



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2014/01.10.18.00-TDI

CORREÇÃO RADIOMÉTRICA DO EFEITO DE ILUMINAÇÃO SOLAR INDUZIDO PELA TOPOGRAFIA

Eder Paulo Moreira

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Marcio de Morisson Valeriano, aprovada em 13 de fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3FHCR62>>

INPE
São José dos Campos
2014

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):**Presidente:**

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2014/01.10.18.00-TDI

CORREÇÃO RADIOMÉTRICA DO EFEITO DE ILUMINAÇÃO SOLAR INDUZIDO PELA TOPOGRAFIA

Eder Paulo Moreira

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Marcio de Morisson Valeriano, aprovada em 13 de fevereiro de 2014.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3FHCR62>>

INPE
São José dos Campos
2014

Dados Internacionais de Catalogação na Publicação (CIP)

Moreira, Eder Paulo.

M813c Correção radiométrica do efeito de iluminação solar induzido pela topografia / Eder Paulo Moreira. – São José dos Campos : INPE, 2014.

xxiv + 86 p. ; (sid.inpe.br/mtc-m19/2014/01.10.18.00-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

Orientador : Dr. Marcio de Morisson Valeriano .

1. correção topográfica. 2. efeito topográfico. 3. SRTM. 4. Landsat. 5. classificação de imagens. I.Título.

CDU 528.852

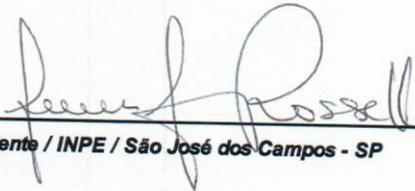


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

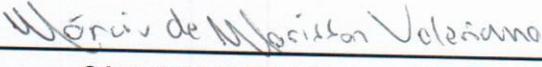
Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Mestre** em
Sensoriamento Remoto

Dra. Dilce de Fátima Rossetti



Presidente / INPE / São José dos Campos - SP

Dr. Marcio de Morisson Valeriano



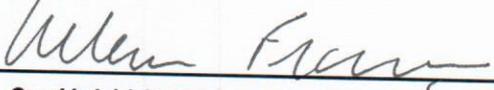
Orientador(a) / INPE / SJC Campos - SP

Dr. Camilo Daleles Rennó



Membro da Banca / INPE / SJC Campos - SP

Dra. Helena França



Convidado(a) / UFABC / Santo André - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

Aluno (a): **Eder Paulo Moreira**

São José dos Campos, 13 de Fevereiro de 2014

“Onde está o caminho para onde se difunde a luz e se espalha o vento oriental sobre a terra?”. (Bíblia, Jó 38: 24).

A minha mãe,
MARIA CATARINA MOREIRA SILVA.

AGRADECIMENTOS

Agradeço ao meu orientador, Dr. Márcio de Morisson Valeriano, pela confiança, orientação e experiências compartilhadas durante o preparo e condução deste estudo, que me permitiram uma aprendizagem agradável e construtiva.

Aos participantes da Banca Examinadora, Dr. Camilo Daleles Rennó (DPI/INPE), Dra. Dilce de Fátima Rossetti (DSR/INPE) e Dra. Helena França (UFABC), pelas sábias críticas e sugestões, que foram importantes para a melhoria deste trabalho e para meu aprendizado.

Ao Dr. Andrew T. Hudak (RMRS/USDA) e ao Dr. João Luiz Lani (UFV), por todos os conhecimentos transmitidos, incentivos e amizade, que começaram antes de minha admissão no INPE.

Agradeço ao Dr. Flávio Jorge Ponzoni e ao Dr. Camilo Daleles Rennó, pelo empenho na coordenação do curso (PG-SER) e por todos os esclarecimentos prestados a mim quando foram necessários.

Ao André, à Malu, à Simone e à Yolanda da Biblioteca do INPE, pelas valiosas ajudas. À Vera e Valéria da secretaria do curso, pela atenção e presteza.

Ao Dr. João Marcos Caixeta Franco (UNIFAL-MG), pela ajuda na identificação, por imagens de satélites, de algumas culturas agrícolas da região de Alfenas, Minas Gerais.

Ao INPE, por me acolher como estudante de pós-graduação, especialmente ao corpo docente pelos ensinamentos transmitidos.

Aos colegas estudantes da PG-SER, com os quais tive o prazer de conviver nas salas de aulas, nos estudos em grupo e nos momentos de descontração durante o curso.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro.

À Sra. Deanna Huffman, ao Carlos Antônio Jr., à Mayumi Hirye e à Viviane Muñoz, pelas sinceras e sábias contribuições para o aperfeiçoamento deste trabalho e pela amizade.

Aos membros da Igreja Cristã Maranata, pelo ambiente espiritual confortável, pelas orações e amizades.

Agradeço à Laísa Conde, pelo companheirismo a toda hora e aos seus familiares pelo imenso apoio.

À minha família, em especial à minha mãe Maria Catariana, à tia Janice e à avó Hilda Moreira (*In Memoriam*), pelo amor e apoio recebidos em todos os momentos.

Sobretudo sou grato ao Onipotente Deus, pelo dom da vida, pela direção e por colocar em minha vida pessoas especiais que sempre foram amigas, pacientes e prontas a me ajudarem.

RESUMO

Este estudo tem como objetivo caracterizar o efeito de variação radiométrica causado pela topografia em imagens óticas de satélite e avaliar a importância de sua correção, principalmente no que se refere à classificação do uso e cobertura da terra. A área de estudo compreende uma região agrícola de relevo suave ondulado a ondulado localizada no sul do estado de Minas Gerais, Brasil. Utilizaram-se as seis bandas Landsat TM da região do espectro solar refletido e dados topográficos derivados da *Shuttle Radar Topography Mission* (SRTM). Foram aplicados e avaliados nove métodos de correção topográfica que utilizam como base o cosseno do ângulo de incidência solar na superfície, que é função da declividade, da orientação de vertentes e dos parâmetros relativos à geometria de iluminação solar no momento de aquisição da imagem. A classificação da cobertura da terra foi conduzida utilizando análise de imagens baseada em objetos (OBIA) e criação de árvore de decisão por mineração de dados. A avaliação dos métodos de correção considerou a análise das características espectrais expressas pela variância e média dos níveis radiométricos de classes de cobertura, a relação entre níveis radiométricos e geometria de iluminação solar controlada pelo relevo, as características dos objetos (segmentos), a estrutura da árvore de decisão, a mineração de dados e os valores obtidos a partir da matriz de confusão gerada para avaliação da classificação. Os resultados indicaram que o efeito topográfico e sua correção afetaram consistentemente a variância dos níveis radiométricos, a estrutura da árvore de decisão e a exatidão da classificação. De acordo com os resultados da mineração de dados, as bandas com correção topográfica foram mais adequadas para a classificação do que as sem correção. Os resultados concordam que o efeito topográfico restringe a capacidade das imagens óticas de satélites em fornecer informações detalhadas e confiáveis da cobertura da terra de áreas com relevo irregular e que alguns métodos são eficientes para sua correção. Concluiu-se que a correção topográfica realizada neste estudo aumentou a capacidade de distinção de classes de cobertura da terra na área de estudo pela classificação de imagens.

RADIOMETRIC CORRECTION OF THE ILLUMINATION EFFECT INDUCED BY TOPOGRAPHY

ABSTRACT

This study aims to characterize the effect of radiometric variations due to topography on optical satellite images and to evaluate the importance of topographic corrections for land cover classification. The study area comprises an agricultural region of undulating terrain type located in the southern of the State of Minas Gerais, Brazil. We used the six Landsat TM bands of the reflected solar spectrum region and topographic data derived from Shuttle Radar Topography Mission (SRTM). Nine methods of topographic correction were applied and evaluated, which are based on the cosine of solar incidence angle on the surface, which is a function of slope, aspect and parameters related to solar illumination geometry at the time of satellite overpass. Land cover classification was accomplished using object-based image analysis (OBIA) and decision tree induction by data mining. The evaluation of the correction methods considered the analysis of spectral characteristics expressed by the mean and variance of radiometric values of land cover classes, the correlation between radiometric values and cosine of solar incident angle on the slope, object (segment) characteristics, decision tree structure, data mining and the error matrix generated to evaluate the land cover classification. Results indicate that the topographic effect and its correction consistently affected the variance of the radiometric values, decision tree structure and classification accuracy. According to the results of data mining, the corrected bands were more suitable for classification than uncorrected bands. The results agree that the topographic effect restricts the capability of optical satellite imagery to provide detailed and reliable information of the land cover from rugged terrain and that some methods are efficient for its correction. It was concluded that the topographic correction implemented in this study improved the capability to distinguish land cover classes in the study area through image classification.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Ilustração esquemática da variação da irradiância solar (fluxo por área) no campo de visada instantâneo do sensor (<i>Instantaneous Field Of View</i> , IFOV) em relação ao ângulo de incidência solar na superfície (i).....	4
Figura 2.2 - Relação entre ângulos que compõem a geometria Sol, superfície e sensor. Onde, i: ângulo de incidência solar; θ_s : ângulo zenital solar; θ_t : ângulo zenital da normal da superfície (Declividade), φ_s : ângulo azimutal solar; φ_t : ângulo azimutal da normal da superfície (Orientação de vertentes).....	5
Figura 2.3 - Banda 3 (a), 4 (b) e 5 (c) do Landsat 8 <i>Operational Land Imager</i> (OLI) e orientação de vertentes (d) de uma região agrícola do município de Alfenas, Minas Gerais. Data de aquisição: 13 de junho de 2013; ângulo azimutal solar (φ_s): 34,6°; ângulo zenital solar (θ_s): 53,3°	6
Figura 2.4 - Banda PAN Landsat 7 ETM+ (a) e fator cosseno (b) de uma região da Serra do Mar, em Ubatuba, São Paulo. Data de imageamento: 3 de junho de 2003; ângulo azimutal solar (φ_s): 37,06°; ângulo zenital solar: 55,14°	7
Figura 2.5 - Ilustração esquemática da variação do sombreamento interno causado pela vegetação em interação com o relevo. Na vertente voltada para o Sol, menos sombreamento interno é visado pelo sensor em relação à vertente voltada contra o Sol. 8	
Figura 2.6 - Ilustração esquemática do efeito da correção topográfica sobre a relação entre refletância e fator cosseno.	9
Figura 2.7 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetro estimado de maneira generalizada em relação às classes de cobertura.....	17
Figura 2.8 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetros estimados de maneira específica em relação às classes de cobertura.....	18
Figura 2.9 - Ilustração esquemática das classes espectrais (classes de NDVI) e das amostras da estratégia de correção com parâmetros estimados de maneira estratificada.....	19
Figura 2.10 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetros estimados com base na cobertura principal.....	19
Figura 2.11 - Ilustração esquemática de uma árvore de decisão	24
Figura 3.1 - Fluxograma das principais atividades desenvolvidas nesse estudo.....	31

Figura 3.2 - Fluxograma das principais atividades de avaliação e análise do estudo.....	32
Figura 3.3 - Localização da área de estudo, no sul de Minas Gerais, Brasil. a) Imagem Landsat 5 TM composição 453 (RGB) com as identificações das classes de uso e cobertura. b) MDE-Topodata	33
Figura 3.4 - a) Diagrama de roseta da orientação de vertentes e histogramas da b) declividade e do c) fator cosseno ($\cos i$) da área de estudo	34
Figura 3.5 - Distribuição das amostras de controle para a) estimar os parâmetros de correção e avaliar a correção, b) treinar o classificador e c) avaliar a classificação.	37
Figura 4.1 - Dados da área de estudo: a) Declividade; b) Orientação de vertentes; c) Fator cosseno e; d) Imagem Landsat 5 TM composição 453 (RGB). Parâmetros de imageamento para cálculo do fator cosseno: ângulo zenital solar = $54,32^\circ$ e; ângulo azimutal solar = $37,01^\circ$	44
Figura 4.2 - Distribuição da área de estudo em função da geometria de iluminação solar (fator cosseno e ângulo de incidência solar), declividade e orientação de vertentes. Parâmetros da cena para cálculo do fator cosseno: ângulo zenital solar = $54,32^\circ$ e; ângulo azimutal solar = $37,01^\circ$	45
Figura 4.3 - Distribuição das amostras (pontos cinza escuro) utilizadas para estimar os parâmetros de correção (somente as classes de cobertura de milho e floresta) e para avaliar a correção (todas as classes) em relação à declividade, orientação de vertentes e fator cosseno (isolinhas). Os pontos em cinza claro representam os <i>pixels</i> da área total	46
Figura 4.4 - Transecto da elevação, declividade, orientação de vertente, fator cosseno ($\cos i$) e banda 5 antes e após correção pelos métodos de correção topográfica estudados. Foram utilizadas as áreas de milho como fonte para estimativa dos parâmetros de correção	51
Figura 4.5 - Estratificação da exatidão da classificação por condições de iluminação: a) Condições de iluminação representadas no histograma do fator cosseno; b) Distribuição das amostras de controle e da área de estudo por condições de iluminação e; c) Exatidão da classificação (estratificada pelas condições de iluminação) da imagem sem correção e das corrigidas pelos diferentes métodos de correção utilizando as áreas de milho e floresta como fonte para estimativa dos parâmetros de correção.	53
Figura 4.6 - Frequência com que o desvio padrão obtido de células adjacentes de 3x3 <i>pixels</i> mostrou-se menor, igual ou superior comparando a banda 4 corrigida pelos métodos estudados com ela não corrigida. Para as correções, utilizaram-se as áreas de milho como fonte para estimativa dos parâmetros de correção.....	54
Figura 4.7 - Imagem Landsat 5 TM, composição 453 (RGB), sem (A) e com (B) correção topográfica.	56

Figura 4.8 - Bandas 3, 4 e 5 sem correção (SC), com correção (CC) e razão entre SC e CC.....	57
Figura 4.9 - Histogramas, médias (MD) e desvios padrões (DP) das bandas espectrais antes e após correção topográfica.....	58
Figura 4.10 - Primeira componente principal (PCA1), gerada antes e após correção topográfica das bandas espectrais.....	60
Figura 4.11 - Diagramas de dispersão entre primeira componente principal (PCA1), gerada antes e após correção topográfica das bandas espectrais, e fator cosseno ($\cos i$). *** O valor-p do teste F da análise de regressão é menor que 0,01.....	61
Figura 4.12 - Classificação do uso e cobertura da terra da imagem sem correção e da com correção, e suas respectivas áreas em porcentagem	62
Figura 4.13 - Distribuição e quantificação das áreas onde a classificação da imagem sem correção é diferente da classificação da imagem com correção.....	63
Figura 4.14 - Representação da área em detalhe para apontar diferenças na classificação sem correção e na com correção topográfica: a) Imagem sem correção; b) Imagem corrigida; c) Classificação da imagem sem correção e; d) Classificação da imagem com correção	64
Figura 4.15 - Árvores de decisão da classificação: a) da imagem sem correção; e b) da imagem com correção.....	66
Figura 4.16 - Árvore de decisão da classificação cuja segmentação foi realizada com as bandas sem correção topográfica e a mineração de dados com atributos de todas as bandas, sem e com correção. Todos os atributos selecionados pela mineração presentes na árvore são das bandas corrigidas	67
Figura 4.17 - Tamanho médio dos segmentos por classe de cobertura resultantes das classificações da imagem sem correção e da com correção topográfica.....	69

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Alguns exemplos de métodos de correção topográfica semiempíricos.....	14
Tabela 2.2 - Bandas espectrais do sensor TM e suas faixas no espectro eletromagnético	27
Tabela 3.1 - Métodos aplicados e avaliados nesse estudo.....	35
Tabela 3.2 - Atributos dos segmentos gerados com todas as bandas não termais Landsat 5 TM para classificação do uso e cobertura da terra	38
Tabela 4.1 - Média (μ), desvio padrão (σ) e parâmetros da regressão (bandas vs. fator cosseno) de amostras das bandas Landsat 5 TM, antes e após correção topográfica pelos métodos estudados.....	48
Tabela 4.2 - Resultados das classificações da imagem sem correção e corrigida pelos diferentes métodos estudados usando as classes de milho e floresta como fonte para estimativa dos parâmetros de correção	52
Tabela 4.3 - Média, desvio padrão e parâmetros de regressão (bandas vs. fator cosseno) de amostras das bandas Landsat 5 TM sem e com correção topográfica	59
Tabela 4.4 - Matriz de confusão que relaciona a área total (em porcentagem) da classificação da imagem sem correção com a da classificação da imagem com correção	63
Tabela 4.5 - Matrizes de confusão da classificação da imagem sem correção, classificação da imagem com correção e da classificação cuja segmentação foi realizada com as bandas sem correção topográfica e a mineração de dados com atributos de todas as bandas sem e com correção (classificação mista)	68
Tabela 4.6 - Diferença entre Kappa das classificações com e sem correção topográfica obtida pelo método de Monte Carlo	69

LISTA DE SIGLAS E ABREVIATURAS

ADD	Aspect-Drainage-Divides
AdS2	Correção de dois estádios adaptada (2ºestádio)
ASI	Italian Space Agency
ASTER	Advanced Spaceborne Thermal Emission and Reflection
CC	Com correção
CV	Coefficiente de Variação
DLR	German Aerospace Center
dNBR	differenced Normalized Burn Ratio
E-Stat	Estatística-empírica
ETM+	Enhanced Thematic Mapper Plus
FDRB	Função de Distribuição de Refletância Bidirecional
FT	Formas do Terreno
GDEM	Global Digital Elevation Map
GEOBIA	Geographic Object Image Analysis
GLCM	Gray Level Co-occurrence Matrix
IFOV	Instantaneous Field Of View
INPE	Instituto Nacional de Pesquisas Espaciais
MaxVer	Máxima Verossimilhança
MDE	Modelos Digitais de Elevação
MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NC	Nível de cinza
NDVI	Normalized Difference Vegetation Index
OBIA	Análise de Imagem Baseada em Objetos
OLI	Operational Land Imager
PCA	Principal component analysis
PCA1	Primeira componente
PEC	Padrão de Exatidão Cartográfica
REM	Radiação Eletromagnética
RGB	Red-Green-Blue

S1	Correção de dois estádios (1° estádio)
S2	Correção de dois estádios (2° estádio)
SAR	Synthetic aperture radar
SC	Sem correção
SCS	Sun-Canopy-Sensor
SID	Serviço de Informação e Documentação
SIG	Sistemas de Informação Geográfica
SPG	Serviço de Pós-Graduação
SRTM	Shuttle Radar Topography Mission
TDI	Teses e Dissertações Internas
TM	Thematic Mapper
USDA	United States Department of Agriculture
USGS	United States Geological Survey
WGS	World Geodetic System

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2. FUNDAMENTAÇÃO TEÓRICA.....	3
2.1 Efeito topográfico.....	3
2.1.1 Características radiométricas	3
2.1.2 Efeito sobre a classificação do uso e cobertura da terra	9
2.2 Correção topográfica	10
2.2.1 Métodos de correção.....	10
2.2.2 Metodologias de aplicação.....	16
2.2.3 Avaliação da correção topográfica	20
2.3 Classificação do uso e cobertura da terra.....	20
2.3.1 Análise de Imagem Baseada em Objetos.....	21
2.3.2 Árvore de decisão	22
2.3.3 Avaliação da classificação	25
2.4 Dados.....	27
2.4.1 Imagens Landsat	27
2.4.2 Dados SRTM	28
3. MATERIAL E MÉTODOS	31
3.1 Visão geral	31
3.2 Material	32
3.2.1 Área de estudo	32
3.2.2 Dados e recursos para processamento	34
3.3 Metodologia	35
3.3.1 Correção topográfica.....	35
3.3.2 Levantamento de dados de referência.....	36
3.3.3 Classificação baseada em objetos	38
3.3.4 Avaliação e análises.....	39
4. RESULTADOS E DISCUSSÃO	43
4.1. Caracterização dos dados em relação ao fator cosseno.....	43
4.2. Avaliação dos métodos de correção topográfica.....	47
4.3. Efeito da correção	55
4.3.1 Análise das bandas espectrais.....	55

4.3.2 Análise da classificação do uso e cobertura da terra	61
4.4 Considerações gerais	70
5 CONCLUSÕES.....	73
REFERÊNCIAS BIBLIOGRÁFICAS	75

1 INTRODUÇÃO

Em diversas circunstâncias, a capacidade de imagens óticas de satélite em fornecer informações confiáveis e detalhadas é restringida por efeitos radiométricos causados pela atmosfera e topografia (TEILLET, 1986). O efeito topográfico é evidente em imagens óticas de áreas de relevo irregular, causado pela variação da iluminação solar em função da declividade e orientação da superfície em combinação com o ângulo zenital e azimutal solar (HOLBEN; JUSTICE, 1980). Esse efeito se caracteriza por acrescentar uma variabilidade radiométrica nos dados de determinada classe de cobertura da terra que não corresponde à sua característica espectral intrínseca (CIVCO, 1989; HORN, 1981). A desconsideração do efeito topográfico pode ocasionar erros no processamento automático de imagens, como de classificação da cobertura da terra, com consequente redução da qualidade das informações geradas.

