidEye.

Para a avaliação das categorias cujas feições foram extraídas no AVNIR-2 (tabela 7.16), pode-se considerar que em termos de exatidão

posicional, todas as classes de hidrografia e vegetação apresentam valores da discrepância médios adequados para a escala 1:50.000, enquanto o sistema de transporte apresentou resultado compatível para 1:25.000.

Já em relação à avaliação da forma dos traçados, no qual foi feita a comparação da distância média dos vértices extraídos do AVNIR-2 com a base 1:25.000, observou-se uma grande divergência entre as categorias. A categoria hidrografia teve as classes com melhor desempenho em termos posicionais, atendendo à escala 1:50.000.

Porém, nas classes de sistema de transporte e vegetação houve de classes que apresentaram valores elevados da distância média dos vértices, sendo compatíveis para o valor projetado na escala 1:250.000.

Já em termos de comparação entre os tamanhos mínimos extraídos com o representativo para cada escala, os resultados mostram que as categorias apresentam adequações de escala distintas. A vegetação apresentou melhor resultado, compatível para 1:50.000, o sistema de transporte apresenta valor compatível para 1:100.000, enquanto a hidrografia o resultado foi 1:250.000

Classe	Exatidão posicional	Forma	Dimensão mínima
HD	1:50.000	1:50.000	1:250.000
ST	1:25.000	1:250.000	1:100.000
VG	1:50.000	1:250.000	1:50.000

Tabela: 7.16: Escalas adequadas para cada classe extraída no AVNIR-2

Para a avaliação das categorias cujas feições foram extraídas no OLI (tabela 7.17), pode-se considerar que em termos de exatidão posicional, todas as classes de hidrografia apresentam exatidão posicional adequados para a escala 1:50.000

Já em relação à avaliação da forma dos traçados, no qual foi feita a comparação da distância média dos vértices extraídos do OLI com a base 1:25.000 e observou-se que as categorias hidrografia e sistema de transporte tiveram as as classes com melhor desempenho em termos posicionais, atendendo à escala 1:100.000. No caso do sistema de transporte, vale ser
destacado a restrição da forma da classe ferrovia, que não atendeu ao valor projetado para 1:250.000. Como o valor da distância média entre vértices foi obtido através de uma projeção de escalas maiores, sem haver um ajuste mais adequado dessa metodologia, esse valor não será usado como referência para a avaliação da categoria como um todo.

Na categoria vegetação houve classes que apresentaram valores elevados da distância média dos vértices, sendo compatíveis para o valor projetado na escala 1:250.000. Em geral, considerando a distância média dos vértices, para a categoria Sistema de Transporte, verificou-se compatibilidade com a escala 1:100.000. No caso da ferrovia, o valor da distância média (aproximadamente 62 metros) ficou acima do limite projetado para 1:250.000, porém as rodovias apresentaram valores de distância média abaixo do limite de 1:100.000, Por isso, pode-se considerar o valor dessa categoria como representativa para 1:100.00, porém com a ressalva de que não é válido para o teste com a ferrovia.

Já em termos de comparação entre os tamanhos mínimos extraídos com o representativo para cada escala, os resultados gerados foram semelhantes ao AVNIR-2, no qual as categorias de vegetação, transporte e hidrografia apresentaram resultados compatíveis respectivamente com a escala 1:50.000, 1:100.000 e 1:250.000.

Classe	Exatidão posicional	Forma	Dimensão mínima
HD	1:50.000	1:100.000	1:250.000
ST	1:50.000	1:100.000*	1:100.000
VG	1:50.000	1:250.000	1:50.000

*com restrição na forma da ferrovia

A tabela 7.18 apresenta os valores dos índices de interpretabilidade (IINT) das três categorias referentes à extração nos três sensores. Para todos os sensores, a categoria de vegetação foi a que apresentou melhores resultados de interpretabilidade, seguida da hidrografia e por último o sistema de transporte.

	Classe	IINT	IINT	IINT
		RapidEye	AVNIR-2	OLI
	Arruamento	0,49	0,26	0,00
ст	Ferrovia	0,72	0,57	0,48
31	Rodovia Leito Natural	0,78	0,68	0,55
	Rodovia pavimentada	0,80	0,69	0,68
	IINT categoria	0,70	0,55	0,43
	Classe de	B	C	6
	Interpretabilidade	Б	C	C
	Campo	0,79	0,75	0,69
ST VG HD	Cultivo	0,73	0,64	0,56
	Floresta	0,85	0,80	0,73
	Mangue	0,87	0,84	0,77
	IINT categoria	0,81	0,76	0,69
	Classe de Interpretabilidade	В	В	В
	Massa d água	0,88	0,81	0,55
HD	Trecho de drenagem	0,41	0,31	0,21
	Trecho de massa d água	0,86	0,81	0,69
	IINT categoria	0,72	0,65	0,49
	Classe de Interpretabilidade	В	В	С

Tabela 7.18: Valores de IINT das classes extraídas calculados para as categorias.

Os resultados mais baixos da hidrografia e sistema de transporte estão diretamente relacionados com o mau desempenho, respectivamente, do trecho de drenagem e arruamento, duas feições lineares que apresentaram problemas principalmente na detecção.

Resumindo um pouco a análise das categorias, a tabela 7.19 apresenta os valores dos índices de interpretabilidade associados com a escala mais adequada para representação, considerando as características do traçado. A categoria vegetação apresenta uma boa interpretabilidade para a escala 1:50.000 nos três sensores, cenário diferente das outras categorias. O sistema de transporte e hidrografia da RapidEye apresentou boa interpretabilidade para 1:100.000. A hidrografia do AVNIR-2 possui boa interpretabilidade para 1:250.000, enquanto que a hidrografia do OLI foi considerada rezoável para 1:250.000. O sistema de transporte do AVNIR-2 e OLI também apresentou um grau razoável de interpretabilidade para 1:250.000.