Métodos de correção do efeito topográfico que utilizam como base o ângulo de incidência solar na superfície foram propostos em diversos estudos (CIVCO, 1989; SANDMEIER; ITTEN, 1997; SMITH et al., 1980; TEILLET et al., 1982; WEN et al., 2009). Alguns autores mostram resultados proeminentes da correção topográfica (HANTSON; CHUVIECO, 2011; SHEPHERD; DYMOND, 2003; VERAVERBEKE et al., 2010), inclusive com impactos positivos sobre a classificação automática do uso e cobertura da terra (CUO et al., 2008; MEYER et al., 1993). No entanto, a aplicação da correção topográfica não tem sido amplamente adotada e existem poucos trabalhos que contemplem a aplicação e avaliação de vários métodos de correção de maneira sistematizada (VANONCKELEN et al., 2013).

Supõe-se que a escassez de dados topográficos e as dificuldades para seu processamento possam explicar esta lacuna em décadas passadas. Porém, avanços relativamente recentes na produção e análise de Modelos Digitais de Elevação (MDE) propiciam um contexto oportuno para a aplicação da correção topográfica (LI et al., 2005). Entre estes avanços, ressaltam-se os MDE da missão SRTM e do sensor ASTER no começo da década de 2000 (ERSDAC, 2009; RABUS, 2003; VALERIANO; ROSSETTI, 2012). No mesmo período foram também notáveis os avanços nos recursos de processamento e análise de MDE, tais como a ampliação das funções oferecidas por Sistemas de

Informação Geográfica (SIG), assim como o advento de programas computacionais dedicados a estes dados (HENGL; REUTER, 2008).

Nesse contexto, o objetivo geral desse trabalho é estudar o efeito topográfico em imagens de satélites do espectro solar refletido. Os principais objetivos específicos são:

- a) Desenvolver metodologia de aplicação e avaliação de métodos de correção topográfica;
- b) Avaliar diferentes métodos de correção topográfica;
- c) Analisar a relação entre ângulo de incidência solar na superfície e dados radiométricos das bandas espectrais, antes e após correção topográfica;
- d) Analisar o efeito topográfico e sua correção utilizando estatísticas descritivas dos dados radiométricos;
- e) Analisar o impacto do efeito topográfico e de sua correção sobre a classificação do uso e cobertura da terra.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, são fundamentados os elementos necessários à compreensão deste estudo: efeito topográfico, classificação de imagens e tipos de dados utilizados na metodologia deste estudo. Maior ênfase será dada ao efeito topográfico, por ser esse o foco do estudo.

2.1 Efeito topográfico

2.1.1 Características radiométricas

Sensores imageadores a bordo de satélite adquirem imagens por meio de medições da radiação eletromagnética (REM) emitida ou refletida pelos alvos da superfície terrestre. Os sensores passivos têm o Sol como fonte de REM, que é emitida por ele em direção à superfície terrestre. A radiância solar refletida pela superfície é medida pelo sensor varia em função da irradiância solar total da superfície, de propriedades de absorção e espalhamento atmosférico e pela função de distribuição de refletância bidirecional (FDRB) da superfície (HOLBEN; JUSTICE, 1981; KIMES, 1983; KRIEGLER et al., 1969).

A irradiância solar total em uma superfície pode ser dividida em irradiância direta e indireta. Em condições de céu sem cobertura de nuvens, a irradiação total é dominada por sua componente direta (DUBAYAH; RICH, 1995). A irradiância direta varia em função do ângulo de incidência solar em relação a normal da superfície (veja também Figura 2.1):

$$\begin{aligned} E_d &= E_d^h \cos i, \text{ quando } \cos i \geq 0, \\ E_d &= 0, \text{ quando } \cos i < 0 \text{ (Sombra)} \end{aligned} \tag{2.1}$$

Onde, E_d é a irradiância solar direta em uma superfície inclinada, E_d^h é a irradiância solar direta numa superfície horizontal e perpendicular a direção do fluxo solar.

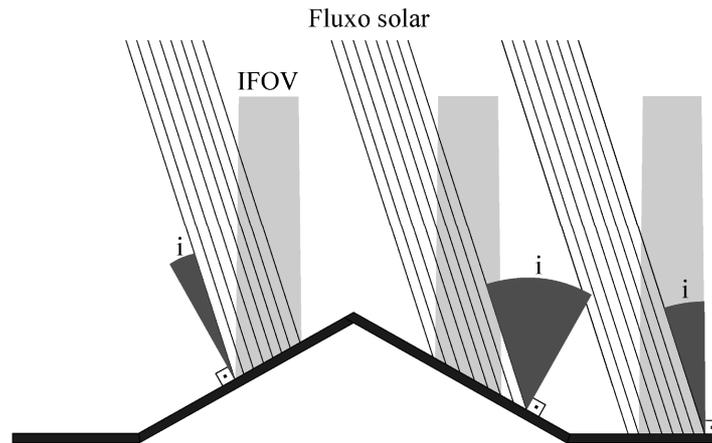


Figura 2.1 - Ilustração esquemática da variação da irradiância solar (fluxo por área) no campo de visada instantâneo do sensor (*Instantaneous Field Of View*, IFOV) em relação ao ângulo de incidência solar na superfície (i).

O $\cos i$, ou fator cosseno, pode ser calculado pela seguinte equação (SELLERS, 1965):

$$\cos i = \cos \theta_s \cos \theta_t + \sin \theta_s \sin \theta_t \cos(\varphi_s - \varphi_t) \quad (2.2)$$

Onde, θ_s é o ângulo zenital solar, θ_t é o ângulo zenital da normal da superfície (Declividade), φ_s é o ângulo azimutal solar, e φ_t é o ângulo azimutal da normal da superfície (Orientação de vertentes). Considerando uma aquisição de imagem de satélite, os parâmetros θ_s e φ_s geralmente são disponíveis nos metadados da imagem ou podem ser calculados em função do local, horário e data de aquisição. Os ângulos relativos ao terreno, θ_t e φ_t , são obtidos por meio de derivações a partir de MDE (VALERIANO, 2011).

Os ângulos que compõem a geometria entre Sol, superfície e sensor são apresentados na Figura 2.2.

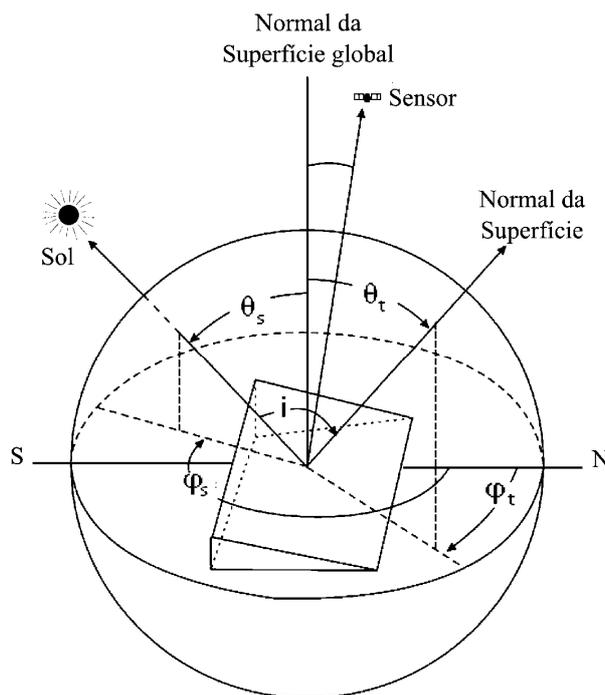


Figura 2.2 - Relação entre ângulos que compõem a geometria Sol, superfície e sensor. Onde, i : ângulo de incidência solar; θ_s : ângulo zenital solar; θ_t : ângulo zenital da normal da superfície (Declividade), φ_s : ângulo azimutal solar; φ_t : ângulo azimutal da normal da superfície (Orientação de vertentes).

Fonte: Adaptado de Smith et al. (1980).

A irradiância indireta pode ser dividida em duas componentes: irradiância difusa e irradiância refletida por superfícies adjacentes. A irradiância difusa é a irradiância solar que foi espalhada pela atmosfera e varia em função da geometria entre Sol e superfície, e das propriedades de espalhamento e de absorção atmosférica. Além disso, outros fatores devem ser considerados como a exposição local à abóboda celeste (*sky view factor*). Já a irradiância refletida por superfícies adjacentes depende da irradiância total das superfícies adjacentes, da área delas (ou *terrain view factor*), de suas refletâncias e distâncias em relação ao alvo (DUBAYAH et al., 1990).

Considera-se nesse estudo que o ângulo de visada (referente a cada pixel da cena) de sensores de resolução espacial alta ou média (e.g., Landsat-TM), apresenta variação podendo ser desprezível, com efeitos igualmente negligenciáveis sobre os dados radiométricos. No entanto, o efeito radiométrico causado pela variação do ângulo de

visada deve ser considerado em sensores com maior ângulo de visada total, como o *Moderate Resolution Imaging Spectroradiometer* (MODIS) (APARICIO et al., 2004; BREUNIG et al., 2012; GALVÃO et al., 2009).

Numa cena de relevo plano não há variações do fator cosseno, pois a declividade e orientação de vertentes são constantes no espaço. Nesta condição, a variação da radiância em função da topografia do terreno é nula. Já em regiões de relevo irregular, a topografia tem participação na variação da radiância medida pelo sensor. Normalmente, as vertentes do terreno que estão voltadas para o Sol, no momento do imageamento, recebem maior irradiação solar quando comparadas àquelas voltadas para a direção contrária. Conseqüentemente, o brilho (ou radiância) é diferente nessas duas condições, ainda que elas possuam um mesmo tipo de uso ou cobertura da terra. É este efeito que permite a percepção visual do relevo em cada banca espectral da imagem (Figura 2.3).

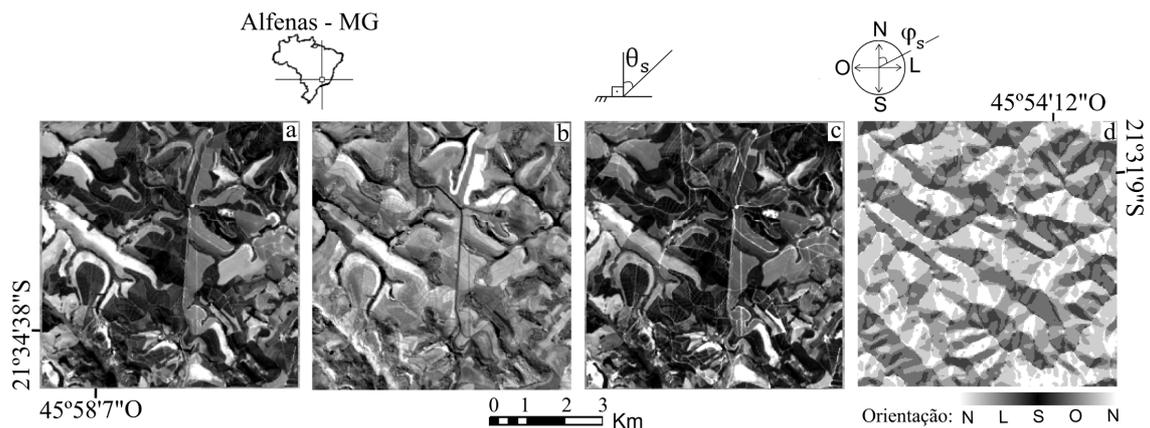


Figura 2.3 - Banda 3 (a), 4 (b) e 5 (c) do Landsat 8 Operational Land Imager (OLI) e orientação de vertentes (d) de uma região agrícola do município de Alfenas, Minas Gerais. Data de aquisição: 13 de junho de 2013; ângulo azimutal solar (φ_s): 34,6°; ângulo zenital solar (θ_s): 53,3°.

Fonte: Bandas espectrais cedidas pelo USGS e orientação de vertentes obtida no Topodata.

O efeito topográfico é mais evidente ao comparar o brilho (nível de cinza) de determinada banda espectral de relevo montanhoso e o fator cosseno calculado para o momento de sua aquisição. Apesar de se observarem nuances de brilho na banda

espectral devido às propriedades espectrais da cobertura, é notável a similaridade entre níveis de cinza (NC) e o fator cosseno (Figura 2.4).

A topografia pode atuar de maneira menos direta na variação da radiância medida pelo sensor remoto. Em áreas cobertas por vegetação arbórea, a arquitetura do dossel em interação com o relevo faz com que tenha variação da área de sombreamento interno visada pelo sensor. Em uma situação em que o sensor está posicionado a nadir, as áreas voltadas para a posição do Sol apresentam menos sombreamento interno causado pela projeção de copas em copas e de folhas em folhas. O inverso ocorre nas áreas voltadas para a direção contrária à do Sol (Figura 2.5). Uma descrição mais detalhada dessa interação é encontrada em Li e Strahler (1992); Gu e Gillespie (1998).

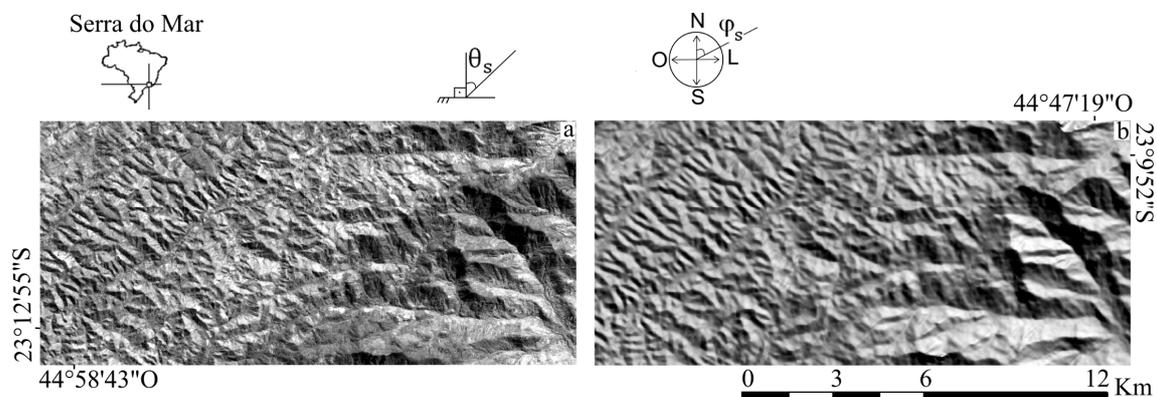


Figura 2.4 - Banda PAN Landsat 7 ETM+ (a) e fator cosseno (b) de uma região da Serra do Mar, em Ubatuba, São Paulo. Data de imageamento: 3 de junho de 2003; ângulo azimutal solar (φ_s): 37,06°; ângulo zenital solar (θ_s): 55,14°.

Fonte: Banda PAN: Catálogo de imagens do INPE; Declividade e Orientação de vertentes para cálculo do fator cosseno: Topodata.

Vários estudos mostram que níveis radiométricos e variáveis topográficas têm correlação entre si (EKSTRAND, 1996, GU; GILLESPIE, 1998; HOLBEN; JUSTICE, 1980). Em Reese e Olsson (2011), os coeficientes de determinação (r^2) de regressões lineares entre níveis radiométricos de bandas Landsat TM e fator cosseno apresentam valores de 0,38, 0,64, 0,55, 0,49, 0,79 e 0,58 para as bandas 1, 2, 3, 4, 5 e 7, respectivamente. Em Gao e Zhang (2009a), estes coeficientes foram 0,49, 0,64, 0,43, 0,65, 0,69 e 0,54 para os níveis radiométricos das bandas 1, 2, 3, 4, 5 e 7 do sensor

Landsat ETM+, respectivamente. Esses coeficientes indicam certa dependência dos dados radiométricos em relação à geometria de iluminação solar (fator cosseno).

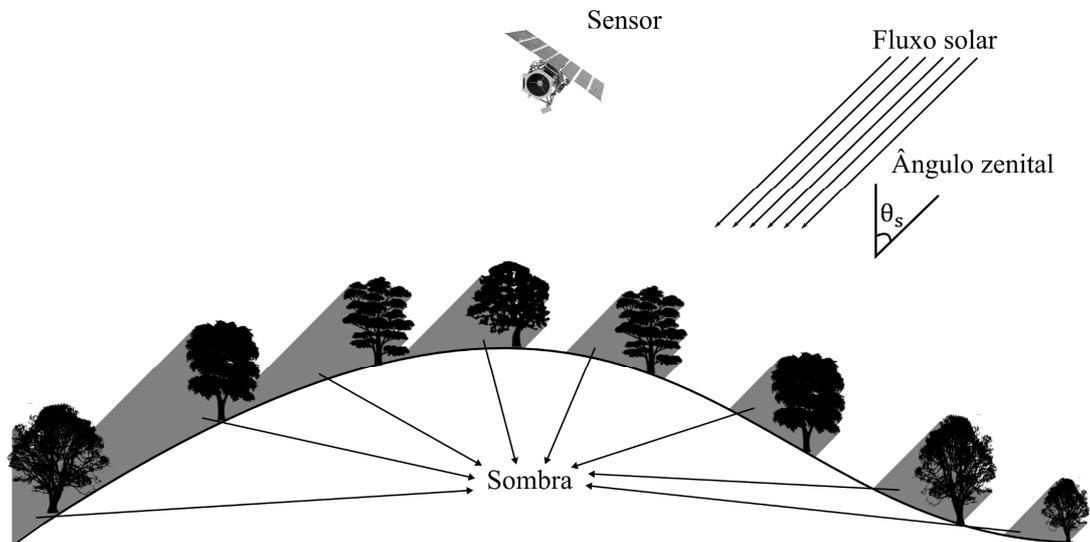


Figura 2.5 - Ilustração esquemática da variação do sombreamento interno causado pela vegetação em interação com o relevo. Na vertente voltada para o Sol, menos sombreamento interno é visado pelo sensor em relação à vertente voltada contra o Sol.

Vários trabalhos analisaram o efeito topográfico sob a perspectiva de sua correção. Alguns autores constaram que a correção topográfica reduziu a variância dos dados radiométricos de determinadas classes de coberturas, sem haver perda de suas propriedades espectrais (CIVCO, 1989; HANTSON; CHUVIECO, 2011; RIAÑO et al., 2003; SHEPHERD; DYMOND, 2003). Isso demonstra que o efeito topográfico insere variação nos dados radiométricos, a qual é reduzida com a correção. Outros relataram que a correção topográfica diminuiu a correlação entre dados radiométricos e fator cosseno (EKSTRAND, 1996; KOBAYASHI; SANGA-NGOIE, 2009; MCDONALD et al., 2000; MEYER et al., 1993). O efeito da correção sobre o diagrama de dispersão entre refletância e fator cosseno é esquematizado na Figura 2.6. Porém, os resultados variam de um método para outro, sendo que alguns não produzem resultados satisfatórios (TEILLET et al., 1982). Detalhes sobre os métodos de correção serão abordados na seção 2.2.

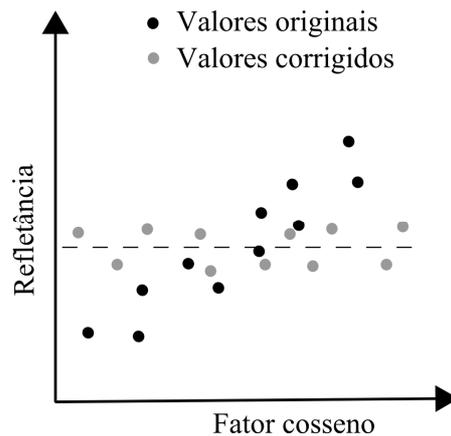


Figura 2.6 - Ilustração esquemática do efeito da correção topográfica sobre a relação entre refletância e fator cosseno.

Fonte: Adaptado de Tan et al. (2013).

2.1.2 Efeito sobre a classificação do uso e cobertura da terra

As classificações do uso e cobertura da terra realizadas de maneira automática normalmente se baseiam nos níveis radiométricos de imagens de satélites. Em áreas de terreno irregular, o efeito topográfico pode afetar a classificação; um mesmo tipo de uso ou cobertura em diferentes posições na paisagem pode apresentar níveis radiométricos diferentes na imagem. Por outro lado, áreas com diferentes tipos de uso ou cobertura podem apresentar níveis radiométricos similares devido ao efeito topográfico (CIVCO, 1989; HOLBEN; JUSTICE, 1980; NICODEMUS et al., 1977; PROY et al., 1989).

McDonald et al. (2000) constataram que a correção topográfica aumentou a distinção entre classes que se mostraram espectralmente semelhantes nos dados originais. Comparando curvas espectrais antes e após correção topográfica, Vanonckelen et al. (2013) observaram que a sobreposição espectral entre diferentes tipos de usos e coberturas da terra diminuíram após correção. Wen et al. (2009) notaram, com a correção topográfica, uma diminuição na discrepância de curvas espectrais de uma mesma classe de cobertura em diferentes condições de iluminação solar.

Vários estudos analisaram o impacto do efeito topográfico na classificação do uso e cobertura da terra por meio de sua correção. Na maioria dos estudos, a correção tem um

impacto positivo nos resultados da classificação. Vanonckelen et al. (2013) resumiram vários estudos que avaliam o impacto da correção sobre a classificação.

Ao analisar o impacto da correção sobre a exatidão total ou sobre o índice de concordância Kappa da classificação, vários autores constataram seu aumento após correção topográfica (CONESE et al., 1993; CUO et al., 2010; HUANG et al., 2008; MEYER et al., 1993), enquanto que outros não verificaram melhorias nos seus valores após correção (BLESUSA; WEIRICHAB, 2005; ZHANG et al., 2011).

As implicações do efeito topográfico sobre a classificação podem ser minimizadas, por exemplo, aumentando-se o número de classes espectrais com o objetivo de considerar determinada classe de cobertura em diferentes condições de iluminação (por exemplo, plantio de café bem iluminado e café mal iluminado). Esta é uma prática comum para reduzir o problema, apesar da eficácia ser variável e não ter garantias de sucesso. Nas situações em que há uma completa sobreposição espectral entre diferentes classes de uso ou cobertura causada pelo efeito topográfico, os erros são incontornáveis por essa alternativa.

2.2 Correção topográfica

Os métodos de correção topográfica foram divididos nesse estudo em quatro categorias. Nessa seção será feita uma abordagem sobre alguns métodos representativos de cada categoria. Também serão descritas as metodologias de aplicação e avaliação dos métodos de correção topográfica.

2.2.1 Métodos de correção

A primeira categoria de métodos de correção topográfica é baseada em razão de bandas. Em geral, utiliza-se a razão simples entre duas bandas espectrais de uma imagem. A razão de bandas nesse aspecto tem o objetivo de anular a variação espacial da radiação causada pela topografia, que seria proporcionalmente constante entre bandas espectrais (HOLBEN; JUSTICE, 1981).

Holben e Justice (1981) concluíram que a razão de bandas não elimina completamente o efeito topográfico. A explicação proposta pelos autores para explicar parte dessa

ineficiência é a dependência das propriedades de retroespalhamento da superfície em relação ao comprimento de onda de cada banda espectral.

Colby (1991) comparou a correção Minnaert (SMITH et al., 1980) com a razão de bandas TM 5 e 4. O autor utilizou análise de variância relacionando três áreas amostrais com a mesma classe de cobertura, mas em diferentes condições de iluminação solar. O mesmo procedimento foi aplicado para relacionar áreas amostrais com classes de coberturas diferentes. A razão de banda foi propícia para reduzir, em relação às bandas originais, as diferenças radiométricas entre áreas amostrais com a mesma classe de cobertura, assim como foi propícia para gerar maior distinção entre as áreas amostrais com diferentes classes de coberturas. Nesse aspecto, a razão de bandas apresentou melhores resultados que as bandas originais, por minimizar o efeito topográfico nos dados. No entanto, o estudo demonstrou que a correção Minnaert foi mais eficiente que a razão de bandas em ambas as análises para reduzir o efeito topográfico.

Ekstrand (1996) relata que várias razões de bandas Landsat TM, incluindo o *Normalized Difference Vegetation Index* (NDVI), foram eficientes para reduzir a correlação entre fator cosseno e dados radiométricos. Porém, esse autor cita que o uso de razão de bandas produz resultados inferiores comparados ao uso de uma única banda espectral em certas aplicações, como para avaliar sintomas de desfolha na área de estudo.

As demais categorias de correção topográfica dependem de variáveis topográficas em escalas compatíveis com os dados espectrais. Dentro dessas categorias, a que se caracteriza por sua maior simplicidade é representado pela correção do Cosseno, de Teillet et al. (1982):

$$\delta NC_{\lambda ij} = NC_{\lambda ij} \left(\frac{\cos \theta_s}{\cos i} \right) \quad (2.3)$$

Onde, $NC_{\lambda ij}$ é o NC do pixel ij da banda espectral λ , $\delta NC_{\lambda ij}$ é o NC corrigido.

Outro exemplo pertencente a essa categoria é a correção SCS, *Sun-Canopy-Sensor*, de Gu e Gillespie (1998), onde os níveis de cinza da imagem são corrigidos pela seguinte equação:

$$\delta NC_{\lambda ij} = NC_{\lambda ij} \left(\frac{\cos \theta_t \cos \theta_s}{\cos i} \right) \quad (2.4)$$

A correção SCS é mais apropriada para áreas de cobertura arbórea, onde particularmente mostra-se mais eficiente que a correção do cosseno. Isso se dá devido à correção SCS modelar o efeito da arquitetura do dossel em interação com o relevo (seção 2.11) (GU; GILLESPIE, 1998).

Geralmente, esses dois métodos citados acima causam uma correção exagerada nas áreas de menor e maior iluminação. O principal motivo da ineficácia desses métodos advém da desconsideração da radiação indireta. As regiões menos iluminadas, ao terem os níveis radiométricos (ou nível de cinza) multiplicados pelo fator de correção (maior que 0, nas áreas menos iluminadas), passam a ter valores superestimados por conterem uma contribuição desconsiderada da iluminação indireta. O inverso ocorre nas áreas mais iluminadas, passando a ter valores subestimados ao serem multiplicadas pelo fator de correção (menor que 0) (TEILLET et al., 1982; VINCINI; FRAZZI, 2003).

A terceira categoria de métodos de correção consiste em métodos empíricos ou semiempíricos, que utilizam parâmetros empíricos com o objetivo de considerar a iluminação indireta e/ou para considerar o comportamento não-lambertiano dos alvos (SMITH et al., 1980; TEILLET et al., 1982). Diferentemente da categoria descrita anteriormente, esta tem parâmetros que dependem dos dados radiométricos em cada comprimento de onda (ou em cada banda espectral).

Um dos métodos mais conhecidos é a correção C:

$$\delta NC_{\lambda ij} = NC_{\lambda ij} \left(\frac{\cos \theta_s + c_\lambda}{\cos i + c_\lambda} \right) \quad (2.5)$$

$$c_\lambda = \left(\frac{b_\lambda}{m_\lambda} \right) \quad (2.6)$$

Onde b_λ e m_λ são os coeficientes obtidos da reta da regressão linear representada pela equação:

$$NC_{\lambda ij} = b_{\lambda} + m_{\lambda} \cos i \quad (2.7)$$

Portanto, c_{λ} é uma constante calculada para cada banda separadamente.

Um outro método semiempírico bastante implementado é o conhecido como correção Minnaert, que foi proposto por Smith et al. (1980) baseado no trabalho do astrofísico Minnaert (1941):

$$\delta NC_{\lambda ij} = NC_{\lambda ij} \cos \theta_t \left(\frac{\cos \theta_s}{\cos i \cos \theta_t} \right)^{k_{\lambda}} \quad (2.8)$$

Onde, k_{λ} é conhecido como constante de Minnaert, ou constante k. Ela varia de 0 a 1 e mede o quanto uma superfície é Lambertiana. Quando k_{λ} é igual a 1, a Equação 2.8 se torna igual a Equação 2.3, e a superfície é considerada Lambertiana. A constante k é a inclinação da reta da regressão linear ($y = k_{\lambda}x + b$) obtida pela linearização da Equação 2.8, dada por:

$$\log(NC_{\lambda ij} \cos \theta_t) = \log \delta NC_{\lambda ij} + k_{\lambda} \log(\cos i \cos \theta_t / \cos \theta_s) \quad (2.9)$$

Onde,

$$y = \log(NC_{\lambda ij} \cos \theta_t) \quad (2.10)$$

$$x = \log(\cos i \cos \theta_t / \cos \theta_s) \quad (2.11)$$

$$b = \log \delta NC_{\lambda ij} \quad (2.12)$$

Outros métodos de correção da categoria de métodos semiempíricos que são avaliados em outra fase desse estudo são apresentados na Tabela 2.1.

Tabela 2.1 - Alguns exemplos de métodos de correção topográfica semiempíricos

Método	Equação	Nº	Referência
Correção de dois estádios (1º estágio)	$\delta NC_{\lambda ij} = NC_{\lambda ij} + NC_{\lambda ij} \left(\frac{\mu_k - X_{ij}}{\mu_k} \right)$	(2.13)	Civco (1989)
Correção de dois estádios (2º estágio)	$\delta NC_{\lambda ij} = NC_{\lambda ij} + NC_{\lambda ij} \left(\frac{\mu_k - X_{ij}}{\mu_k} \right) C_\lambda$	(2.14)	Civco (1989)
Onde,	$C_\lambda = \frac{\left[\frac{\mu_\lambda - N_\lambda}{(\mu_\lambda - N_\lambda) - (\mu_\lambda - N'_\lambda)} + \frac{\mu_\lambda - S_\lambda}{(\mu_\lambda - S_\lambda) - (\mu_\lambda - S'_\lambda)} \right]}{2}$	(2.15)	
Correção de dois estádios adaptada (1º estágio)	$\delta NC_{\lambda ij} = NC_{\lambda ij} + (NC_{\lambda \max} - NC_{\lambda \min}) \left(\frac{\mu_w - X_{ij}}{\mu_w} \right)$	(2.16)	Nichol et al. (2006)
Correção de dois estádios adaptada (2º estágio)	$\delta NC_{\lambda ij} = NC_{\lambda ij} + (NC_{\lambda \max} - NC_{\lambda \min}) \left(\frac{\mu_w - X_{ij}}{\mu_w} \right) C_\lambda$	(2.17)	Nichol et al. (2006)
Onde,	$C_\lambda = \frac{S'_\lambda - N_\lambda}{N'_\lambda - N_\lambda}$	(2.18)	
Estatística-empírica	$\delta NC_{\lambda ij} = NC_{\lambda ij} \cos i m_\lambda - b_\lambda + NC_{\lambda \mu}$	(2.19)	Teillet et al. (1982)
SCS+C	$\delta NC_{\lambda ij} = NC_{\lambda ij} \left(\frac{\cos \theta_t \cos \theta_s + c_\lambda}{\cos i + c_\lambda} \right)$	(2.20)	Soenen et al. (2005)

Onde, μ_k é a média do fator cosseno escalonado (o fator cosseno que varia de -1 to +1 foi escalonado para o intervalo de 0 a 255) da classe de cobertura principal (modificado em relação a Civco (1989), onde esse termo é baseado em todas as classes de cobertura); X_{ij} é o fator cosseno escalonado do *pixel* ij ; μ_λ é o NC médio da classe de cobertura principal; N_λ é o NC médio da cobertura principal em vertentes voltadas para a posição contrária ao Sol (vertentes mal iluminadas); N'_λ é o NC médio da cobertura principal em vertentes mal iluminadas depois do primeiro estágio de correção; S_λ é o NC médio da cobertura principal em vertentes voltadas para a posição do Sol (vertentes bem iluminadas); S'_λ é o NC médio da cobertura principal em vertentes bem iluminadas depois do primeiro estágio de correção; $NC_{\lambda \min}$ é o NC mínimo da cobertura principal; $NC_{\lambda \max}$ é o NC máximo da cobertura principal; μ_w é o fator cosseno escalonado da cobertura principal em áreas bem iluminadas; b_λ e m_λ são obtidos da mesma forma em relação a correção C (Equação 2.5).

A quarta categoria de correção topográfica compreende os métodos que utilizam modelo de transferência radiativa, como o 6S (VERMOTE et al., 1997). Para exemplificar essa categoria, utilizam-se como referências nesse estudo os trabalhos de Sandmeier e Klaus (1997); Shepherd e Dymond (2003).

Para modelar a variação da iluminação em uma superfície é necessário modelar a radiação solar em uma superfície inclinada. Alguns parâmetros de superfícies horizontais, como a irradiância total e a irradiância direta, são obtidos do modelo 6S. A irradiância solar total $E(\lambda, z)$ na banda λ para uma superfície inclinada com altitude z é calculada pela equação:

$$\begin{aligned}
 E(\lambda, z) = & \theta E_d^h(\lambda, z) \frac{\cos i}{\cos \theta_s} \\
 & + E_f^h(\lambda, z) \left(k(\lambda, z) \frac{\cos i}{\cos \theta_s} + (1 - k(\lambda, z)) V_d \right) \\
 & + E^h(\lambda, z) V_t \rho_{adj}
 \end{aligned} \tag{2.21}$$

Onde, $E^h(\lambda, z)$ é a irradiância total em uma superfície horizontal, $E_d^h(\lambda, z)$ é a irradiância direta em uma superfície horizontal, $E_f^h(\lambda, z)$ é a irradiação difusa em uma superfície horizontal, $k(\lambda, z)$ é o índice de anisotropia, V_d é o fator de exposição à abóboda celeste (tradução proposta de *sky view factor*), V_t é o fator de obstrução do terreno à abóboda celeste (tradução proposta de *terrain view factor*), ρ_{adj} é a refletância média das superfícies adjacentes, θ é o coeficiente binário igual a um e ajustado para zero em regiões de sombra.

O parâmetro ρ_{adj} pode ser estimado a partir da refletância média da imagem com correção atmosférica (SHEPHERD; DYMOND, 2003). $k(\lambda, z)$ é calculado segundo Hay (1983, citado por Sandmeier e Klaus, 1997), a partir da razão entre irradiação direta de uma superfície perpendicular a direção da iluminação solar $E_d^n(\lambda, z)$ e a radiação no topo da atmosfera $E_d^t(\lambda, z)$, pela equação:

$$k(\lambda, z) = \frac{E_d^n(\lambda, z)}{E_d^t(\lambda, z)} \tag{2.22}$$

V_d e V_t são determinados analiticamente com base na metodologia proposta por Dozier e Marks (1987), obtidos pelas seguintes equações:

$$V_d = \int_0^{2\pi} \int_{h_0}^{\pi/2} \cos \gamma \cos(h[\varphi_s]) dh d\varphi_s \quad (2.23)$$

$$V_t = \int_0^{2\pi} \int_0^{h_0} \cos \gamma \cos(h[\varphi_s]) dh d\varphi_s \quad (2.24)$$

Onde, φ_s é o ângulo azimutal solar, h_0 é o ângulo do horizonte local, h é o ângulo de elevação solar, γ é o ângulo entre a normal da superfície e o vetor de ângulo h . O ângulo do horizonte local h_0 representa a maior declividade entre um ponto específico (ou *pixel*) e qualquer ponto numa dada direção azimutal φ_s .

V_d e V_t também podem ser calculadas por aproximações trigonométricas segundo Kondratyev (1969, citado por Sandmeier e Klaus, 1997).

Finalmente, a irradiância total em uma superfície inclinada $E(\lambda, z)$ calculada para cada *pixel* da cena é utilizada para calcular a refletância (ρ_λ) da superfície, representada pela equação:

$$\rho_\lambda = \frac{\pi (L_\lambda - L_p(\lambda, z))}{E(\lambda, z)T_u(\lambda, z)} \quad (2.25)$$

$$L_\lambda = a_0 + a_1 NC \quad (2.26)$$

Onde, L_λ é a radiação da cena na banda λ (Equação 2.26), a_0 e a_1 é offset e o ganho das bandas do sensor, respectivamente. $L_p(\lambda, z)$ é a radiação de trajetória, $T_u(\lambda, z)$ é a transmitância atmosférica.

2.2.2 Metodologias de aplicação

Os métodos de correção semiempíricos podem ser aplicados diretamente sobre a imagem sem nenhuma transformação ou correção prévia. Alguns autores realizam a correção topográfica sobre os valores de refletância, enquanto outros sobre radiação,

com ou sem correção atmosférica (KOBAYASHI; SANGA-NGOIE, 2009; MEYER et al., 1993; RIAÑO et al., 2003).