Categoria	Sensor	IINT	Classe	Escala
ST	RapidEye	0,70	В	1:100.000
ST	AVNIR-2	0,55	С	1:250.000
ST	OLI	0,43	С	1:100.000*
VG	RapidEye	0,81	В	1:100.000
VG	AVNIR-2	0,76	В	1:250.000
VG	OLI	0,69	В	1:250.000
HD	RapidEye	0,72	В	1:100.000
HD	AVNIR-2	0,65	В	1:250.000
HD	OLI	0,49	C	1:250.000

Tabela 7.19: Adequação do índice de Interpretabilidade das categorias.

* com restrição da forma da ferrovia

7.2.3 Interpretabilidade por sensor

A terceira e última análise da interpretabilidade está associada ao sensor, correspondendo ao agrupamento das categorias extraídas e classificadas a partir das imagens RapidEye, AVNIR-2 e OLI (tabela 7.17). Essa análise corresponde ao estágio final da proposta desse estudo, de forma que se possa estabelecer, para cada tipo de insumo, um valor do potencial da interpretabilidade envolvida.

Em termos de exatidão posicional, todas as categorias extraídas do RapidEye apresentam valores da discrepância médios adequados para a escala 1:25.000, enquanto os dados obtidos a partir do AVNIR-2 e OLI atenderiam à 1:50.000

Já em relação à avaliação da forma dos traçados e a avaliação do tamanho mínimo, houve novamente um melhor resultado para o RapidEye, apropriado para o atendimento na escala 1:100.00, enquanto os outros dois sensores atenderiam à escala 1:250.000. A tabela 7.20 mostra, de forma

resumida, as escala adequadas para cada sensor, considerando os critérios de exatidão posicional, forma e dimensão mínima.

Classe	Exatidão posicional	Forma	Dimensão mínima
RapidEye	1:25.000	1:100.000	1:100.000
AVNIR-2	1:50.000	1:250.000	1:250.000
OLI	1:50.000	1:250.000	1:250.000

Tabela 7.20: Escalas adequadas para as imagens de cada sensor.

A tabela 7.21 apresenta os valores do índice de interpretabilidade (IINT) dos três sensores. Como era esperado, o índice de interpretabilidade (IINT) para as classes extraídas para o RapidEye apresentaram os melhores resultados, cujo valor foi de 0,74. Já para o sensor AVNIR-2 e OLI os valores do IINT foram, respectivamente de 0,65 e 0,53. Nas três categorias, percebe-se que o valor do IINT do AVNIR-2 é melhor que o OLI, com as maiores diferenças no sistema de transporte e na hidrografia, enquanto na vegetação, a diferença é relativamente pequena.

Tabela 7.21: Valores do índice de interpretabilidade (IINT) para as imagens dos três sensores.

	Categoria	IINT	Classe de interpretabilidade
	ST	0,70	В
RepidEye	VG	0,81	A
	HD	0,72	В
	IINT sensor	0,74	В
AVNIR-2	ST	0,55	С
	VG	0,76	В
	HD	0,65	В
	IINT sensor	0,65	В
OLI	ST	0,43	С
	VG	0,69	В
	HD	0,49	С
	IINT sensor	0,53	C

Dessa forma, pode-se perceber que a resolução espacial de cada sensor tem um papel fundamental nessa distinção do potencial de interpretação. Um sensor como o OLI, apresentando resoluções radiométrica e espectral melhores do que o AVNIR-2, apresentou um desempenho inferior em termos de Interpretabilidade para aplicações em cartografia de referência.

Analisando o índice de identificação por sensor, percebe-se novamente o melhor resultado para as imagens RapidEye, cujo valor encontrado foi de 0,74, enquanto para o AVNIR-e e OLi foram, respectivamente de 0,65 e 0,53. Os melhores resultados para os três sensores foram na categoria Vegetação.. Os resultados para o sistema de transporte ficaram abaixo das outras categorias.

Dessa forma, para atender às necessidades do mapeamento das principais classes do mapeamento de referência, pode-se considerar que o RapidEye apresenta uma boa interpretabilidade (classe B para o mapeamento na escala 1:100.000), o AVNR-2 também apresenta uma boa interpretabilidade, porém para o atendimento a 1:250.000, enquanto o OLI atenderia também neste escala, mas como qualidade de interpretabilidade razoável, conforme apresentado na tabela 7.22.

Sensor	IINT	Classe	Escala
RapidEye	0,74	В	1:100.000
AVNIR-2	0,65	В	1:250.000
OLI	0,49	C	1:250.000

Tabela 7.22: Adequação do índice de Interpretabilidade das categorias.

7.2.4 Conclusões

O desenvolvimento do Índice de Interpretabilidade mostrou que é possível estabelecer alguns critérios para avaliação da qualidade dos produtos cartográficos derivados dos processos de extração e classificação de imagens orbitais. Dessa forma, essas avaliações complementam as já tradicionais formas de avaliação dos produtos cartográficos, cujo foco está normalmente baseado apenas na exatidão posicional.

Os resultados demostram que, apesar das imagens poderem atender às escalas cartográficas nas escalas 1:25.000 e 1:50.000 do ponto de vista posicional, o panorama muda quando se avalia o tratamento do seu conteúdo,

cuja exatidão se adequa a escalas menores. O principal fator restritivo obeservado ocorreu ao analisar a Qualidade de Detecção das Extensões, comparando-se a dimensão mínima representativa para cada escala com o tamanho extraído.

Sugere-se, para trabalhos futuros, alguns reajustes na metodologia, principalmente na Qualidade da Forma, que constituiu o parâmetro mais instável, porém acabou não sendo tão decisivo para a avaliação da interpretabilidada quanto o parâmetro de detecção que considera a dimensão mínima.