Os parâmetros de correção (por exemplo, o c_λ da correção C e o k_λ da correção Minnaert) são estimados com base em amostras das bandas espectrais com a equação de cada método de correção. As amostras podem ser coletadas de diferentes formas em relação às classes de cobertura e ao fator cosseno. Recomenda-se que as amostras sejam representativas das condições de iluminação da cena imageada (REESE; OLSSON, 2011). Esses autores desenvolveram uma metodologia que utiliza técnicas estatísticas para definir o número de amostras e estratificá-las pelo fator cosseno. Eles mostraram que a estratificação das amostras pelo fator cosseno resulta em parâmetros mais precisos em relação a uma amostragem aleatória não estratificada.

Referente às classes de uso e cobertura, alguns autores estimam os parâmetros de correção de maneira generalizada, ou seja, um único parâmetro é estimado considerando todas as classes de uso ou cobertura (RIAÑO et al., 2003; TAN et al., 2013; TEILLET et al., 1982; VANONCKELEN et al., 2013). Assim, várias amostras são selecionadas, independentemente da classe de cobertura, para estimar os parâmetros e aplicar a correção sobre toda a cena (Figura 2.7).

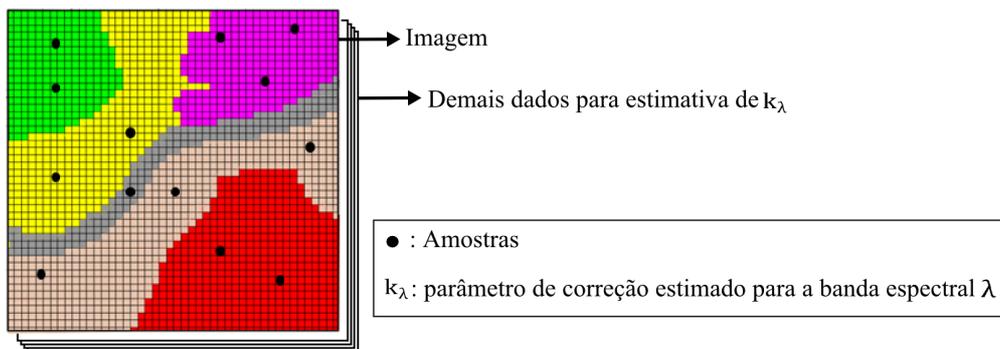


Figura 2.7 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetro estimado de maneira generalizada em relação às classes de cobertura.

Outra estratégia é a estimativa dos parâmetros de correção para cada classe de uso e cobertura da terra (KOBAYASHI; SANGA-NGOIE, 2009; SMITH et al., 1980). Esta

estratégia requer um mapa prévio de cobertura da terra para estimativa dos parâmetros e para aplicação da correção. Dessa maneira, a correção é realizada de maneira específica considerando as classes de cobertura (Figura 2.8).

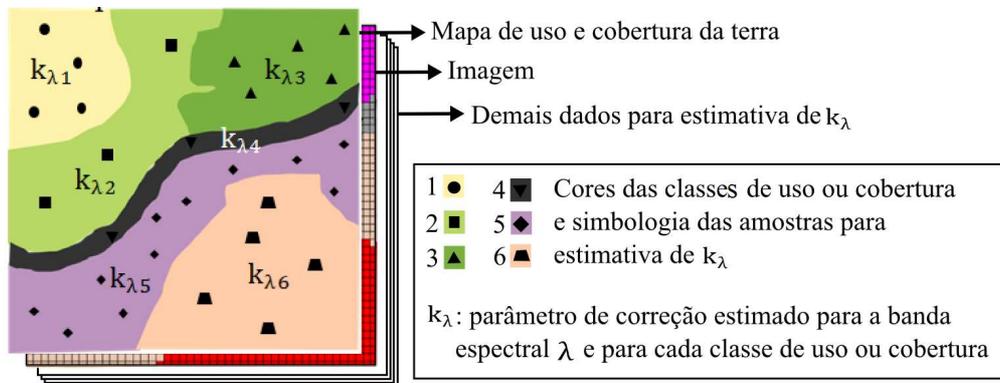


Figura 2.8 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetros estimados de maneira específica em relação às classes de cobertura.

A estimativa dos parâmetros e a aplicação da correção de maneira específica é apontada como mais apropriada e com resultados mais satisfatórios que a estratégia generalizada (BISHOP; COLBY, 2002; KOBAYASHI; SANGA-NGOIE, 2009; MCDONALD et al., 2000). Nesse sentido, os parâmetros mostram-se dependentes em relação à classe de cobertura, sendo mais recomendável a estimativa de um parâmetro de correção para cada classe de cobertura de determinada área.

Para superar a necessidade de um mapa prévio, requerido na estratégia anterior, alguns autores estimaram os parâmetros e aplicaram a correção de maneira estratificada por classes ou grupos espectrais (BISHOP; COLBY, 2002; BISHOP et al., 2003; HANTSON; CHUVIECO, 2011). Essas classes espectrais podem ser definidas, por exemplo, pelo fatiamento do NDVI (Figura 2.9). Essa alternativa demonstra ser mais eficiente que a estratégia generalizada (HANTSON; CHUVIECO, 2011).

Presume-se que a estratégia estratificada pode ter seu desempenho prejudicado pelo fato de se basear na estratificação de dados sem correção topográfica. Por exemplo, Veraverbeke et al. (2010) estudaram o efeito topográfico sobre o índice *differenced*

Normalized Burn Ratio (dNBR), calculado com as bandas Landsat TM pela fórmula $(TM4-TM7)/(TM4+TM7)$. Em seus estudos, estes autores constataram que o dNBR é consideravelmente afetado pelo efeito topográfico, e que a correção topográfica propiciou uma avaliação mais precisa da severidade de queimada.

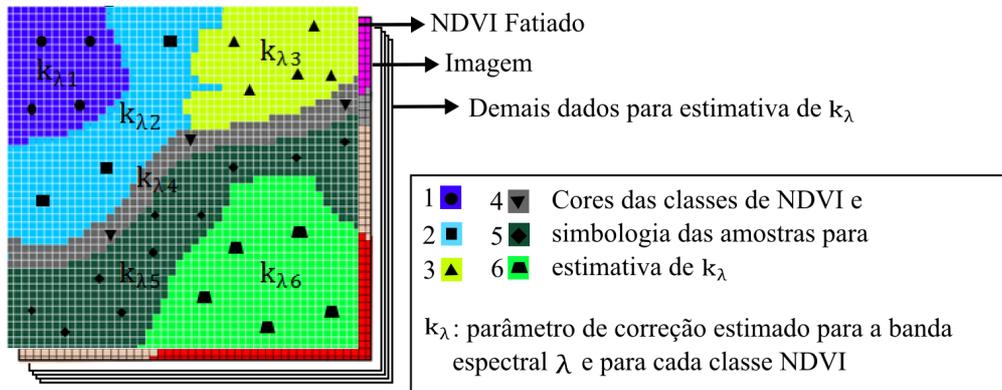


Figura 2.9 - Ilustração esquemática das classes espectrais (classes de NDVI) e das amostras da estratégia de correção com parâmetros estimados de maneira estratificada.

Outra estratégia, intermediária em relação à estratégia generalizada e a específica, é baseada na classe de cobertura principal, como é realizado no método de correção desenvolvido por CIVCO (1989). A classe de cobertura principal pode ser considerada aquela de maior importância para classificação. Nesta abordagem, a classe principal é utilizada como fonte para estimar os parâmetros, e a correção é aplicada sobre toda a cena com os mesmos parâmetros da cobertura principal (Figura 2.10).

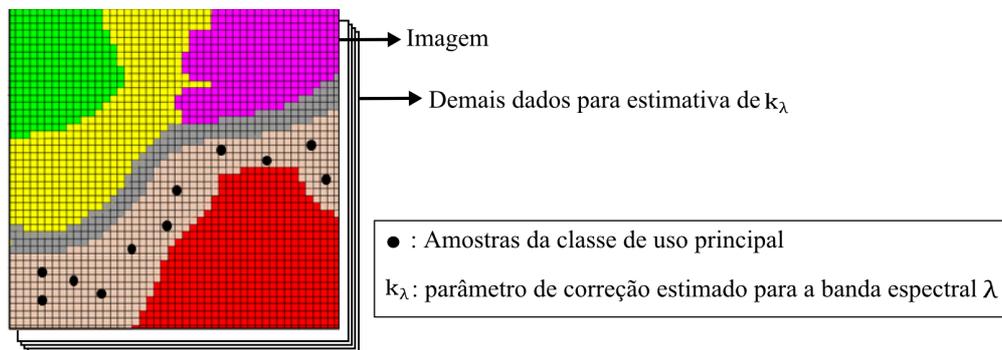


Figura 2.10 - Ilustração esquemática das classes de cobertura e das amostras da estratégia de correção com parâmetros estimados com base na cobertura principal.

Em relação à última estratégia apresentada, o desempenho da correção pode ser variado ao comparar a classe de cobertura principal com as demais. Espera-se maior desempenho para a classe principal. Porém, esta estratégia pode ser útil quando as amostras da classe principal são coletadas por interpretação de imagens ou trabalhos de campo, dispensando a necessidade de um mapa prévio de classes de cobertura. Ela é mais apropriada quando o objetivo da classificação é caracterizar uma única classe de cobertura, como é o foco de vários estudos (HANSEN; LOVELAND, 2012; RUDORFF et al., 2010; VIBRANS et al., 2013).

2.2.3 Avaliação da correção topográfica

Existem várias formas de avaliação da correção topográfica, que incluem principalmente a(o): a) variância ou desvio padrão dos dados radiométricos; b) análise da relação entre dados radiométricos e fator cosseno; c) análise visual da correção; e/ou d) resultado de classificação dos dados espectrais (MCDONALD et al., 2000; MEYER et al., 1993). Estas avaliações são detalhadas a seguir:

- a) A variância da imagem corrigida é teoricamente menor, pois o efeito topográfico, que aumenta a variação radiométrica intraclasse de uso ou cobertura, é removido ou minimizado.
- b) A relação entre dado radiométrico e fator cosseno diminui após correção. Essa relação geralmente é analisada pelo coeficiente de determinação (r^2) e pela inclinação da reta de regressão.
- c) A análise visual é feita observando os impactos da correção em diferentes condições de iluminação.
- d) A análise da correção pelos resultados da classificação é feita pela observação e análise de seus erros. Isso pode ser feito pela visualização dos limites das classes ou pela análise da matriz de confusão, do valor Kappa ou da exatidão (COHEN, 1960; CONGALTON, 2009).

2.3 Classificação do uso e cobertura da terra

Existe uma vasta gama de métodos de classificação que permitem a distinção de alvos na imagem. Um dos métodos mais utilizados é o classificador paramétrico de Máxima

Verossimilhança ou MaxVer, de abordagem local. Recentemente, com o avanço do processamento de imagens, outros métodos têm sido muito explorados na classificação de imagens, especialmente os métodos não paramétricos e a abordagem não local (ou contextual). São citadas neste contexto Redes Neurais Artificiais, *Support Vector Machines*, Árvore de Decisão e Análise de Imagem Baseada em Objetos (OBIA).

Essa seção faz uma descrição de OBIA e de classificação por árvore decisão, além de fazer uma contextualização desses métodos em relação ao efeito topográfico. Estas abordagens de classificação, além de não terem sido exploradas em estudos do efeito topográfico, permitem outras formas de avaliação do efeito topográfico, como pela análise da estrutura da árvore de decisão e das características dos objetos.

2.3.1 Análise de Imagem Baseada em Objetos

O termo OBIA tem sido empregado em várias áreas do conhecimento que utilizam processamento digital de imagens. No sensoriamento remoto, OBIA é abordado no contexto geográfico, e tem sido empregado como GEOBIA (*Geographic Object Image Analysis*) (BLASCHKE, 2010). GEOBIA pode ser definido como o processo de segmentação e de classificação de imagens conduzidos de forma a gerar segmentos ou objetos com características próximas ou iguais aos objetos reais da cena (BENZ et al., 2004).

O processo de segmentação de imagens com abordagem contextual geralmente se inicia com a agregação de *pixels* adjacentes utilizando algum critério de homogeneidade. GEOBIA além de incluir a segmentação, envolve sua interação com a classificação e pode considerar a estruturação hierárquica do conteúdo da imagem. Assim, o analista tem a possibilidade de aplicar seu conhecimento e gerar a classificação dos segmentos em diferentes escalas ou níveis, como exemplo, é possível criar segmentos maiores para separar diferentes culturas agrícolas e a partir desses segmentos fazer outra segmentação para separar diferentes estádios fenológicos ou condição fitossanitária (ex.: clorose). Para isso, o analista pode gerar atributos a partir dos níveis radiométricos dos *pixels* dos segmentos, como de textura/homogeneidade, assim como da forma dos segmentos, e também incluir dados multitemporais na análise (BENZ et al., 2004).

O Definiens (DEFINIENS, 2009) é um programa que tem algoritmos para GEOBIA em sua plataforma. Neste programa, o algoritmo multirresolução de Baatz e Schäpe (2000) tem sido muito utilizado para segmentação por crescimento de regiões. Este algoritmo agrega *pixels* ou grupo de *pixels* com base na similaridade entre elementos adjacentes. Quando um grau mínimo de similaridade entre elementos não é atingido, o processo de agregação não ocorre. O critério similaridade é formado por uma combinação da homogeneidade espectral e da forma do segmento. A homogeneidade espectral é estabelecida com base em métricas que usam a variância e a média dos níveis radiométricos. A forma é controlada com base na razão perímetro/área do segmento. Com essa razão a segmentação pode ter segmentos mais compactos (maior perímetro/área) ou mais suaves (menor perímetro/área).

O usuário controla a segmentação do algoritmo multirresolução por meio de parâmetros que influenciam o tamanho dos segmentos (parâmetro escala). Além disso, pode-se controlar o peso que pondera homogeneidade espectral em relação à forma dos segmentos. Por exemplo, quando o usuário fornece maior peso para homogeneidade espectral, a segmentação se baseia mais nos níveis radiométricos e, portanto, menos na forma dos objetos. Dentro de forma existe o parâmetro peso, que pondera compactidade e suavidade. Maiores detalhes em relação ao algoritmo multirresolução são abordados em Baatz e Schäpe (2000); Definiens (2009).

Em relação ao efeito topográfico sobre a imagem ótica, caracterizado na seção 2.1, é razoável afirmar que este pode ter implicações na segmentação. Teoricamente, o tamanho e a forma dos segmentos são influenciados pelo efeito topográfico, uma vez que este efeito altera os níveis radiométricos e a variância espectral da cobertura.

2.3.2 Árvore de decisão

Árvore de decisão é um método de classificação supervisionada representada por um fluxograma em forma de árvore, gerada com base no princípio de partição recursiva, onde determinado conjunto de dados de treinamento é recursivamente dividido em grupos que contém classes iguais ou similares (STROBL et al., 2009). A árvore de decisão apresenta-se como uma estrutura hierárquica constituída de nós, ramos e folhas, onde é explícito como e quais os atributos que contribuem para a classificação. O ponto

inicial da árvore é o nó raiz, que se divide em dois ramos ligados a outros dois nós (considerando árvores binárias). Quando o nó é posicionado entre dois ramos é denominado nó interno e quando faz parte do término da árvore é denominado nó folha ou simplesmente folha, que representa uma classe identificada.

A divisão do conjunto de treinamento em cada nó é feita por um determinado atributo e seu limiar de divisão (critério de divisão). A seleção do critério de divisão comumente é realizada com base no grau de “redução de impureza”, onde cada divisão resulta em nós descendentes mais puros que o nó ascendente. O nível perfeito de impureza é satisfeito quando a frequência relativa de determinada classe é zero em um dos nós descendentes. O nível de impureza mais elevado é atingido quando as frequências relativas da classe são iguais nos nós descendentes (isto é, 0,5) (STROBL et al., 2009). Medidas de entropia, como o Índice de Gini e Ganho de Informação, são usadas para quantificar a impureza (BREIMAN et al., 1984; QUINLAN, 1993). Alguns algoritmos mais modernos se baseiam em testes estatísticos para seleção do critério de divisão ao invés de medidas de impureza (HOTHORN et al., 2006).

Depois que um critério de divisão é definido, o conjunto de treinamento é dividido entre os nós descendentes e o processo de divisão continua até que determinado critério de parada seja estabelecido. Os critérios de parada mais comuns são: divisão dos dados até que: (a) todas folhas sejam puras (contenham dados de uma única classe); (b) um número mínimo de observações em um nó ou folha seja atingido; ou (c) determinado nível de impureza necessário não seja atingido com atributo algum. Alguns algoritmos utilizam procedimentos estatísticos que envolvem a distribuição dos critérios de parada para estabelecer a “parada” (HOTHORN et al., 2006), enquanto que outros se baseiam em sistemas de podas para definir o tamanho final da árvore (BREIMAN et al., 1984; QUINLAN, 1993).

Nesse estudo, o algoritmo CTREE de Hothorn et al. (2006) é apresentado em mais detalhes. Como já mencionado, este algoritmo utiliza procedimentos estatísticos para definir o critério de divisão e para estabelecer o tamanho final da árvore de decisão. Os critérios de divisão e de parada podem ser controlados pelo analista através do nível de

significância do teste estatístico, do “número mínimo de amostras na folha”, entre outros.

Na Figura 2.11 é apresentada a árvore de decisão gerada pelo CTREE, onde são apresentados o nó raiz (balão maior nº 1), os nós internos (balões maiores nº 2 e 3) e as folhas (balões menores nº 1, 2, 3 e 4). Internamente aos nós se encontram os atributos selecionados e o valor-p do teste estatístico da seleção. Os valores nas linhas que unem os nós e folhas são os limiares do critério de divisão. Internamente às folhas da classificação resultante, estão presentes o número de amostras de treinamento e a proporção de acertos.

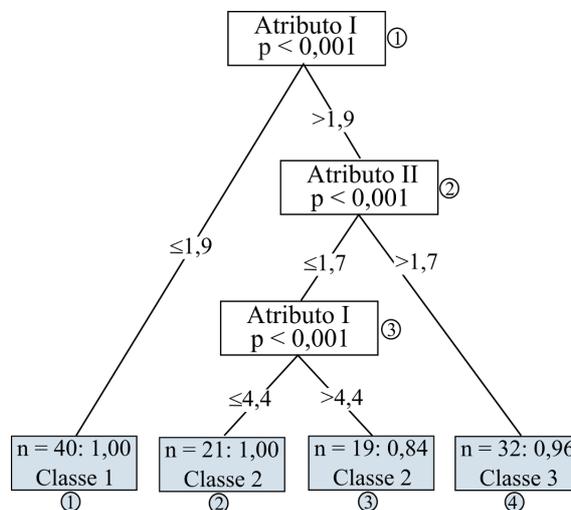


Figura 2.11 - Ilustração esquemática de uma árvore de decisão.

Fonte: Adaptado de Zhao (2013).

A classificação por árvore de decisão é constantemente associada ao termo mineração de dados. O significado mais amplo de mineração de dados é definido como o processo de descoberta de conhecimento a partir de grandes quantidades de dados (HAN; KAMBER, 2006). Nesse sentido, algoritmos de árvore de decisão são utilizados para o reconhecimento de padrões nos dados através do processo de classificação e para indicar quais atributos contribuíram para a classificação, quais atributos foram úteis para discriminar determinada classe, etc.

Com o que foi descrito, pode-se afirmar que a estrutura da árvore de decisão gerada pelo algoritmo CTREE depende do (a) número de classes do conjunto de amostras de treinamento, (b) dos atributos das amostras de treinamento e (c) dos parâmetros da árvore controlados pelo analista. Na árvore de decisão gerada pelo algoritmo CTREE o valor-p está ligado ao nível de impureza (ou mistura) dos nós descendentes, onde valores maiores são determinados para nós relacionados com maior nível de impureza.

O número de nó ou folhas é uma variável que é utilizada para analisar a estrutura da árvore e sua complexidade (ESPOSITO et al., 1997; GELFAND et al., 1989). Por exemplo, uma árvore com maior número de folhas em relação à outra é considerada mais complexa.

Em relação ao efeito topográfico em imagens óticas de satélite, é razoável considerar que ele afeta a estrutura da árvore de decisão. Se houver classes em diferentes condições de iluminação é esperada uma árvore mais complexa (diferentes condições de iluminação de uma mesma classe poderão ser alocadas em diferentes folhas). Se o efeito topográfico aumenta o grau de impureza dos nós descendentes, são esperados valores superiores de valor-p.

2.3.3 Avaliação da classificação

A avaliação da classificação usualmente é feita com base em amostras para as quais se conheçam a classificação “verdadeira” (referência) e o resultado da classificação dos dados de sensoriamento remoto (classificação). A maneira mais simples de avaliar a classificação é calculando a proporção de acertos das amostras, denominada de exatidão total. Pode-se ainda elaborar uma matriz que relaciona as classes da referência àquelas atribuídas pela classificação. Esta matriz é conhecida como matriz de confusão ou matriz de erro. Por ela pode-se analisar as confusões existentes entre as classes e calcular os erros (omissão e comissão) das classes individualmente. Além disso, a partir da matriz de confusão calcula-se o índice de concordância Kappa (COHEN, 1960 CONGALTON, 2009).

Muitas vezes, quando existem duas classificações diferentes de uma mesma área, procura-se saber qual classificação é significativamente melhor. Para isso, a simples

comparação de valores Kappa pode não ser suficiente. Congalton (2009) descreve um método que utiliza estatística de teste Z para determinar se dois Kappa calculados com matrizes de confusão independentes são significativamente diferentes.

Outra forma para avaliar se dois Kappa são estatisticamente diferentes é utilizando o método de Monte Carlo. Esse método se baseia na repetição em um número elevado de vezes de sucessivas simulações a partir de reamostragens aleatórias dos dados de entrada. Através de um grande número de repetições (acima de 1.000), espera-se que grande parte das combinações de entradas possa ser avaliada.

Para avaliar se duas classificações são estatisticamente diferentes pelo Kappa, pode-se propor a seguinte abordagem utilizando o método Monte Carlo: a partir da referência e dos resultados das classificações faz-se (a) uma amostragem de n amostras aleatórias sem reposição, onde em cada amostra se observam a classe da referência e as classes resultantes das duas classificações; (b) a partir das n amostras calcula-se um Kappa para cada classificação, resultando em k_{1i} e k_{2i} ; (c) faz-se a reposição das n amostras. Repete-se (a), (b) e (c) m vezes com reposição das n amostras. Como resultado disso têm-se m vezes k_{1i} e k_{2i} calculados de forma pareada, ou seja, calculados em cada reamostragem com o mesmo conjunto de amostras. Por último, subtrai-se k_{1i} por k_{2i} para obter m diferenças e, a partir delas, calcula-se o intervalo de credibilidade (por exemplo, de 95%), desprezando os valores extremos. Caso o valor zero pertença ao intervalo, as duas classificações não são significativamente diferentes, caso contrário, as duas classificações são significativamente diferentes (CAMILO D. RENNÓ, comunicação pessoal).

Alfaya (2012) utilizou o método de Monte Carlo para avaliar a concordância entre uma classificação e um mapa de referência. O autor considerou um número de 5.000 reamostragens. Em cada reamostragem foram selecionados aleatoriamente 150 *pixels* para cada classe estudada. Considera-se que o intervalo de credibilidade elaborado com vários Kappa estimados com reamostragens permite uma avaliação mais completa da classificação que o uso de um único Kappa, que utiliza um número limitado de amostras.

2.4 Dados

2.4.1 Imagens Landsat

O programa de lançamento de satélites Landsat foi uma iniciativa da *National Aeronautics and Space Administration* (NASA), *United State Geological Survey* (USGS) e do *United States Department of Agriculture* (USDA). O lançamento do primeiro satélite da série ocorreu em 1972. Desde então, imagens Landsat são adquiridas com certa continuidade temporal em escala global. O último lançamento da série ocorreu em fevereiro de 2013, com o Landsat 8. O satélite Landsat 5, sensor TM, foi o que adquiriu imagens por um período mais longo, de 1984 a 2012, consistindo em uma fonte imensa de dados da superfície terrestre que são úteis para diversas aplicações, dentre elas a caracterização do uso e cobertura da terra e sua dinâmica (USGS, *online*).

O Landsat 5 apresenta órbita hélio-síncrona a 705 km da superfície terrestre e possui uma resolução temporal de 16 dias. O tamanho da cena imageada é de 170 km x 185 km, com resolução espacial de 30 m para as bandas de 1 a 5 e banda 7, e resolução espacial de 120 m para a banda 6. As faixas espectrais das bandas do Landsat 5 são apresentadas na Tabela 2.2. O tempo de duração da órbita do Landsat 5 é de 98,20 minutos e o horário de passagem na linha do equador é 9:45h (+/- 15 minutos).

Tabela 2.2 - Bandas espectrais do sensor TM e suas faixas no espectro eletromagnético

Banda	Faixa espectral (μm)
1 (Azul)	0,45 - 0,52
2 (Verde)	0,52 - 0,60
3 (Vermelho)	0,63 - 0,69
4 (Infravermelho próximo)	0,76 - 0,90
5 (Infravermelho médio)	1,55 - 1,75
6 (Infravermelho termal)	10,40 - 12,50
7 (Infravermelho de ondas curtas)	2,08 - 2,35

2.4.2 Dados SRTM

A SRTM consiste em uma fonte de modelos digitais de elevação (MDE) de sensoriamento remoto projetados para atender a mapeamentos na escala de 1:100.000 a 1:250.000 para quase toda a superfície terrestre. A aquisição dos dados SRTM foi feita entre 11 e 22 de fevereiro de 2000, por interferometria SAR, banda C e X, a bordo do ônibus espacial *Endeavor*. A SRTM foi um projeto cooperativo entre NASA dos Estados Unidos, *German Aerospace Center* (DLR) da Alemanha e *Italian Space Agency* (ASI) da Itália (RABUS et al., 2003).

Com vista ao desenvolvimento metodológico para a utilização dos dados SRTM no Brasil, Valeriano (2008) elaborou processos de refinamento dos dados originais e desenvolveu metodologias para geração de variáveis geomorfológicas a partir deles. Os processos de refinamento resultaram na remoção de falhas, redução de artefatos e distribuição da aleatoriedade dos dados por krigagem (técnica de interpolação por geoestatística). Os dados refinados, que originalmente são de 3 arco-segundos (~90m), passaram para 1 arco-segundo (~30m) com essa interpolação (VALERIANO; ROSSETTI, 2012).

O desenvolvimento de metodologias para refinamento dos dados SRTM e de geração de variáveis geomorfológicas a partir dos modelos refinados culminaram na criação do Banco de Dados Geomorfológicos do Brasil (Topodata). Os produtos do Topodata, junto com especificações técnicas e orientações aos usuários, estão disponíveis em <http://www.dsr.inpe.br/topodata>. O conjunto de dados inclui planos de informação numéricos e qualitativos das variáveis: altitude (Z), declividade (S), orientação de vertentes (O), curvatura vertical (V) e horizontal (H), bem como insumos para o delineamento da estrutura de drenagem (modelo ADD) e formas do terreno (FT) (VALERIANO, 2008).

Uma característica indesejável dos dados SRTM, assim como de outros MDE gerados por sensoriamento remoto como GDEM (ERSDAC, 2009), é o comumente denominado efeito do dossel: os dados podem expressar a presença de objetos não topográficos (vegetação, prédios, casas) sobre a superfície do terreno. O efeito dossel se torna mais evidente por meio da observação da declividade do terreno, onde são observadas

mudanças abruptas nos limites entre, por exemplo, vegetação arbórea e vegetação rasteira. O efeito dossel é mais expressivo em áreas de relevo do tipo plano, onde representa limitações a seu uso em detalhe local. Em áreas de relevo do tipo ondulado a montanhoso, ele é normalmente encoberto pelas variações do terreno, onde estas são superiores as variações da vegetação (VALERIANO et al., 2006).

Os dados SRTM já foram utilizados como subsídio para a correção do efeito topográfico em imagens de satélite Landsat. Gao e Zhang (2009b) avaliaram um MDE na escala de 1:50.000 obtido a partir de curvas de nível e o MDE-SRTM para correção do efeito topográfico em imagens Landsat 7 ETM+. Os autores relatam que ambos MDE contribuíram para redução do efeito topográfico com desempenho similar. Outros autores utilizaram MDE-SRTM para correção topográfica de imagens Landsat e obtiveram resultados satisfatórios (BALTHAZAR et al., 2012; VANONCKELEN et al., 2013).

3. MATERIAL E MÉTODOS

3.1 Visão geral

O fluxograma geral de trabalho encontra-se esquematizado na Figura 3.1. Utilizaram-se imagens multiespectrais Landsat TM e dados topográficos SRTM como insumos principais. A fase de pré-processamento consistiu no registro e preparação dos dados em um sistema de informação geográfica (SIG). Os dados multiespectrais e topográficos, apesar de originalmente estarem georreferenciados, quando foram sobrepostos em planos de informação estavam deslocados lateralmente. Para completa sobreposição dos mesmos foi realizado um deslocamento linear daqueles em relação a estes. Esse deslocamento foi feito com base em pontos de maior contraste em relação a seus vizinhos, aparentes em todos os dados, principalmente em regiões de feições de drenagem e divisores de águas. Além disso, as posições dos *pixels* dos dados foram estruturadas pelo método do vizinho mais próximo, para seus completos alinhamentos quando sobrepostos. Os dados foram processados no sistema de coordenadas geográficas, datum WGS 1984.

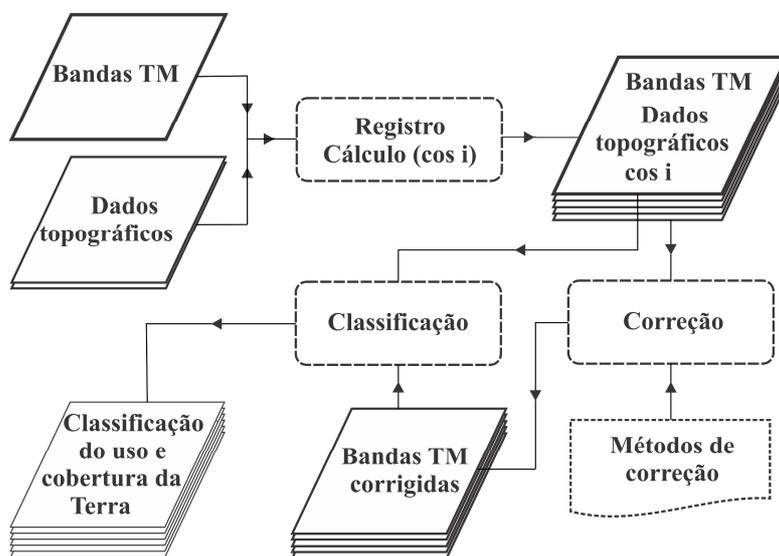


Figura 3.1 - Fluxograma das principais atividades desenvolvidas nesse estudo.

Foi elaborado um plano de informação pelo cálculo do fator cosseno por meio da Equação 2.2, descrita na seção 2.1.1, que utiliza a declividade, orientação de vertentes e informações relativas à geometria de iluminação do momento de aquisição da imagem.

Vários métodos de correção do efeito topográfico foram pré-selecionados para serem avaliados nesse estudo e para análise do efeito topográfico e de sua correção. A avaliação foi realizada por meio de análises das bandas espectrais e por meio da classificação do uso e cobertura da terra. Pelos resultados da avaliação foi selecionado um método de correção para a análise detalhada do efeito topográfico e de sua correção. Todas as etapas de avaliação e análise consideraram os dados antes e após correção topográfica (Figura 3.2).

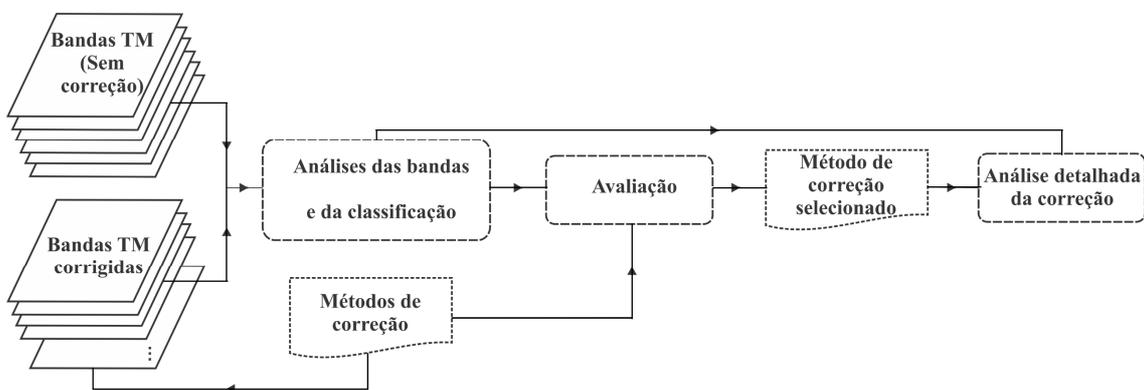


Figura 3.2 - Fluxograma das principais atividades de avaliação e análise do estudo.

3.2 Material

3.2.1 Área de estudo

A área de estudo (Figura 3.3) localiza-se na parte sul do estado de Minas Gerais, entre os municípios de Alfenas e Machado, com uma área de 11,5 por 11,5 quilômetros. É uma região tropical predominantemente agrícola, com culturas anuais e perenes, e com pequenos fragmentos florestais do bioma Mata Atlântica. Existem também pequenas áreas de silvicultura, principalmente de eucalipto. As principais culturas agrícolas na região são café, milho e feijão (IBGE, 2011).

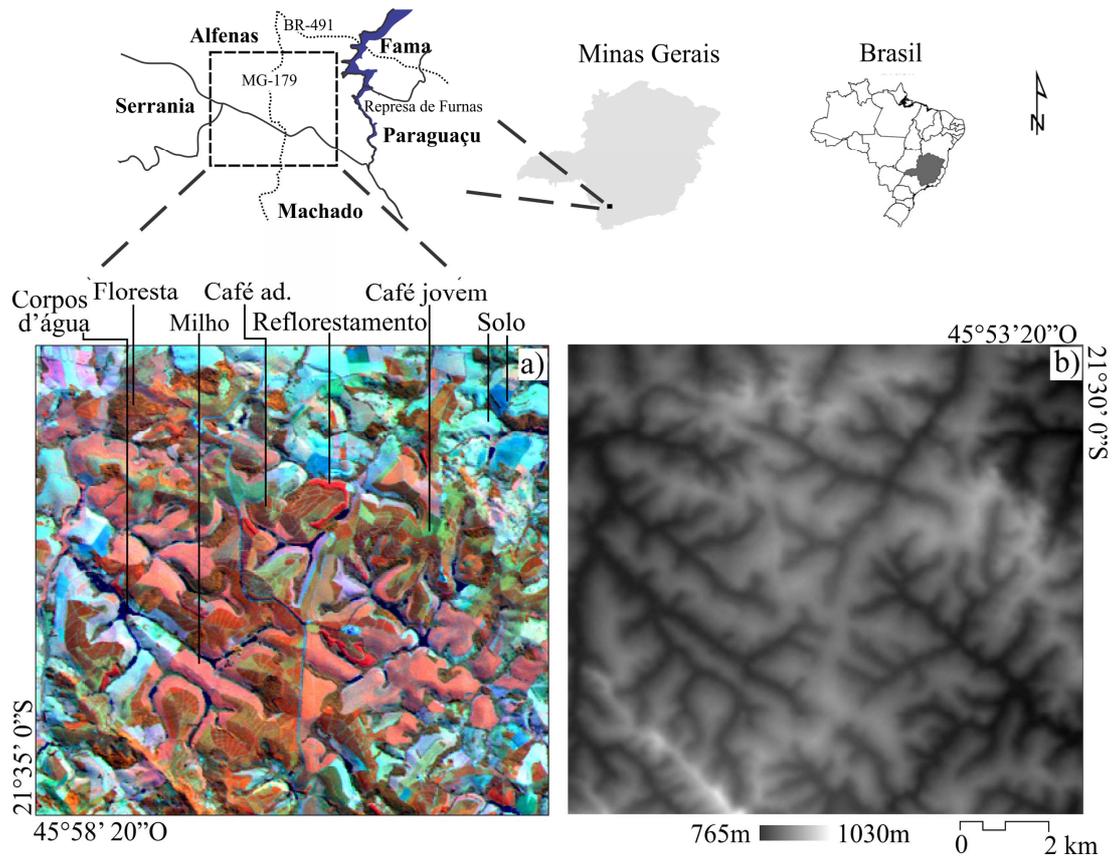


Figura 3.3 - Localização da área de estudo, no sul de Minas Gerais, Brasil. a) Imagem Landsat 5 TM composição 453 (RGB) com as identificações das classes de uso e cobertura. b) MDE-Topodata.

O relevo da área é do tipo suave ondulado a ondulado (EMBRAPA, 2006). A declividade média é de $7,5^\circ$ e a máxima de 35° . A altitude varia de 765 a 1.030 metros. A Figura 3.4 mostra os histogramas de frequência da declividade e orientação de vertentes da área de estudo utilizando os dados do Topodata.

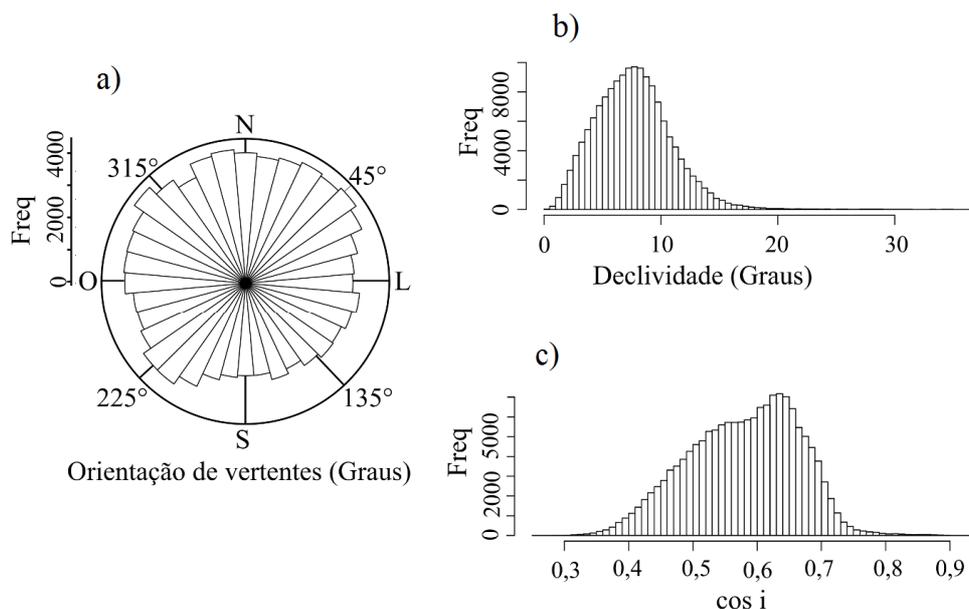


Figura 3.4 - a) Diagrama de roseta da orientação de vertentes e histogramas da b) declividade e do c) fator cosseno ($\cos i$) da área de estudo.