De qualquer forma, acredita-se que a construção do índice de Interpretabilidade se mostrou adequada para se alcançar o propósito desse estudo, destacando que a exatidão cartográfica de um produto cartográfico não deve ser vista apenas pelo seu caráter posicional, mas também pelo seu potencial na geração de novos produtos, ou seja, novas bases cartográficas.

Há a necessidade de documentação dos processos de avaliação de qualidade do dado para todas as etapas do processo de produção cartográfica, desde a ortorretificação e classificação das imagens até a base vetorial extraída e classificada, já que os erros tendem a se propagar em cada processo envolvido.

Reconhece-se que novas atividades possam ser aperfeiçoadas e que podem ser sugestões para continuidade do trabalho. Uma das reflexões é o escalonamento do índice de Interpretabilidade, que talvez precise ser revista. Utlizando como exemplo o valor de interpretabilidade de 0,81 da vegetação no RapidEye (tabela 7.16) com a escala de maior detalhe sendo 1:100.000. Caso fosse utilizada uma imagem de alta resolução espacial e se obtenha um índice aproximando de um, ainda é provável que não passe da escala 1:25.000, ou seja, não haverá linearidade. Apenas sobrariam a classe A para sensores com resoluções melhores que 5 metros. A solução seria um reescalonamento do índice para contemplar novos sensores.

De qualquer forma, optou-se no trabalho enfatizar a escolha de imagens de média resolução, usadas principalmente para o mapeamento topográfico nas escalas 1:50.000 e menores. Para a cartografia temática, outras questões precisam ser consideradas, principalmente no que se refere aos parâmetros radiométricos.

8. CONSIDERAÇÕES FINAIS

No projeto de tese enviado para o processo seletivo do Programa de Pós-Graduação em Geografia da UFRJ e refletido durante o início dos estudos, ficou estabelecido que este estudo devesse contribuir, do ponto de vista metodológico, para a extração, armazenamento e atualização de feições cartográficas, obtidas através da interpretação visual e automática de imagens de sensores remotos.

Para atingir esse objetivo, foram discutidas as potencialidades e limitações dos sensores para o processo de extração e classificação das feições cartográficas usadas no mapeamento de referência. Inicialmente procurou-se detalhar os conceitos mais importantes para a pesquisa e o planejamento metodológico do trabalho.

Sendo assim. foi feito um levantamento conceitual sobre Interpretabilidade, através de observações à respeito de suas diferentes abordagens. A partir da reflexão conceitual, elaborou-se uma proposta do Indice de Interpretabilidade, instrumento para avaliação da qualidade de imagens associada a critérios de extração e classificação de feições e que pode ser um elemento motivador para a avaliação da cartografia de referência. Na literatura específica não foram encontradas propostas de avaliação da interpretação vinculadas diretamente com a escala cartográfica. Neste estudo buscou-se uma breve reflexão da adequação do índice de interpretabilidade para as escalas do mapeamento sistemático brasileiro.

A proposta inicial era trabalhar na escala 1:100.000, usando-se os requisitos para a construção de todas as feições nesta escala. Porém, em virtude das limitações de tempo de estudo, foram focadas apenas as análises considerando imagem e feições selecionadas. Ou seja, foi estudada uma metodologia de trabalho, sem vínculo direto com escala, para extração de feições de algumas categorias.

De qualquer forma, dado a relevância desse estudo, existe um potencial para que este trabalho seja expandido para maiores e menores escalas. Sugere-se, para trabalhos futuros, uma análise específica por escala, podendo ser 1:100.000 ou 1:250.000, a fim de se obter repostas diretas em termos de extração e classificação para uma determinada escala.

Além disso, os procedimentos metodológicos abordados podem ser replicados para outras imagens de sensores lançados em 2015 e 2016, como por exemplo o CBERS-4 e SENTINEL-2. A avaliação de interpretabilidade destas imagens podem corroborar os resultados produzidos.

A referência para se construir os critérios de interpretabilidade foi a ET-EDGV, tendo em vista que é apresentada uma modelagem e padronização de dados geoespaciais para a cartografia de referência no Brasil. Nessa documentação, estão descritas as feições a serem extraídas para o mapeamento, assim como seus respectivos atributos. Usando-se os conceitos de detecção e identificação, foi possível criar relacionamentos entre estas tarefas com as feições e atributos contemplados na ET-ADGV.

Juntando-se a esta documentação, trabalhou-se também com a nova edição da ET-ADGV publicada em março de 2016, onde são detalhados os tipos de feição que devem ser contemplados para cada escala cartográfica e os critérios de aquisição das feições do mapeamento topográfico em função da escala. Esse documento auxiliou no entendimento sobre o grau de interpretabilidade apropriado para cada escala cartográfica.

Para avaliar a qualidade dos dados foram utilizadas as recomendações técnicas propostas na norma ISO 19157, principalmente em termos de completude, exatidão posicional e exatidão temática. Esse procedimento garante que o estudo esteja dentro da padronização das medidas de qualidade dos dados cartográficos produzidos.

Houve a compatibilização de metodologias de aquisição dos dados e seus respectivos controles de qualidade, considerando as normas estabelecidas. Ao final do estudo, pretende-se documentar o desenvolvimento de todas as técnicas voltadas para a questão de interpretabilidade em imagens, que possibilitem o aperfeiçoamento da aquisição e atualização de feições planimétricas da base cartográfica do mapeamento em diferentes escalas.

Os materiais e métodos estabelecidos para o desenvolvimento do trabalho podem ser considerados adequados. Inicialmente foram realizados os procedimentos de correção geométrica e radiométrica. Em termos de avaliação posicional das imagens, foi testada uma nova metodologia estatística de Vieira & Genro (2011) que necessita de mais estudos. Os resultados para o AVNIR-2 não corresponderam ao que se esperava desse tipo de produto.

Os procedimentos de extração e classificação dos dados de forma automática foram realizados, principalmente, para reduzir o tempo de interpretação. Um exemplo é o processo de segmentação e classificação da vegetação e massas d'água. Porém, em algumas situações, foi necessária uma intervenção semi-automática, no caso da vetorização dos trechos rodoviários e, até mesmo, visual para validar as observações de campo.

Ao final do estudo, mostrou-se uma síntese da classificação da interpretabilidade para as feições analisadas nos três sensores. Para isso, foram estabelecidas as premissas de detecção e identificação para avaliar a interpretabilidade das feições a partir de diferentes insumos, baseando-se em oito parâmetros de qualidade que pudessem refletir o potencial de interpretação envolvido. O grau da interpretabilidade foi associada à determinadas escalas de acordo com três critérios: exatidão posicional, forma e dimensão mínima de representação.

Pode-se considerar que os resultados gerados estão dentro da faixa esperada no início do estudo, considerando as potencialidades e limitações de extração e classificação envolvidas.

Por ser um estudo inicial, alguns ajustes serão necessários para o aprimoramento do índice de interpretabilidade. Dentre os principais aspectos a serem avaliados para trabalhos futuros destacam-se:

• Adaptação dos valores do índice de interpretabilidade que contemple a inserção de novos sensores, principalmente os de alta resolução.

• Reavaliar alguns parâmetros que apresentaram uma maior instabilidade, principalmente a Qualidade da Forma.

Uma limitação deste estudo foi a falta da abordagem sobre a questão da resolução temporal, através da identificação dos efeitos das variações sazonais e intervalo do tempo prolongado entre as datas de aquisição de cada imagem usadas como insumos para a interpretação.

No primeiro caso seria interessante buscar parâmetros climáticos, que visassem auxiliar na seleção de insumos de acordo com períodos secos e úmidos. Algumas classes possuem uma dinâmica significativa, como por exemplo, os elementos de hidrografia e vegetação. Além disso, algumas regiões tendem a ser mais sensíveis aos efeitos sazonais do que outras, dependendo das características do bioma.

Outra questão temporal está relacionada ao intervalo de tempo entre as imagens a serem analisadas e o dado de referência. Nesse estudo, utilizou-se uma base cartográfica de referência produzida a partir de modelos fotogramétricos referentes ao ano de 2005 e imagens do sensor OLI do ano de 2014, além das imagens AVNIR do ano de 2010 e RapidEye dos anos de 2011 e 2012. Em um intervalo de nove anos, podem ocorrer mudanças significativas na paisagem. O cenário ideal é que todas as imagens tivessem suas datas de aquisição mais próximas possíveis, a fim de evitar problemas causados por mudanças temporais, como, por exemplo, os desmatamentos, urbanização e outros processos que acontecem em ritmos acelerados. Porém, surgem as limitações impostas durante a fase da seleção dos dados, na qual as opções se restringem a um pequeno conjunto de dados.

Por isso, sugere-se a consideração das implicações da sazonalidade dos elementos caracterizados nos insumos, de forma que os parâmetros de interpretabilidade considerem as variações temporais, como por exemplo, os períodos secos e úmidos. Dessa forma, há de se pensar na possibilidade de incluir a exatidão temporal das imagens como critério para avaliação da interpretabilidade. Nesse estudo, não há como saber, de forma exata, se as diferenças encontradas foram causadas pelos efeitos sazonais, mas acreditase que seja um procedimento importante na avaliação da interpretabilidade.

9. REFERÊNCIAS BIBLIOGRÁFICAS

AMADOR, E. S.. Baía de Guanabara e Ecossistemas Periféricos: Homem e Natureza. Rio de Janeiro, 539 p. 1997.

ALMEIDA, F. F. M. de. The system of continental rifts bordering the Santos Basin, Brazil. Anais da Academia Brasileira de Ciências, v. 48 (suplemento). p. 15-26. 1976.

ALMEIDA, F. F. M. de; CARNEIRO, C. D. R. Origem e evolução da Serra do Mar. Revista Brasileira de Geociências, São Paulo, v. 28, n. 2. Jun 1998. p.135-150.1998.

ALVES, R.A. L.; VERGARA, O. R. Identificação de alvos urbanos em imagens Ikonos, aplicando classificação orientada a segmentos. Simpósio Brasileiro de Sensoriamento Remoto, XII, 16-21 de abril de 2005, Goiânia, p. 2573-2580.2005.

ALVES, P. D. V. Avaliação da qualidade de produtos cartográficos: proposta de metodologia para avaliação do Componente completude. Anais do XXVI Congresso Brasileiro de Cartografia. 2014.

ANDERSON, G.P.; PUKALL, B.; ALLRED, C.L.; JEONG, L.S.; HOKE, M.; CHETWYND, J.H.; ADLER-GOLDEN, S.M.; BERK, A.; BERNSTEIN, L.S.; RICHTSMEIER, S.C.; ACHARYA, P.K.; MATTHEW, M.W. FLAASH and MODTRAN4: State-of-the-art atmospheric correction for hyperspectral data. In: Aerospace Conference, IEEE,1999. Proceedings. v. 4, p. 177-181,1999.

ANDRADE, J. B. Fotogrametria, 2ª Edição. Ed.SBEE.274 p. 2003.

ANJOS. C.S, ALMEIDA, C. M. Identificação de Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE. p. 4377-4384. 2015

ANTUNES, A. F. B. Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial. 147 f. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.

ASPRS. Guide to Land Imaging Satellites.W. E. Stoney. Noblic INC. Disponível em: <u>http://www.asprs.org/a/news/satellites/ASPRS_DATABASE_021208.pdf</u>. Acessado em 25 de janeiro de 2016. 2008

AZEVEDO, F.M, BRASIL, L.M. OLIVEIRA, R.C.L. Redes neurais com aplicações em controle em sistema especialista. Visual books. Florianópolis. 401 p. 2000.