3.2.2 Dados e recursos para processamento

Foram usadas as seis bandas não-termais Landsat 5 TM da área de estudo, do catálogo de imagens do INPE (<http://www.dgi.inpe.br/CDSR/>), cena 219/75 (*path/row*), com data de imageamento de 8 de junho de 2011. A geometria de iluminação solar no momento da aquisição da imagem corresponde ao ângulo zenital solar de $54,32^\circ$ e ao ângulo azimutal solar de $37,01^\circ$. Os dados topográficos, representados principalmente pela declividade e orientação de vertentes, foram obtidos do Topodata (VALERIANO; ROSSETTI, 2012). Também foram usadas imagens de alta resolução do *Google Earth*, adquiridas no ano de 2011, para verificação dos dados de referência.

As etapas de processamento de dados foram feitas utilizando a linguagem de programação R, versão 3.0 (R DEVELOPMENT CORE TEAM, 2013), com exceção da segmentação, que foi realizada no Definiens, versão 8.0 (DEFINIENS, 2009). A segmentação foi realizada com o algoritmo multiresolução de Baatz e Schäpe (2000). No R, foram necessários usar funções do pacote “raster” (HIJMANS, 2013) para processar os dados no formato matricial, o pacote “maptools” (BIVAND, 2013) e

“rgdal” (KEITT et al., 2013) para os arquivos no formato vetor. Foram utilizados os pacotes padrões do R para análise de regressão, análise de componentes principais (função “princomp”) e geração de gráficos. Foi utilizado o algoritmo “CTREE” implementado no pacote “party” (HOTHORN et al, 2006) para mineração de dados e geração da árvore de decisão.

3.3 Metodologia

3.3.1 Correção topográfica

Os métodos de correção topográfica selecionados para esse estudo encontram-se na Tabela 3.1. Esses métodos foram aplicados diretamente sobre os valores digitais de cada banda espectral, sem nenhuma transformação prévia.

Tabela 3.1 - Métodos aplicados e avaliados nesse estudo

Método de correção	Abreviação	Equação
C		2.5
Correção de dois estádios (1º estádio)	S1	2.13
Correção de dois estádios (2º estádio)	S2	2.14
Correção de dois estádios adaptada (2º estádio)	AdS2	2.17
Cosseno		2.3
Estatística-empírica	E-Stat	2.19
Minnaert		2.8
SCS		2.4
SCS+C		2.20

Com exceção dos métodos Cosseno e SCS, os demais são da categoria de métodos semiempíricos. A estratégia adotada para estimativa dos parâmetros empíricos baseia-se em amostras da classe de cobertura principal (seção 2.2.2). Como não há uma classe de cobertura principal nesse estudo e o objetivo do trabalho foi classificar todos os tipos de cobertura presentes na área, optou-se por testar amostras de duas classes distintas de cobertura, aplicar e avaliar as correções com parâmetros de correção estimados com cada uma delas. Dessa forma cada método semiempírico foi aplicado duas vezes para comparação resultados com o objetivo de responder questões, tais como: ambos os tipos de cobertura foram úteis para estimar os parâmetros de correção e corrigir toda a

imagem? Os resultados da correção são diferentes? Se forem diferentes, quais as características de cada cobertura que levaram a isso?

3.3.2 Levantamento de dados de referência

Os dados de referência foram gerados com a ajuda de especialistas que conhecem a área de estudo por meio de interpretação da imagem Landsat TM e de imagens do *Google Earth*. Foram identificadas áreas de floresta, café (em vários estádios fenológicos), milho, reflorestamento, solo exposto e corpos de água.

Para diferenciar as classes de cobertura, foi elaborada uma chave de interpretação (Figura 3.3) da imagem Landsat 5 TM. As classes de cobertura são facilmente separadas visualmente pelas cores e texturas na imagem. É importante ressaltar que a classe de cobertura milho é a que apresenta maior homogeneidade para toda a área em termos de brilho (cor) e textura, indicando pouca variação fenológica de uma plantação para outra, enquanto que a classe solo varia bastante e pode ser subdivida em solo arado, solo com palha seca e pasto degradado; cada uma dessas subdivisões pode variar com outros fatores, como umidade.

Foram coletadas três conjuntos de amostras de controle com as seguintes finalidades:

- a) Estimar os parâmetros empíricos da correção topográfica;
- b) Treinar o classificador; e
- c) Avaliar a classificação.

Os três esquemas de distribuição dessas amostras estão representados na Figura 3.5:

- a) As amostras de controle para estimativa dos parâmetros de correção foram coletadas para as classes de cobertura milho e floresta através da interpretação visual da imagem Landsat TM. Para cada ponto foram inseridos os valores das diferentes bandas espectrais do seu *pixel* correspondente e seu fator cosseno, declividade, etc. Para representar as classes de cobertura e as diferentes condições de iluminação foram coletadas amostras posicionadas em diferentes

declividades e orientação de vertentes, totalizando 222 e 156 amostras da classe de cobertura milho e floresta, respectivamente.

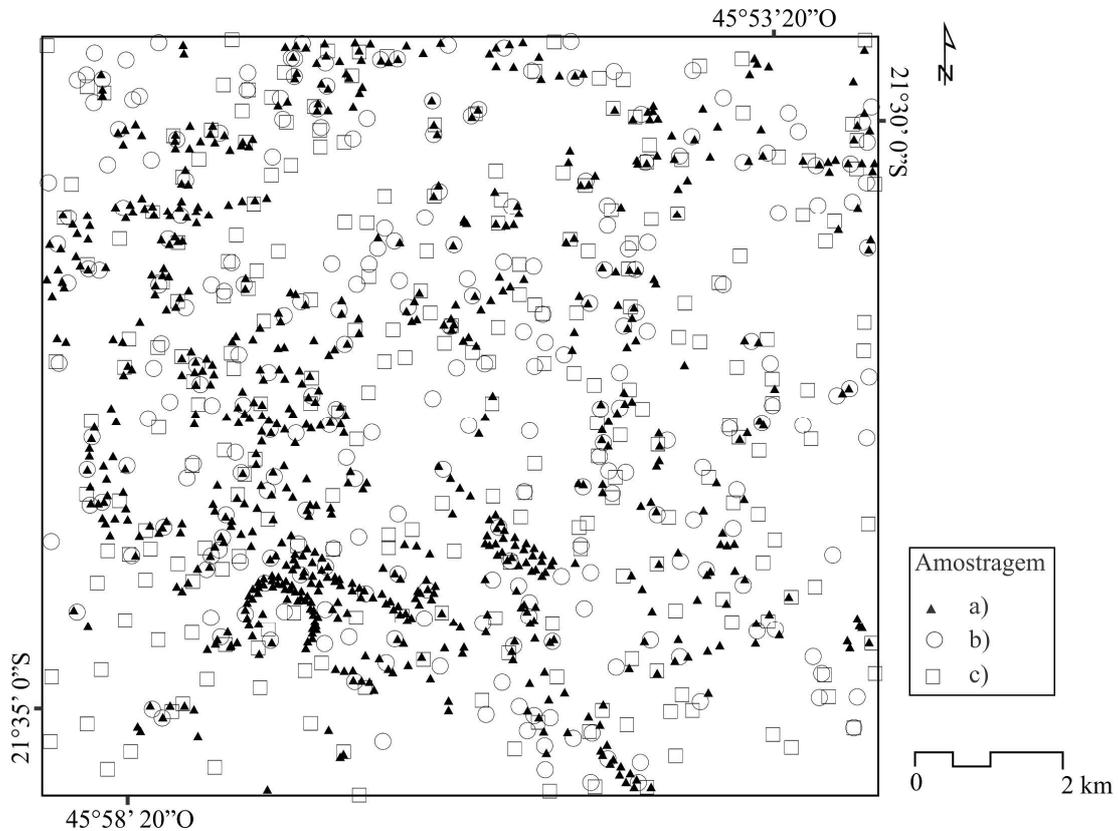


Figura 3.5 - Distribuição das amostras de controle para a) estimar os parâmetros de correção e avaliar a correção, b) treinar o classificador e c) avaliar a classificação.

- b) As amostras de treinamento do classificador foram coletadas para todas as classes de cobertura. As amostras foram identificadas por pontos localizados no centro de talhões das classes, os quais foram usados para selecionar os segmentos gerados pelo processo de segmentação e treinar o classificador. O processo de seleção das amostras envolveu a análise visual do resultado da classificação da imagem sem correção (bandas originais), de modo a representar um bom conjunto de treinamento para o classificador e otimizar a classificação. Foram coletadas 55 amostras da classe café adulto, 63 de milho, 41 de floresta, 59 de solo e 39 das demais (aquelas que ocupam menores extensões territoriais).
- c) Para a avaliação da exatidão da classificação foram coletadas 50 amostras coletadas aleatoriamente em forma de pontos para cada classe de cobertura.

Segundo Congalton (2009), essa quantidade de amostras é considerada satisfatória para avaliação da classificação por meio da matriz de confusão quando o número de classes não é alto (abaixo de 12). Nesta fase foi decidido nomear como uma mesma classe aquelas de menor importância territorial, que são as classes café jovem, reflorestamento e corpos d'água, totalizando 50 amostras.

3.3.3 Classificação baseada em objetos

A classificação dos dados Landsat divide-se em duas partes: segmentação e classificação por árvore de decisão. As bandas sem correções foram utilizadas na definição dos parâmetros de segmentação do algoritmo. Os parâmetros foram definidos pelo método de tentativa e erro utilizando as bandas 3, 4, 5 e 7 com mesmo peso. Procurou-se otimizar os parâmetros de segmentação de forma a evitar mistura de duas classes espectrais distintas dentro de um segmento. Os parâmetros de segmentação foram: escala=6, forma=0,2, compacidade=0,3. Os mesmos parâmetros foram utilizados para segmentar as bandas com correção. Os atributos apresentados na Tabela 3.2 foram calculados para todos os segmentos gerados com a finalidade de serem utilizados para classificação dos dados.

Tabela 3.2 - Atributos dos segmentos gerados com todas as bandas não termais Landsat 5 TM para classificação do uso e cobertura da terra

Tipo	Nome
Espectral	Media
	Desvio padrão
Textura ^a	GLCM Média ^b
	GLCM Contraste
	GLCM Dissimilaridade
	GLCM Entropia
	GLCM Desvio padrão
	GLCM <i>Ang. 2nd moment</i>
Customizado	NDVI ^c
	<i>Tasseled cap: Brightness, Greenness e Wetness</i> ^d
	Razão de bandas: todas as razões possíveis entre duas quaisquer bandas
	Coefficiente de variação (CV)

a: Métodos propostos por Haralick (1979).

b: GLCM: *Gray Level Co-occurrence Matrix*.

c: NDVI: *Normalized Difference Vegetation Index*.

d: Transformação espectral *Tasseled cap* (Kauth; Thomas, 1976).

As amostras de treinamento, representadas por um conjunto de segmentos selecionados pelos pontos descritos na seção 3.3.2, foram utilizadas para treinar o algoritmo para geração da árvore de decisão. Alguns parâmetros do algoritmo foram ajustados para maior adequação aos dados: o número mínimo de amostras nos nós terminais foi ajustado para 3, o valor do teste estatístico (1 - valor-p) que deve ser excedido a fim de possibilitar uma divisão foi ajustado para 0,95 e a soma mínima de amostras para ocorrer uma divisão foi ajustada para 6. Os demais parâmetros do algoritmo não foram alterados. Todas as árvores das classificações foram geradas com os mesmos parâmetros.

3.3.4 Avaliação e análises

As atividades de avaliação e análises dos resultados foram feitas em duas etapas: (A) avaliação dos métodos de correção e (B) análise detalhada do efeito topográfico e de sua correção. Na etapa A, todos os métodos foram avaliados e as correções foram analisadas de maneira geral considerando as características dos dados espectrais e os resultados da classificação. Além disso, compararam-se na etapa A os desempenhos das correções realizadas com parâmetros estimados com cada uma das duas coberturas (milho e floresta) utilizadas como fonte para estimativa de parâmetros empíricos dos métodos de correção. Ainda nesta etapa foi selecionado um método de correção para ser utilizado em B.

Os procedimentos realizados nas etapas A e B foram divididos em duas frentes: análise das bandas espectrais e análise da classificação do uso e cobertura da terra. Os procedimentos de análise das bandas espectrais podem ser compartimentados em:

- a) Comparação da média e desvio padrão, antes e depois da correção, de amostras das diferentes classes de cobertura (realizado nas etapas A e B).
- b) Análise de regressão entre cada banda espectral e fator cosseno através de amostras das classes de cobertura visando o estudo da relação entre essas variáveis. Essa análise foi feita com base no r^2 e valor-p do teste F da regressão linear (realizado nas etapas A e B).

- c) Análise de componentes principais com as 6 bandas espectrais. Foram feitas análises visuais da primeira componente (PCA1) e análise de regressão entre PCA1 e fator cosseno (somente na etapa B).
- d) Análise da média e desvio padrão das bandas espectrais (somente na etapa B).
- e) Análise visual das bandas espectrais (realizada em ambas etapas, porém de maneira mais detalhada na etapa B).

Nos procedimentos a, b e c listados, considerou-se na etapa A somente as amostras das duas classes de cobertura usadas como fontes para estimativa dos parâmetros de correção. Em B, foi considerado um número maior de classes de cobertura.

Os procedimentos da análise da correção através da classificação nas etapas A e B podem ser compartimentados em:

- a) Análise da estrutura da árvore de decisão. Nesta análise, considerou-se o número de nós e folhas (etapas A e B), os atributos presentes nos nós (somente na etapa B) e o valor-p do teste estatístico usado como critério de divisão em cada nó (somente em B).
- b) Forma e tamanho dos segmentos. A forma dos segmentos foi analisada de maneira visual (somente na etapa B). O tamanho foi analisado considerando o tamanho médio dos segmentos de toda a área (somente em A) e por classes de uso e cobertura da terra (somente em B).
- c) Mineração de dados. A mineração foi utilizada para indicar quais dados (com e sem correção) contribuem, ou são mais adequados, para a classificação. Para isso, a classificação foi realizada considerando ao mesmo tempo dados sem e com correção topográfica. Para favorecer a seleção de atributos dos dados sem correção, o processo de segmentação considerou somente as bandas não corrigidas, mas os atributos dos seguimentos foram gerados em relação a todas as bandas, sem e com correção (somente em B).
- d) Análise detalhada da matriz de confusão (somente em B) e do índice de concordância Kappa calculado a partir dela (nas etapas A e B).
- e) Exatidão total. A exatidão total foi calculada de maneira estratificada, considerando diferentes condições de iluminação dadas pelo fator cosseno. A

área foi estratificada em quatro condições de iluminação, em que cada uma delas foi representada pelo intervalo de um quartil do fator cosseno. Para cada estrato foi calculada a exatidão total com base nas amostras de controle (somente na etapa A).

- f) Comparação de Kappa. Nesta análise, foi utilizado o método de Monte Carlo. Como não há um mapa de referência, foi utilizado como referência as amostras de controle da avaliação das classificações. Das 50 amostras de controle de cada classe de uso e cobertura foram selecionadas aleatoriamente 25, totalizando 125 amostras para as 5 classes de uso e cobertura da terra. O número de simulações foi de 10.000. O intervalo de credibilidade adotado foi de 95% (somente na etapa B).
- g) Análise visual da classificação para serem notadas as principais confusões da classificação (somente na etapa B).

4. RESULTADOS E DISCUSSÃO

Este capítulo está dividido em quatro partes. Na primeira parte, caracterizam-se a área de estudo e os dados espectrais em relação às suas condições de iluminação solar descritas pelo fator cosseno. Numa segunda etapa, é feita uma avaliação geral dos diferentes métodos de correção topográfica. Em seguida, a partir de um método de correção selecionado com base na etapa de avaliação anterior, é abordada uma análise detalhada do efeito da correção sobre as bandas espectrais e sobre a classificação do uso e cobertura da terra. Por fim, são feitas considerações gerais referentes a todos os resultados.

4.1. Caracterização dos dados em relação ao fator cosseno

A declividade, a orientação de vertentes, o fator cosseno e a imagem Landsat TM 453 da área de estudo são apresentados na Figura 4.1. O fator cosseno foi calculado considerando as condições locais do terreno (declividade e orientação de vertentes) e momentâneas de iluminação (azimute e zênite solar), correspondentes ao horário e data da aquisição da imagem Landsat.

É evidente uma similaridade entre o fator cosseno e a imagem Landsat (Figura 4.1). Nas vertentes menos iluminadas, caracterizadas por fator cosseno menores, a imagem também apresenta níveis radiométricos menores, considerando áreas de uma mesma classe de cobertura da terra em diferentes vertentes. Essa similaridade também se verifica pela percepção das feições do relevo nesses dados, dando uma impressão visual de tridimensionalidade. Isso demonstra a presença do efeito topográfico nos dados espectrais.

Pelas representações de cores e tons de cinza, essa relação de similaridade não ocorre entre imagem e declividade ou imagem e orientação de vertentes porque, nos esquemas de visualização adotados (VALERIANO, 2007), a representação da declividade simula uma iluminação a nadir, por não conter variações em azimute, e a orientação de vertentes, reciprocamente, não representa a ocorrência de áreas planas, além de simular uma iluminação do Norte, diferente do azimute vigente na aquisição da imagem.