BAATZ, M.; SCHÄPE, A. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. Journal of Photogrammetry and Remote Sensing, Heidelberg, v. 58, n. 3-4, p. 12-23, 2000.

BARROS, R. S. de Avaliação da Altimetria de Modelos Digitais de Elevação Obtidos a Partir de Sensores Orbitais. Tese de Doutorado. Universidade Federal do Rio de Janeiro. 172p. 2006.

BAZAN, W. S., TOMMASELLI, A.M.G, GALO, M. TELLES,S.S.. Extração de feições retas com precisão subpixel: estudo comparativo entre três métodos. Boletim de Ciências Geodesicas. Curitiba. PR: Universidade Federal do Paraná. v. 14, n. 1, p. 128-148, 2008.

BIDEGAIN, P. Plano das Bacias Hidrograficas da Regiao dos Lagos e do rio São Joao. Paulo Luiz Firmino Martins Pereira - Rio de Janeiro: Consórcio Intermunicipal para Gestão das Bacias Hidrográficas da Região dos Lagos, Rio São João e Zona Costeira – CILSJ 153 p.2005

BLASCHKE, T. Object based image analysis for remote sensing ISPRS Journal of Photogrammetry and Remote Sensing, 65 pp. 2–16.2010

BORSOTTI, M.; CAMPADELLI, P.; SCHETTINI, R. Quantitative evaluation of color image segmentation results. Pattern Recognition Letters, v.19, n.8, p.741-747, 1998.

BRAZ, N. G. S., MIURA, A.K. Utilização de Morfologia Matemática para Extração de Malha Viária em Imagens Orbitais, Anais do Congresso Brasileiro de Cartografia. Gramado. Rio Grande do Grande do Sul. 2014.

CÂMARA, G.; SOUZA, R.; FREITAS, U.; GARRIDO, J. SPRING: Integrating Remote Sensing and GIS with Object-Oriented Data Modelling. Computers and Graphics, v. 15, n.6, p. 13-22, 1996.

CAMPBELI, J. B., WYNNE, R. H. Introduction to Remote Sensing. 5th edition. Guildford press. New York.2011.

CARIGNAM, M., DUMOULIN, G., Topographic Mapping at the 1:100,000 Scale in Quebec: Two Techniques; One Product. Proceedings of the Symposium on Geospatial Theory, Processing and Applications, Ottawa, Canada, pp. 1-5 2002.

CEOS. The Earth Observation Handbook. Special Edition for Rio+20 Updated for 2014. Disponível em <u>http://www.eohandbook.com/</u>. Acessado em 31 de janeiro de 2014.

CONCAR. Especificações Técnicas Para Estruturação de Dados Geoespaciais Digitais Vetoriais Versão 2.0. Sistema Cartográfico Nacional. Norma Cartográfica Brasileira. Brasília-DF. 2007.

CONCAR. Plano de Ação para Implantação da Infraestrutura de Dados Espaciais. Comitê de Planejamento da Infraestrutura de Dados Espaciais. Brasília-DF. 2010. CONGALTON, R. G., GREEN, K. Assessing the accuracy of remotely sensed data: Principles and practices.New York: Lewis Publishers, 137p. 2009.

CORREIA, A. H. Metodologias e Resultados Preliminares do Projeto Radiografia da Amazônia. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.8083. 2011.

CORREIA, J. D., CRUZ, C. B. M., MENEZES, P. M., MARINI, S., BARROS, R. Contribuição das Imagens CBERS na Atualização do Mapeamento Sistemático Brasileiro Na Escala 1:100.000. XII Simpósio Brasileiro de Sensoriamento Remoto. Goiânia. Instituto Nacional de Pesquisas Espaciais. P. 873-880. 2005.

CPRM - Serviço Geológico do Brasil. Programa de Levantamentos Geológicos Básicos do Brasil. Geologia do Estado do Rio de Janeiro. Orgs. Silva, L.C. & Cunha, H.C.S. Brasília, 2001.

CRÓSTA, A. P. Processamento digital de imagens de sensoriamento remoto. São Paulo, 173P. 4^a reimpressão. Instituto de Geociências, Universidade de Campinas. 2002.

CRUZ, C. B. M., MENEZES, P. M. A Cartografia no Ordenamento Territorial do Espaço Geográfico Brasileiro. In: Flávio Gomes de Almeida; Luiz Antônio Alves Soares. (Org.). Ordenamento Territorial. 1^a Edição. Editora Bertrand. Rio de Janeiro. P. 194-225. 2009.

CRUZ, C.B.M., ROSÁRIO, L. S., ABREU, M. B., ALMEIDA, P. M. M., VICENS, R.S., CRONEMBERGUER, F.M. Classificação Orientada a Objetos na Geração do Mapa de Uso e Cobertura da Terra do estado do Rio de Janeiro. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 7789-7796. 2009.

CRUZ, C. M.; BARROS. R. S., Contribution of New Sensors to Cartography. *In*: Cartography – A Tool fos Spatial Analysis. Edited by Bateira, C. 312 páginas. Publicado por *InTech*, em 17/08/2012. <u>Earth and Planetary Sciences</u>. Disponível em: http://www.intechopen.com/books/cartography-a-tool-for-spatial-analysis/contribution-of-new-sensors-to-cartography-2.2012.

CUNHA, S. B. Impactos Das Obras De Engenharia Na Dinâmica do Canal e Planície de Inundação do Rio São João - RJ - Brasil. In: V Simpósio Luso Brasileiro de Hidráulica e Recursos Hídricos- IX Simpósio Brasileiro de Recursos Hídricos, 1995. Anais do V Simpósio Luso Brasileiro de Hidráulica e Recursos Hídricos -IX Simpósio Brasileiro de Recursos Hídricos. Vol. 4, p.110-12

D' ALGE, Júlio César. Atualização Cartográfica por Imagens de Satélite. Instituto Nacional de Pesquisas Espaciais.São José dos Campos. SP.1997.