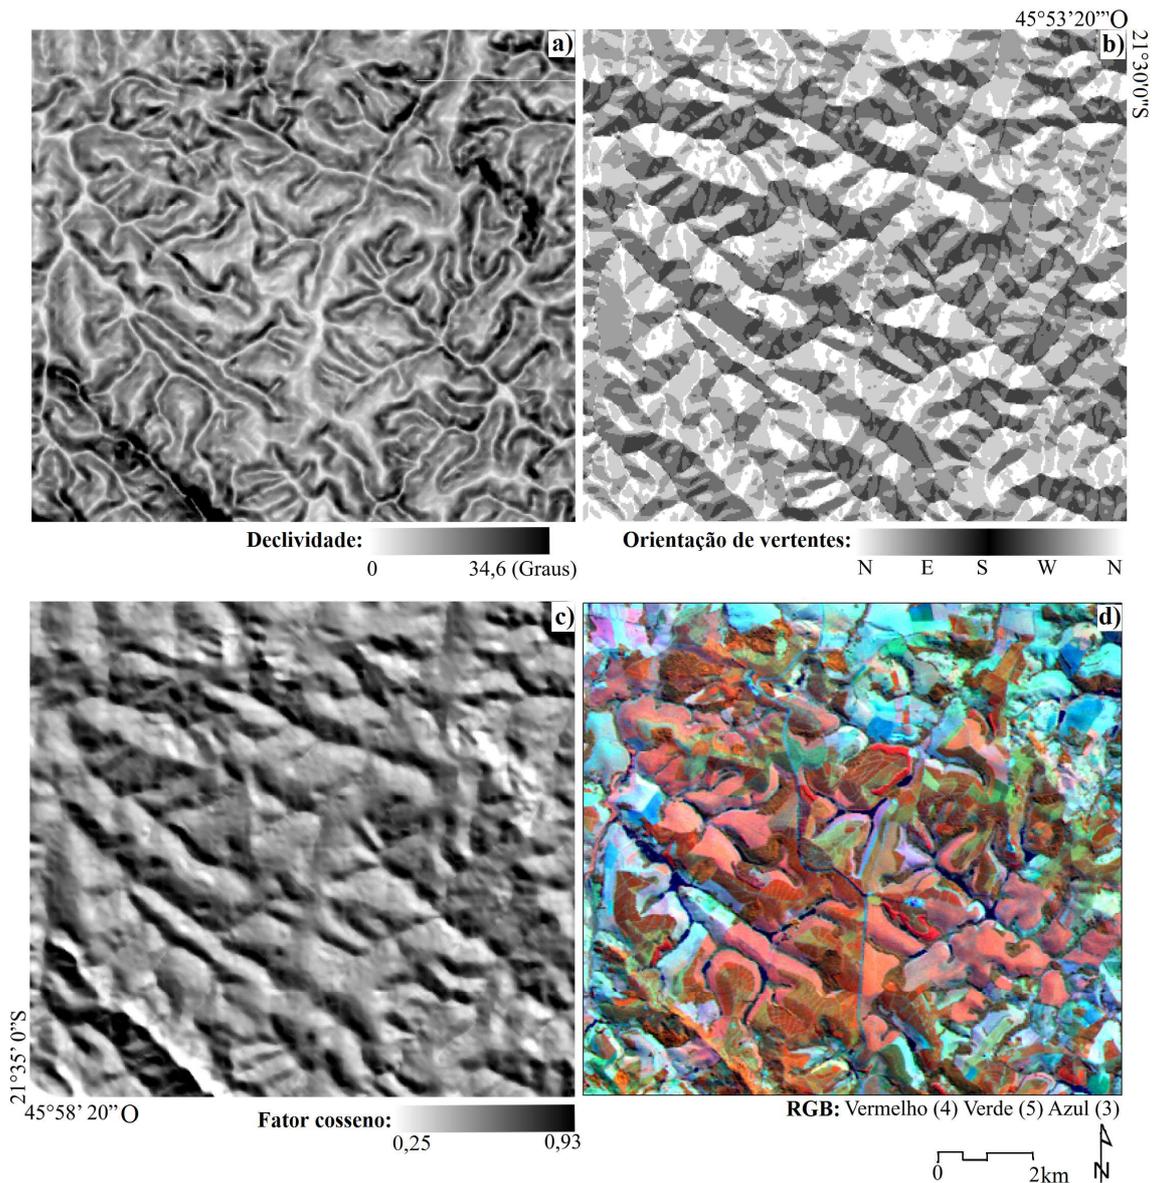


Figura 4.1 - Dados da área de estudo: a) Declividade; b) Orientação de vertentes; c) Fator cosseno e; d) Imagem Landsat 5 TM composição 453 (RGB). Parâmetros de imageamento para cálculo do fator cosseno: ângulo zenital solar = $54,32^\circ$ e; ângulo azimutal solar = $37,01^\circ$.

As condições de iluminação da área de estudo poderiam ser mais satisfatórias considerando outros horários de aquisição da imagem e meses do ano. Quanto mais distante é do meio dia a aquisição de imagens, maior é o ângulo de elevação solar, favorecendo maior variação da iluminação solar em áreas de relevo irregular. Ao longo do ano, nos períodos próximos ao solstício de inverno, a declinação solar é maior,

levando a geometria de iluminação solar ser mais desfavorável para a aquisição de imagens de satélites no hemisfério sul. No entanto, em muitas regiões tropicais o inverno corresponde ao período com menos cobertura de nuvens do ano, no qual há maior probabilidade de imageamento livre de nuvens. Por outro lado, as condições de iluminação poderiam ser piores em latitudes mais elevadas e em áreas de relevos do tipo ondulado a escarpado, onde o efeito topográfico e o sombreamento seriam mais intensos.

O fator cosseno e o ângulo de incidência na superfície podem ser representados em isolinhas sobre o plano cartesiano definido pela declividade e pela orientação de vertentes, conforme na Figura 4.2. O fator cosseno varia de 0,25 a 0,93 e o ângulo de incidência solar em relação à normal da superfície varia de 21 a 76°. Nota-se que o fator cosseno é superior à zero para toda a área, indicando que toda ela recebe iluminação solar direta no momento da aquisição da imagem.

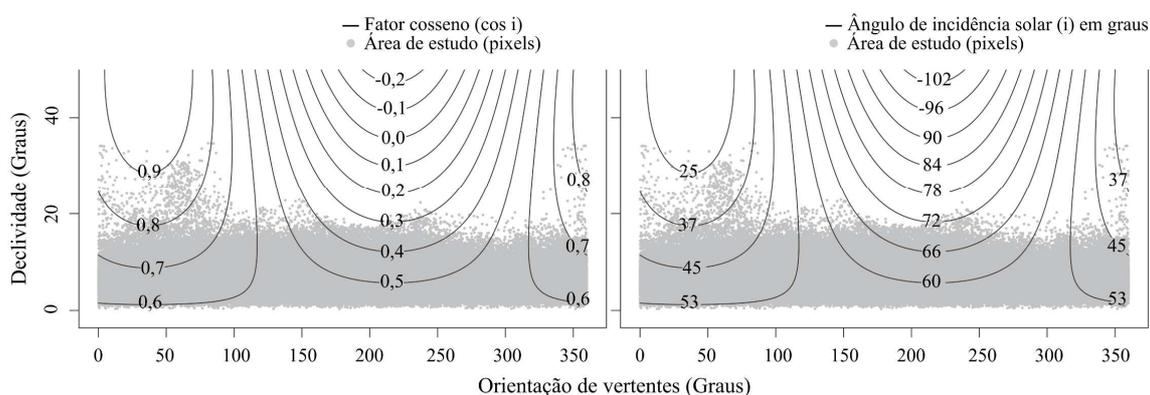


Figura 4.2 - Distribuição da área de estudo em função da geometria de iluminação solar (fator cosseno e ângulo de incidência solar), declividade e orientação de vertentes. Parâmetros da cena para cálculo do fator cosseno: ângulo zenital solar = 54,32° e; ângulo azimutal solar = 37,01°.

A distribuição das amostras usadas para estimativa dos parâmetros de correção topográfica e para a primeira etapa de avaliação da correção varia em relação às condições de iluminação solar (Figura 4.3). As amostras da classe de floresta são as que mais representam as áreas relativamente pouco iluminadas (fator cosseno < 0,4). Na

perspectiva de que a geometria da aquisição tenha correlação com o balanço anual da radiação, isto deve ser uma tendência para outras áreas ou regiões à medida que usos agrícolas mais competitivos em rendimento ocupem as áreas mais iluminadas (principalmente na parte da manhã), restando as demais áreas para os remanescentes florestais. De fato, as amostras de café adulto mostram-se numa situação intermediária, com fator cosseno até aproximadamente 0,7, enquanto que as de milho e solo (estes predominantemente em preparo, para usos agrícolas) são as mais frequentes acima desse limiar, ou seja, em áreas mais iluminadas.

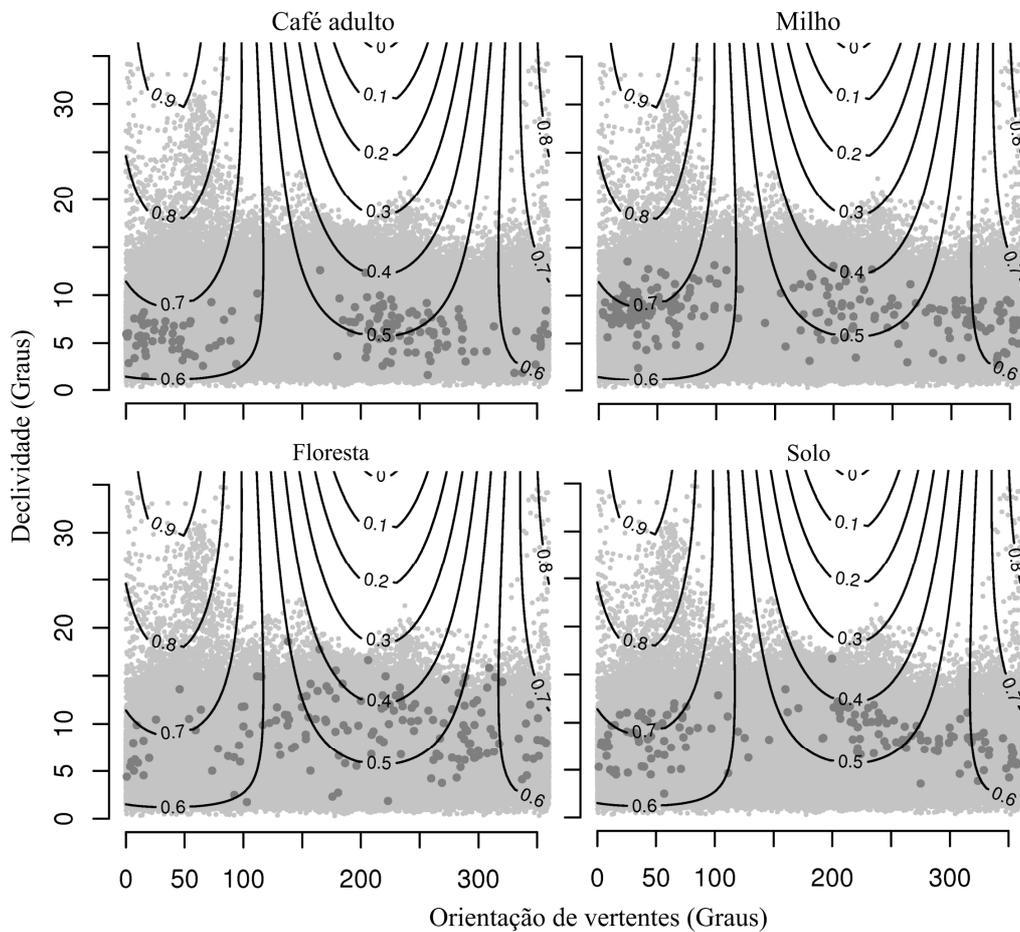


Figura 4.3 - Distribuição das amostras (pontos cinza escuro) utilizadas para estimar os parâmetros de correção (somente as classes de cobertura de milho e floresta) e para avaliar a correção (todas as classes) em relação à declividade, orientação de vertentes e fator cosseno (isolinhas). Os pontos em cinza claro representam os *pixels* da área total.

4.2. Avaliação dos métodos de correção topográfica

A primeira fase de avaliação dos métodos de correção topográfica foi elaborada com as amostras das classes de cobertura milho e floresta, usadas também como fonte para estimativa dos parâmetros de correção. Cabe salientar que as correções realizadas sobre as amostras tiveram seus parâmetros estimados com as mesmas amostras usadas para avaliá-las. Nessa avaliação, o exame em todas as classes de cobertura (e decorrentes possibilidades de combinação) implicaria uma apresentação e explicação de resultados exaustiva em relação à expectativa de ganho de informação. A estratégia de usar somente as classes de milho e floresta foi embasada em diversas ponderações: suas representatividades em termos de área; características distintas e bem representativas de textura/homogeneidade. No entanto, uma avaliação da correção considerando todas as classes de cobertura foi realizada numa primeira etapa, com um único método de correção topográfica, e apresentada na próxima seção deste estudo.

As estatísticas descritivas básicas dos valores amostrais antes e após correção topográfica encontram-se Tabela 4.1. No geral, a correção causou diminuição da média dos valores radiométricos amostrais, ou níveis de cinza (NC), da classe milho, e aumento da média dos da floresta. Em outros trabalhos relata-se que para áreas com baixa iluminação solar (vertentes voltadas para a posição contrária à direção do Sol) há aumento nos NC após correção, o oposto ocorre para áreas bem iluminadas (MEYER et al., 1993; WEN et al., 2009). Nesse aspecto, o comportamento da média está concordando com a distribuição das amostras (Figura 4.3). As amostras da cobertura milho apresentam-se mais distribuídas em áreas mais iluminadas, assim têm sua média reduzida pela compensação da iluminação por meio da correção, enquanto que as de floresta, por se concentrarem em áreas menos iluminadas, recebem aumento da média radiométrica.

As correções dos métodos E-Stat e Ad2S não tiveram o mesmo comportamento em relação à média. A E-Stat não alterou a média radiométrica em relação aos dados não corrigidos. Já o Ad2S aumentou a média radiométrica, tanto para as amostras de milho quanto para as de floresta (Tabela 4.1). Esse comportamento é explicado pelas

características desses métodos: o E-Stat utiliza a média radiométrica das amostras em sua equação e o Ad2S utiliza média das amostras localizadas em áreas bem iluminadas.

Tabela 4.1 - Média (μ), desvio padrão (σ) e parâmetros da regressão (bandas vs. fator cosseno) de amostras das bandas Landsat 5 TM, antes e após correção topográfica

Band		Sem	Método de correção								
			Cosseno	S1	S2	Ad2S	SCS	Minnaert	E-Stat	C	SCS+C
----- Classe de cobertura: Milho -----											
1	μ	48,5	47,5	48,4	48,4	48,8	46,9	47,8	48,5	48,2	48,1
	σ	1,83	7,56	2,38	1,54	1,59	7,41	1,54	1,55	1,53	1,53
	r^2	28,8	94,2	58,4	0,5 ^{ns}	5,1	94,7	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
2	μ	24,4	23,8	24,3	24,3	24,7	23,5	23,9	24,4	24,1	24,0
	σ	1,89	3,37	1,57	1,55	1,66	3,31	1,52	1,55	1,52	1,52
	r^2	32,5	79,7	3,6	0,5 ^{ns}	11,8	79,9	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
3	μ	20,7	20,1	20,6	20,6	21,0	19,9	20,3	20,7	20,4	20,3
	σ	1,65	2,55	1,18	1,18	1,38	2,51	1,15	1,18	1,16	1,16
	r^2	48,8	80,1	0,0 ^{ns}	0,2 ^{ns}	26,1	80,2	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
4	μ	79,0	76,4	78,6	78,3	80,7	75,5	76,9	79,0	77,0	76,5
	σ	9,09	8,07	6,46	5,93	7,20	7,98	5,69	5,90	5,71	5,72
	r^2	57,8	52,1	16,4	0,0 ^{ns}	32,9	51,4	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
5	μ	50,6	48,8	50,3	50,0	51,6	48,3	49,1	50,6	49,1	48,8
	σ	5,94	4,24	3,95	3,28	4,66	4,20	3,04	3,11	3,06	3,08
	r^2	72,6	50,0	35,0	0,1 ^{ns}	55,5	49,0	0,1 ^{ns}	0,0 ^{ns}	0,1 ^{ns}	0,1 ^{ns}
7	μ	15,7	15,2	15,6	15,6	16,1	15,0	15,3	15,7	15,3	15,2
	σ	2,17	1,82	1,73	1,62	1,80	1,81	1,55	1,56	1,55	1,55
	r^2	48,7	28,5	15,3	0,0 ^{ns}	24,8	27,8	0,1 ^{ns}	0,0 ^{ns}	0,1 ^{ns}	0,1 ^{ns}
----- Classe de cobertura: Floresta -----											
1	μ	43,2	47,8	43,1	43,2	43,8	47,1	43,1	43,2	43,5	43,4
	σ	1,79	7,89	2,49	1,66	1,66	7,52	1,72	1,66	1,68	1,68
	r^2	13,8	90,4	54,7	0,0 ^{ns}	0,5 ^{ns}	90,3	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
2	μ	18,1	20,0	18,1	18,1	18,5	19,7	18,2	18,1	18,4	18,3
	σ	1,02	3,15	1,08	0,91	0,92	3,00	0,92	0,90	0,92	0,92
	r^2	21,6	85,7	28,5	0,0 ^{ns}	2,6	85,6	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
3	μ	14,3	15,8	14,3	14,3	14,6	15,5	14,4	14,3	14,5	14,5
	σ	1,22	2,58	1,19	1,13	1,13	2,46	1,15	1,12	1,15	1,14
	r^2	14,8	72,2	9,1	0,4 ^{ns}	1,6 ^{ns}	71,1	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
4	μ	55,6	60,6	55,3	55,0	58,9	59,7	58,1	55,6	58,3	57,7
	σ	8,47	8,02	6,68	6,20	6,84	7,73	6,53	6,31	6,56	6,48
	r^2	44,6	26,5	13,1	0,2 ^{ns}	15,0	24,1	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}
5	μ	38,1	41,7	37,9	37,8	39,9	41,0	39,7	38,1	39,8	39,5
	σ	4,86	4,92	3,58	3,33	3,88	4,68	3,46	3,36	3,48	3,44
	r^2	52,2	43,3	13,2	0,1 ^{ns}	24,7	40,9	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,1 ^{ns}
7	μ	12,1	13,3	12,1	12,1	12,7	13,1	12,6	12,1	12,6	12,5
	σ	1,61	1,91	1,30	1,28	1,34	1,82	1,33	1,27	1,34	1,32
	r^2	37,7	39,6	4,5	0,0 ^{ns}	10,7	37,6	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}	0,0 ^{ns}

Onde, μ : média; σ : desvio padrão; r^2 : coeficiente de determinação em porcentagem (%). : o σ da banda corrigida é maior que o da não corrigida; : o r^2 da banda corrigida é maior que o da não corrigida; ns: o valor-p do teste F é maior que 0,05.

O desvio padrão de todas as bandas espectrais após correção diminuiu, exceto para as correções com os métodos Cosseno, S1 e SCS, os quais aumentaram o desvio padrão das amostras de algumas bandas. Nesse aspecto, esses métodos não foram eficazes para correção do efeito topográfico. Em outros estudos (GAO; ZHANG, 2009a; VINCINI; FRAZZI, 2003), a correção Cosseno e SCS também não foram eficientes para correção topográfica.

As amostras da classe milho tiveram maior redução no desvio padrão após a correção do que as de floresta. É importante salientar que o desvio padrão de uma classe é afetado (reduzido) com a remoção das variações dadas pela iluminação, sugerindo que o milho foi mais intensamente corrigido. Porém, deve-se considerar o valor do fator de correção aplicado sobre os níveis radiométricos, ou seja, o valor multiplicativo da equação de determinado método sobre os níveis radiométricos, o qual afeta o desvio padrão dos níveis radiométricos. Pode-se supor que nas áreas de floresta haveria tendência de se aumentar o desvio padrão dos níveis radiométricos com a aplicação da correção, uma vez que estas foram mais frequentes em áreas menos iluminadas, cujos fatores de correção seriam maiores que 1, com conseqüente aumento do desvio padrão. Além disso, deve-se considerar mais universalmente a variabilidade intrínseca da floresta natural, reconhecida pela textura rugosa de sua superfície. Em imagens Landsat, essa textura se caracteriza pela variabilidade espacial de seus atributos espectrais, diferentemente de outras coberturas, que tendem a ser mais uniformes. Em outras palavras, uma proporção maior do desvio padrão da floresta independe do efeito topográfico em relação a outras coberturas mais uniformes.