DAL POZ, A.P. MARTINS, E.F.O. Métodos baseados em otimização para o delineamento semiautomático de rodovia. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE. P. 785-792. 2015.

DEFINITIENS. The Principles of Definiens Cognition Network Technology. Disponível em: http://earth.definiens.com/learn/technology. 2010.

DRAEGER, A. Interpretability of High Altitude Multispectral Imagery for the Evaluation of Wildland Resources. Annual Progress Report. 30 de setembro de 1967.

DRÅGUŢ, L., TIEDE, D., LEVICK, S. ESP: a tool to estimate scale parameter formultiresolution image segmentation of remotely sensed data', International Journal of Geographical Information Science. 2010. DSG. Mapeamento dos Processos Cartográficos Referentes aos Produtos Gerados pela Diretoria de Serviço Geográfico. Revista do Serviço Geográfico. Ano II. nº 2. Maio de 2010. ISSN 2177-2002. Brasília. DF. 2010.

DSG. Norma da Especificação Técnica para a Aquisição de Dados Geoespaciais Vetoriais de Defesa da Força Terrestre. Diretoria de Serviço Geográfico. 2^a edição. Versão 1.1. Brasília. DF. 2016.

DUDA, R. O., HART, P. E, STORK, D. G. Pattern Classification. New York: John Wiley & Sons. 2001.

ESPINDOLA, G. M. Ajuste de parâmetros em algoritmos de segmentação de imagens por crescimento de regiões. Dissertação de Mestrado.INPE. São José dos Campos. 2006.

FIGUEIREDO, G.C. & VIEIRA, C.A.O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: Anais Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, INPE, p. 5755-5762. 2007.

FISCHER, R, PERKINS, S, WALKER, A, WOLFART, E. Sobel Edge Detection. Disponível em: http://homepages.inf.ed.ac.uk/rbf/HIPR2/sobel.htm>. Acesso em: 27 maio 2014. 2003.

FLOREZANO, T. G. Iniciação em Sensoriamento Remoto. Oficina de Textos. São Paulo. 2007.

FONSECA, L. M. G. Processamento digital de imagens. Instituto Nacional de Pesquisas Espaciais. 105p.2000.

FOODY, G. M. On the compensation for chance agreement in image classification accuracy assessment. Photogrammetric Engineering and Remote Sensing, 58, 1459 – 1460. 1992.

GALO, M. e CAMARGO, P. de O. Utilização do GPS no controle de qualidade de cartas. In Anais do 1º Congresso Brasileiro de Cadastro Técnico Multifinalitário. COBRAC. Vol. II, Florianópolis - SC, Brasil, pp. 41-48. 1994.

GEOSCIENCE AUSTRALIA. Topographic Data And Map Specifications For Topo250k & Topo100k National Topographic Databases & Ntms Series 1:250 000 & 1:100 000. Scale Topographic Map Products Version:5. Department of Resources, Energy and Tourism. 2007.

GLITTONE, R. Quickbird and IKONOS Images Interpretability. Evaluation Results. National Imagery and Mapping Agency. 2010.

GONZALES, R. C.; WOODS, R. E. Digital image processing. New York: Addison-Wesley Publishing Company, Inc, 1987

GOMES, J.M. VELHO, L.C.P.R. Computação Gráfica: Imagem. Série de Computação Gráfica e Matemática. Segunda Edição. São Paulo.421 p. 2002

GREER, J.D. and CAYLOR, Y. Development of an Environmental Image Interpretability Rating Scale. SPIE Vol. 1763 Airborne Reconnaissance XVL p. 151-157. 1992.

GUERRA, A.J.T. Encostas e a Questão Ambiental. *In*: CUNHA, S. B.& GUERRA, A.J.T. (Organizadores). A Questão Ambiental. Diferentes Abordagens. 4ª Edição. Bertrand Brasil. P. 191-218. 2008.

HOLANDA, A. F. Novo dicionário Aurélio da língua portuguesa . Positivo, 2004.

HOTHEM, D., IRVINE, J.M. MOHR, E.;. BUCKLEY, K.B, Quantifying Image Interpretabifity For Civil Users. Proceedings of the American Society of Photogrammetry and Remote Sensing Annual Meetings. April 1996.

HOUAISS, A. Dicionário eletrônico Houaiss da língua portuguesa. Versão 1.0. Objetiva, 2001.

IBGE. Programa Especial de Dinamização da Cartografia Terrestre. Departamento de Cartografia. Diretoria de Geociências.116 p. 1978.

IBGE. Avaliação Planialtimétrica de Dados ALOS/PRISM. Estudo de Caso: Itaguaí-RJ. Coordenação de Cartografia. Diretoria de Geociências. Disponível em http://www.ibge.gov.br/alos/RelatoriodeAvaliacaoAlos.pdf. Acesso em: 31 de janeiro de 2016. 2009.

IBGE. Manual de Procedimentos Técnicos para Fiscalização,Controle de Qualidade e Validação da Base Cartográfica Contínua na Escala 1:250 000. Manual Técnico de Geociências. № 12. Coordenação de Cartografia. Diretoria de Geociências. 2011a.

IBGE. Avaliação Planimétrica de Imagens Alos/Avnir-2. Estudo de caso: Uberlândia-MG. Relatório 2009/2010. Coordenação de Cartografia. Diretoria de Geociências. 2011b.

IGN. Curso IDE. Infraestrutura de Datos Espaciales. Grupo de Investigación Mercator. Laboratorio de Tecnologías de la Información Geográfica. Instituto Ggeográfico Nacional da Espanha. 2011.

INEGI. Productos y Servicios: Cartas Topgráficas. Instituto Nacional de Estadística e Geografía. Divisíon de Geografía. México. Disponível em: <u>http://www.inegi.org.mx/geo/contenidos/topografia/default.aspx</u>. Acessado em 31 de janeiro de 2016.

INPE. Monitoramento da Cobertura Florestal da Amazônia por Satélites . São José dos Campos- SP: Ministério da Ciência e Tecnologia, Instituto Nacional de Pesquisas Espaciais. 179 p. Disponível em: <u>http://www.obt.inpe.br/deter/RelatorioMonitoramento .pdf</u> Acessado em 25 de janeiro de 2014. 2008

INSPIRE. INSPIRE Data Quality and Metadata. Workshop: "From Requirements to Metadata". Spatial Data Infrastructures Unit. European Commision. 2010.

IRARS. Multispectral Imagery Interpretability Rating Scale Reference Guide. Image Resolution Assessment and Reporting Standards Committee (IRARS). United States. 1999.

IRVINE, J. National Imagery Interpretability Ratings Scales: Overview and Product Description. Prceedings of the American Society of Photogrammetry and Remote Sensing Annual Meetings. 1997.

ISO 19115. Geographic Information - Metadata. Primeira Edição. Suíça. Cópia licenciada para uso da CONCAR. Interbook Ltda., pedido nº 135145. 2003.

ISO 19113. Geographic Information – Quality Principes. Primeira Edição. Suíça. Cópia licenciada para uso da CONCAR. Interbook Ltda., pedido nº 135145. 2003.

JENSEN, J. R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Tradução da 2 ed. por (pesquisadores do INPE): José Carlos N. Epiphanio (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 2009.

KIM, Y. KIM, D. KIM, S. Image-Based Estimation And Validation Of Niirs For High-Resolution Satellite Images. Method for Assessing Spectral Image Utility. XXII Congress of the International Society for Photogrammetry and Remote Sensing. Melbourne. 2012.

LEACHTENAUER, J.C. and SALVAGGIO, N.L. NIIRS Prediction: Use of the Briggs Target. Proceedings of the American Society of Photogranunetry and Remote Sensing Annual Meetings. 1996.

LILLESAND, T.M.; KIEFER, R.W. Remote sensing and image interpretation. New York: John Wiley & Sons, 1994

MA, Z., REDMOND, R.L. Tau coefficients for accuracy assessment of classification of remote sensing data. Photogrammetric Engineering and Remote Sensing, Bethesda, 61(4), 453 - 439. 1995

MACHADO E SILVA, A., SILVA, M., SANTINI, D., Mapeamento Topográfico usando imagens IKONOS. Anais do XI Simpósio Brasileiro de Sensoriamento Remoto, 5-10 abril de 2003. p. 297-302. Belo Horizonte. Org. Instituto Nacional de Pesquisas Espaciais. 2003.

MANGABEIRA, J., LAMPARELLI, R. A., AZEVEDO, E. Utilização de Imagem IKONOS-II para Identificação de Uso da Terra em Área com Alta Estrutura Fundiária. Anais do XI Simpósio Brasileiro de Sensorioamento Remoto, 5-10 abril de 2003. p. 165-167. Belo Horizonte. Org. Instituto Nacional de Pesquisas Espaciais. 2003.

MANTA, V. Utilização De Imagens de Satélite no Contexto Municipal actualização da cartografia 1:10 000. Deteção Remota como um instrumento de gestão e apoio à decisão. Ordem dos Engenheiros de Portugal. 2012.

MAYER, L.M., ERDMAN, C.D; RIEHI, K. (1995), Imagery Interpretability Ratings Scales, Presented to the Society for Information Display, May 1995.

MEINEL, G.; NEUBERT, M. A Comparision of segmentation programs for high resolution remote sensing data. Int. Arch. of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXV-B4, pp. 1097- 1102. 2004.

MENEZES, P.M.L. FERNANDES, M.C. Roteiro de Cartografia. São Paulo. Oficina de Textos. 288p. 2013. MERCHANT, D. C.; Spatial Accuracy Standards for Large Scale Line Maps. Technical Papers of the American Congress on Surveying and Mapping (1), 222-231. 1982.

MONICO, J. F.G., DAL PÓZ, A. P., GALO, M., SANTOS, M. C., OLIVEIRA, L.C. Acurácia e Precisão: Revendo os Conceitos de Forma Acurada. Boletim Ciências Geodésicas. Sec. Comunicações. Curitiba. V.15, nº 3, p. 469-483. julset. 2009.

MOREIRA, M.A.; RUDORFF, B.F.T. Sensoriamento remoto aplicado à agricultura. São José dos Campos. INPE, 2002.

MOZAS, A. T.; ARIZA, F. J New method for positional quality control in cartography based on lines. A comparative study of methodologies. International Journal of Geographical Information Science, v. 25, n. 10, p. 1681-1695, 2011.

NASA. Landsat Data Continuity Mission: Continuously Observing Your World.
2013. Disponível em: <<u>http://ldcm.gsfc.nasa.gov/mission_details.html</u>>.
Acessado em 19 de julho de 2013.

NOVO, E. Sensoriamento Remoto: Princípios e Aplicações. Ed. Blucher. 4ª Ed revista. 2010.

OGC. The OpenGIS Abstract Specification. Topic 7: The Earth Imagery Case. Version 5. Geographic information . Reference Model . Imagery. ISO TS 19101. 2004.

PAIXÃO, S.; NICHOLS, S; COLEMAN, D. Towards a spatial data infrastructure: brazilian iniciatives. Infraestrutura de dados espaciais: iniciativas brasileiras. Revista Brasileira de Cartografia, Rio de Janeiro, n. 60, ago. 2008.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. Avaliação de técnicas de fusão aplicadas à imagem Quickbird. Anais do XIII Simpósio Brasileiro de

Sensoriamento Remoto, 16-21 de abril de 2005, Goiânia, Brasil. INPE, p. 4225-4232. 2005.

REIS, R. B., CARDOSO, P. V., CRUZ, C B. M., VICENS, R. S. Classificação do Uso e Cobertura do Solo da APA do São João em uma abordagem orientada a objeto. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 7087-7094. 2009.

RICHARDS, J. JIA, X. Remote Sensing Digital Image Analysis. Na Introduction. Springer. 4^a Edition. Germany. 454 p. 2006.

RODRÍGUEZ, A. F. ISO 19104. Terminología y Armonización de términos. Curso de IDE. Infraestructuras de Datos Espaciales. Instituto Geográfico Nacional da Espanha. 2011.

SANTIAGO, V.S., SILVA, E.A. NOGUEIRA, J.R. Utilização de Equações Diferenciais Parciais para detecção de rodovias em imagens de alta resolução. Anais XV Simpósio Brasileiro de Sensoriamento Remoto, Curitiba, Brasil, 30 de abril-5 maio 2011, INPE, p. 7875-7879. 2011.

SANTOS, A.P. Controle de Qualidade Cartográfica: Metodologias para avaliação da Acurácia Posicional em Dados Espaciais. Tese de Doutorado em Engenharia Civil. Universidade Federal de Viçosa. Minas Gerais. 172 p. 2015

SANTOS, S. M., SOUZA, W.V. Introdução à Estatística Espacial para a Saúde Pública. In: Introdução à Estatística Espacial para a Saúde Pública. Capacitação e atualização em geoprocessamento em saúde. Fundação Fiocruz. Ministério da Saúde. Brasília. 2007.

SCHOWENGERDT, R. A. Spectral Transforms in: Remote Sensing: Models and Methods for Image Processing. London: Academic Press, 1997. 522p.

SCOTT, J. R. Remote sensing: The Image Chain Approach. New York: Oxford University Press, 1997.

SEABRA, V.S. Análise da paisagem em apoio aos estudos de favorabilidade à recuperação florestal na bacia hidrográfica do rio São João. Tese de Doutorado em Geografia. UFRJ. 206 p. 2012.

SILVEIRA, G., SASSAKI, A., NEVES, C., ISHIKAWA, M. Escala Máxima de Uso do Produto IKONOS. Estudo de Caso para Araçoiaba da Serra. Anais do XII Simpósio Brasileiro de Sensorioamento Remoto, p. 2589-2596. Goiânia. Org. Instituto Nacional de Pesquisas Espaciais. 2005.

SOH, L.-K.; TSATSOULIS, C. Segmentation of satellite imagery of natural scenes using data mining. IEEE Transactions on Geoscience and Remote Sensing, v. 37, n. 2, p. 1086, 1999.

SOILE, Morphological Image Analysis: Principles and Applications. Springer-Verlag. Berlim Heidelberg. 316 p. 1999.

SOUZA, A. F. Esqueletos isotrópicos. Dissertação. Mestrado em Computação Aplicada. INPE, São José dos Campos. Disponível em: http://mtc-m05.sid.inpe.br/col/dpi.inpe.br/lise/2003/01.16.09.47/doc/. Acesso em: 10 de janeiro de 2015. 2002.

SOUZA, U. D. V. Classificação da cobertura e do uso do solo urbano de São Luís (MA), com imagens worldview-2 utilizando mineração de dados e sistema interimage. Dissertação (Mestrado em Sensoriamento Remoto)- São José dos Campos : INPE, 2012.

STEFANOU, M.; KEREKES, J. A method for assessing spectral image utility. Transactions On Geoscience And Remote Sensing, Vol. 47, N^o. 6, Junho 2009.

TEDESCO, A., ANTUNES, A.F.B. Integração de OBIA, árvores de decisão e classificação hierárquica para mapeamento de voçorocas. Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto. 2015. João Pessoa. p. 4527-4534. 2015.

TILTON, J.; LAWRENCE, W. Interactive analysis of hierarchical image segmentation. In: International Geoscience and Remote Sensing Symposium IGARSS-2000, New York. Proceedings. IEEE Pres. p. 733-735. 2000.

USGS. A Land Use And Land Cover Classification System For Use With Remote Sensor Data. Geological Survey Professional Paper 964. Redigido por James R. Anderson, Ernest E. Hardy, John T. Roach, And Richard E. Witmer. 2001.

VERGARA, O., CINTRA, J., D`ALGE, J. Avaliação da Exatidão Cartográfica de Documentos Atualizados com Imagens Orbitais e Sistemas de Informação Geográfica. Comissão Técnica V: Sensoriamento Remoto e Interpretação de Imagens. Departamento de Engenharia Cartográfica. Instituto Militar De Engenharia. 2007.

VIEIRA, C.A., MATHER, P.M. e APLIN, P. Assessing the positional and thematic accuracy of remotely sensed data In: Proceedings XXth Congress of the International Society for Photogrammetry and Remote Sensing: Geoimagery Bridging Continents, Istanbul, Turkey, pp. 979-984.2004.

VIEIRA, H. B. G.; GENRO, R.S. Inferência estatística para validação de documentos cartográficos obtidos com sensores remotos orbitais ou aerotransportados, em áreas de operação da Petrobras. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.2339. 2011.

VIEIRA, H. B. G.; GENRO, R. S. Estimativa da acurácia posicional de documentos cartográficos na Petrobras a partir do erro máximo provável inferido do erro médio quadrático e da respectiva variância propagada. Foz do Iguaçu: Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto. 2013.

XU, Y., OLMAN, V., & UBERBACHER, E. C. A segmentation algorithm for noisy images: Design and evaluation. Pattern Recognition Letters, 19(13), 1213-1224. 1998.