A correlação entre NC e fator cosseno, indicada pelo coeficiente de determinação (r^2), é alta para algumas bandas não corrigidas, principalmente as do infravermelho próximo (Tabela 4.1). Isso confirma a influência da topografia sobre os dados espectrais. Após correção topográfica, a correlação entre dados espectrais e fator cosseno foi minimizada, indicada pelo r^2 e o valor-p do teste F da análise de regressão. Os métodos S2, Minnaert, E-Stat, C e SCS+C causaram redução no r^2 para próximo de zero em todas as bandas espectrais, com valor-p maior que 0,05.

A redução do desvio padrão dos NC de determinada classe de cobertura e da correlação destes com o fator cosseno é comumente constatada e utilizada para medir a eficiência da correção topográfica. Civco (1989) identificou uma redução do desvio padrão de aproximadamente 100% em todas as bandas Landsat TM após correção. Hantson e Chuvieco (2011) obtiveram uma redução do desvio padrão de 28%, 38% e 37% após correção das bandas Landsat TM 4, 5 e 7, respectivamente. Meyer et al. (1993) perceberam uma redução do r^2 após correção, de 42%, 41% e 47% para aproximadamente 0%, sobre dados nas bandas Landsat TM 2, 4 e 5, respectivamente.

Baseado nos resultados acima, os métodos S2, Minnaert, E-Stat, C e SCS+C foram selecionados para a correção completa das bandas espectrais e para as próximas avaliações por meio do processo de classificação.

As bandas corrigidas e não corrigidas foram usadas para classificar os diferentes tipos de cobertura da terra presentes na área. Por meio de uma análise visual das bandas espectrais, todos os métodos de correção causaram redução na impressão de tridimensionalidade do terreno evidente nas bandas não corrigidas e a um melhor equilíbrio entre áreas mal e bem iluminadas. Maiores detalhes sobre esses aspectos serão apresentados na próxima seção para o método de correção C. A Figura 4.4 mostra que todas as cinco correções aumentaram os NC nas áreas mal iluminadas e diminuíram nas bem iluminadas, aumentando a uniformidade entre essas duas condições de iluminação.

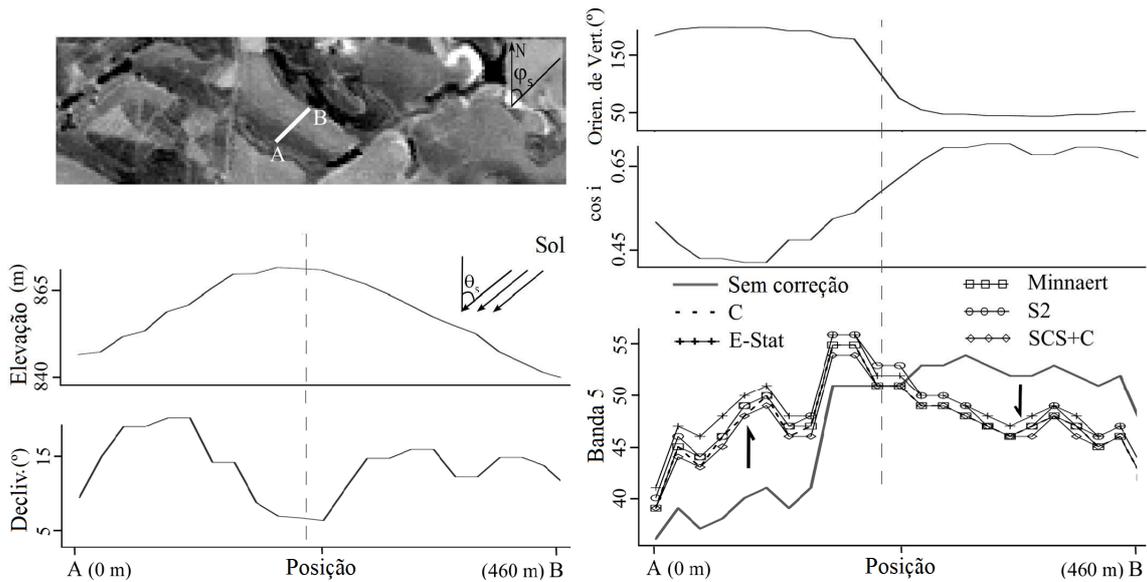


Figura 4.4 - Transecto da elevação, declividade, orientação de vertente, fator cosseno ($\cos i$) e banda 5 antes e após correção pelos métodos de correção topográfica estudados. Foram utilizadas as áreas de milho como fonte para estimativa dos parâmetros de correção.

A avaliação dos métodos de correção com a classificação mostrou que os coeficientes de concordância Kappa variaram ligeiramente entre correções, todos superiores ao Kappa da classificação sem correção (Tabela 4.2). Os resultados da comparação (por sobreposição de dados) entre classificação da imagem sem correção e as das imagens corrigidas indicam uma diferença expressiva em termos de área (Tabela 4.2). Pelo menos um quarto da área total da classificação da imagem corrigida foi diferente da sem correção, o que enfatiza o impacto da correção na classificação.

Foi realizada a estratificação da exatidão total em quatro diferentes condições de iluminação (Figura 4.5). Os resultados indicam que a exatidão é inferior nas áreas menos iluminadas (fator cosseno $< 0,52$) e nas bem iluminadas (fator cosseno $> 0,64$). Nas áreas com iluminação intermediária a exatidão é superior. Coerentemente, após correção topográfica a exatidão global aumentou principalmente nas duas condições extremas de iluminação. Ainda assim, a exatidão global após correção continua relativamente menor nas áreas pouco iluminadas. Meyer et al. (1993) utilizando o

método de classificação do paralelepípedo, constaram que as áreas bem iluminadas tiveram um expressivo aumento da exatidão após correção topográfica.

Tabela 4.2 - Resultados das classificações da imagem sem correção e corrigida pelos diferentes métodos estudados usando as classes de milho e floresta como fonte para estimativa dos parâmetros de correção

Estatística	Sem Correção	Método de correção				
		S2	Minnaert	E-Stat	C	SCS+C
Classe de cobertura fonte: Milho						
Kappa	0,82	0,87	0,91	0,86	0,91	0,91
Número médio de <i>pixels</i> por segmento	50,26	29,49	47,71	47,93	52,78	44,85
Número de folhas da árvore de decisão	10	8	9	8	9	9
Diferença (%)	0	27	28	27	26	32
Classe de cobertura fonte: Floresta						
Kappa		0,89	0,87	0,88	0,87	0,89
Número médio de <i>pixels</i> por segmento		29,14	44,91	39,69	49,53	44,37
Número de folhas da árvore de decisão		8	8	10	8	8
Diferença (%)	27	27	29	34	32	27

* Diferença, calculada com a sobreposição dos dados, da classificação com correção (área total) em relação à classificação da imagem não corrigida.

Os resultados globais apresentados até então indicam um impacto positivo da correção topográfica sobre a exatidão da classificação, confirmando os de outros estudos que abordaram outros métodos de classificação. Cuo et al. (2010) identificaram um aumento no Kappa de 0,44 para 0,81 após a correção topográfica. Conese et al. (1993) tiveram um aumento no Kappa de 0,56 para 0,62. Outros exemplos são sumarizados em Vanonckelen et al. (2013).

A correção realizada com parâmetros estimados a partir da classe floresta apresentou melhores resultados de exatidão do que aquela feita a partir da classe milho nas áreas menos iluminadas (Figura 4.5). O inverso ocorreu em áreas bem iluminadas. Isso

concorda com a distribuição das amostras de ambos os tipos de classe de cobertura, em que as amostras da classe floresta estão relativamente mais concentradas em áreas mal iluminadas e as de milho em áreas bem iluminadas (Figura 4.3). Logo, a distribuição das amostras em relação às condições de iluminação é importante para estimar os parâmetros de correção, conforme foi constatado por Reese e Olsson (2011).

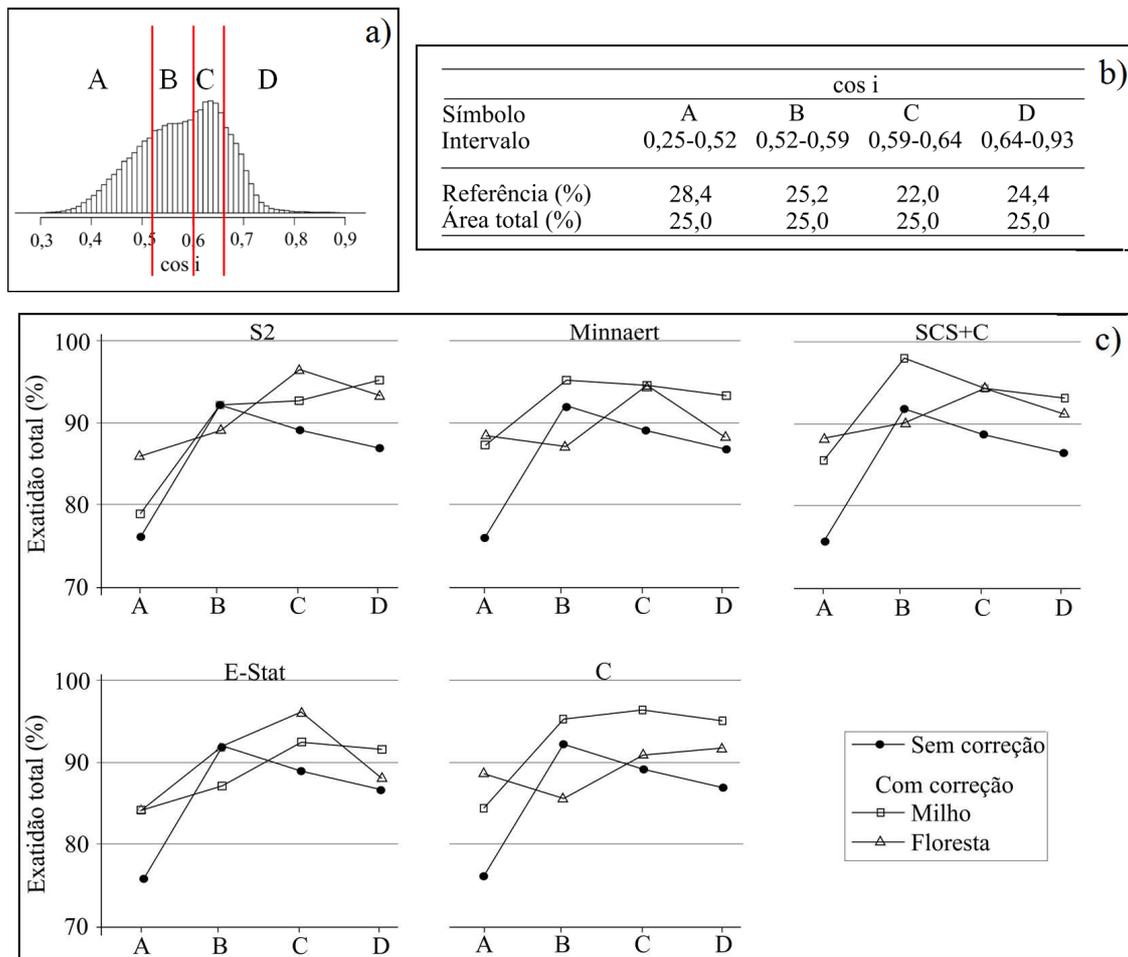


Figura 4.5 - Estratificação da exatidão da classificação por condições de iluminação: a) Condições de iluminação representadas no histograma do fator cosseno; b) Distribuição das amostras de controle e da área de estudo por condições de iluminação e; c) Exatidão da classificação (estratificada pelas condições de iluminação) da imagem sem correção e das corrigidas pelos diferentes métodos de correção utilizando as áreas de milho e floresta como fonte para estimativa dos parâmetros de correção.

As árvores de decisão geradas no processo de classificação com mineração de dados, em geral, tiveram redução no número de folhas e nós após correção topográfica (Tabela 4.2). Isso indica que as árvores se tornaram menos complexas após correção (GELFAND et al., 1989; ESPOSITO et al., 1997). A diminuição da complexidade da árvore é um fator positivo para a classificação e aponta a efetividade da correção topográfica, conforme explicado na seção 2.3.2.

O número médio de *pixels* por segmento em geral diminuiu com a correção (Tabela 4.2). A segmentação da imagem corrigida pelo método S2 teve maior impacto sobre a diminuição do tamanho dos segmentos, pois é onde há menor média de pixels por segmentos.

As características dos segmentos são resultantes de uma combinação entre homogeneidade espectral e forma dos segmentos (seção 2.3.1). A supersegmentação causada pelo método S2 pode ter relação com seu efeito sobre o desvio padrão de conjuntos de pixels adjacentes da imagem (Figura 4.6). Este método e o E-Stat apresentam desvio padrão relativamente superiores, comparando os diferentes métodos com a imagem sem correção. Diferentemente dos outros métodos de correção topográfica, a correção C causou aumento no tamanho médio dos segmentos quando seus parâmetros foram estimados com as amostras da classe milho. Por outro lado, a supersegmentação aparentemente não afetou o resultado final da classificação, conforme o índice Kappa calculado para as classificações.

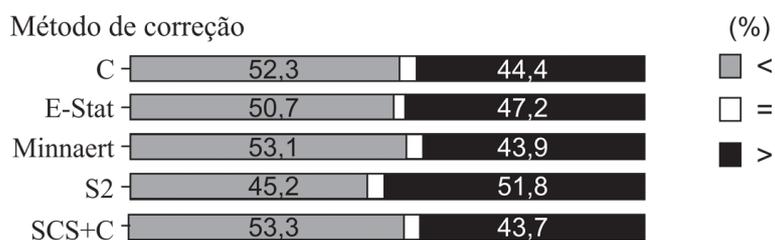


Figura 4.6 - Frequência com que o desvio padrão obtido de células adjacentes de 3x3 *pixels* mostrou-se menor, igual ou superior comparando a banda 4 corrigida pelos métodos estudados com ela não corrigida. Para as correções, utilizaram-se as áreas de milho como fonte para estimativa dos parâmetros de correção.

Conforme os resultados apresentados, os métodos C, Minnaert e SCS+C apresentaram resultados similares entre si e mais consistentes que os demais. Na avaliação de Hantson e Chuvieco (2011), por meio de outra abordagem, o método E-Stat mostrou superioridade, inclusive em relação ao C e Minnaert. Para Riaño et al. (2003) o método de correção C foi superior ao S2 e Minnaert. Já McDonald et al. (2000) obtiveram melhores resultados com o método C em relação ao Minnaert, E-Stat, Cosseno, entre outros.

4.3. Efeito da correção

Enquanto que na seção anterior procedeu-se uma avaliação geral dos métodos, aqui serão realizadas análises mais específicas e com caráter mais qualitativo utilizando um único método de correção topográfica. O método de correção C, com a classe de cobertura milho para estimativa do parâmetro c_λ (da equação do método), foi selecionado para essa etapa. Este método, quando utilizando essa classe como fonte para estimativa do parâmetro c_λ , apresentou resultados satisfatórios em todas as avaliações anteriores, principalmente em relação à exatidão da classificação e ao tamanho médio dos segmentos. Um dos fatores importantes para a escolha da classe de cobertura milho foi sua grande representatividade em termos de área e condições de iluminação, além da fenologia da cultura e sua textura aparente, que são mais homogêneas em relação às demais classes de cobertura estudadas.

4.3.1 Análise das bandas espectrais

A imagem sem correção e a com correção topográfica estão representadas na Figura 4.7. As características do relevo da cena são muito visíveis na imagem sem correção, enquanto que na corrigida o relevo deixou de ser evidente e, aparentemente a cena é mais plana. Isso indica que o efeito topográfico de fato foi minimizado com a correção, e sem perda aparente da informação espectral que distingue as classes de cobertura.

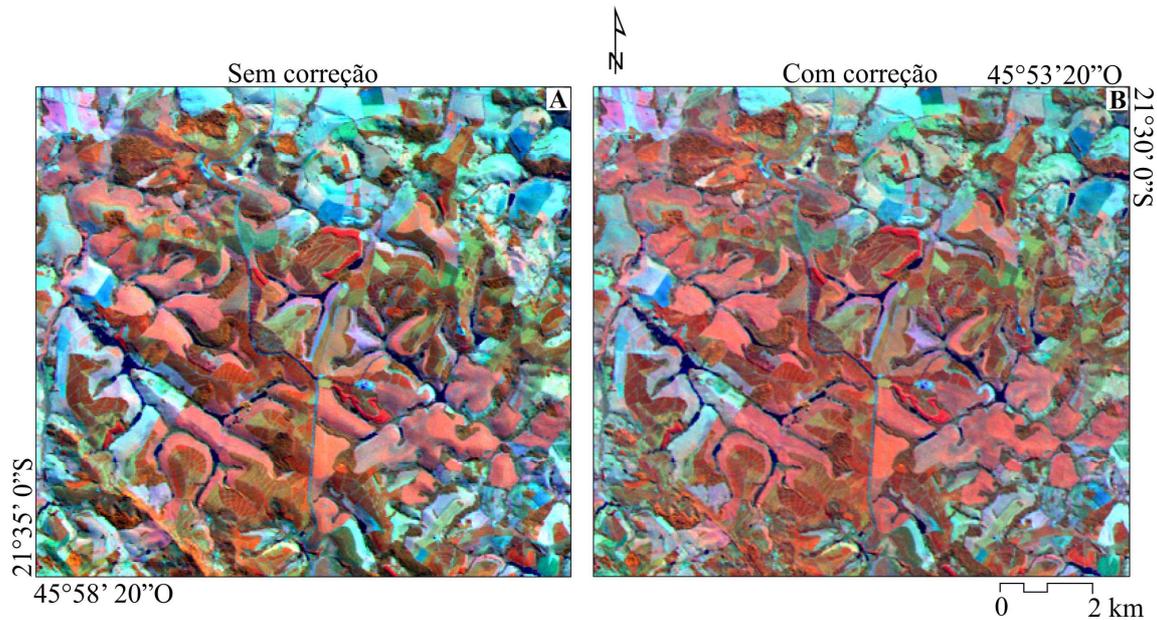


Figura 4.7 - Imagem Landsat 5 TM, composição 453 (RGB), sem (A) e com (B) correção topográfica.

A análise visual das bandas 3, 4 e 5 corrigidas, também indica diminuição do efeito topográfico das bandas individualizadas, aparentemente sem afetar as características intrínsecas da cobertura da terra (Figura 4.8).

A razão entre bandas espectrais corrigidas e não corrigidas evidencia a magnitude da correção realizada nelas (Figura 4.8). A razão menor que zero indica que a correção aumentou o nível radiométrico da banda e vice-versa. Observa-se que o aumento do nível radiométrico ocorre onde a iluminação solar é mais fraca e a diminuição acontece onde a iluminação é mais forte.

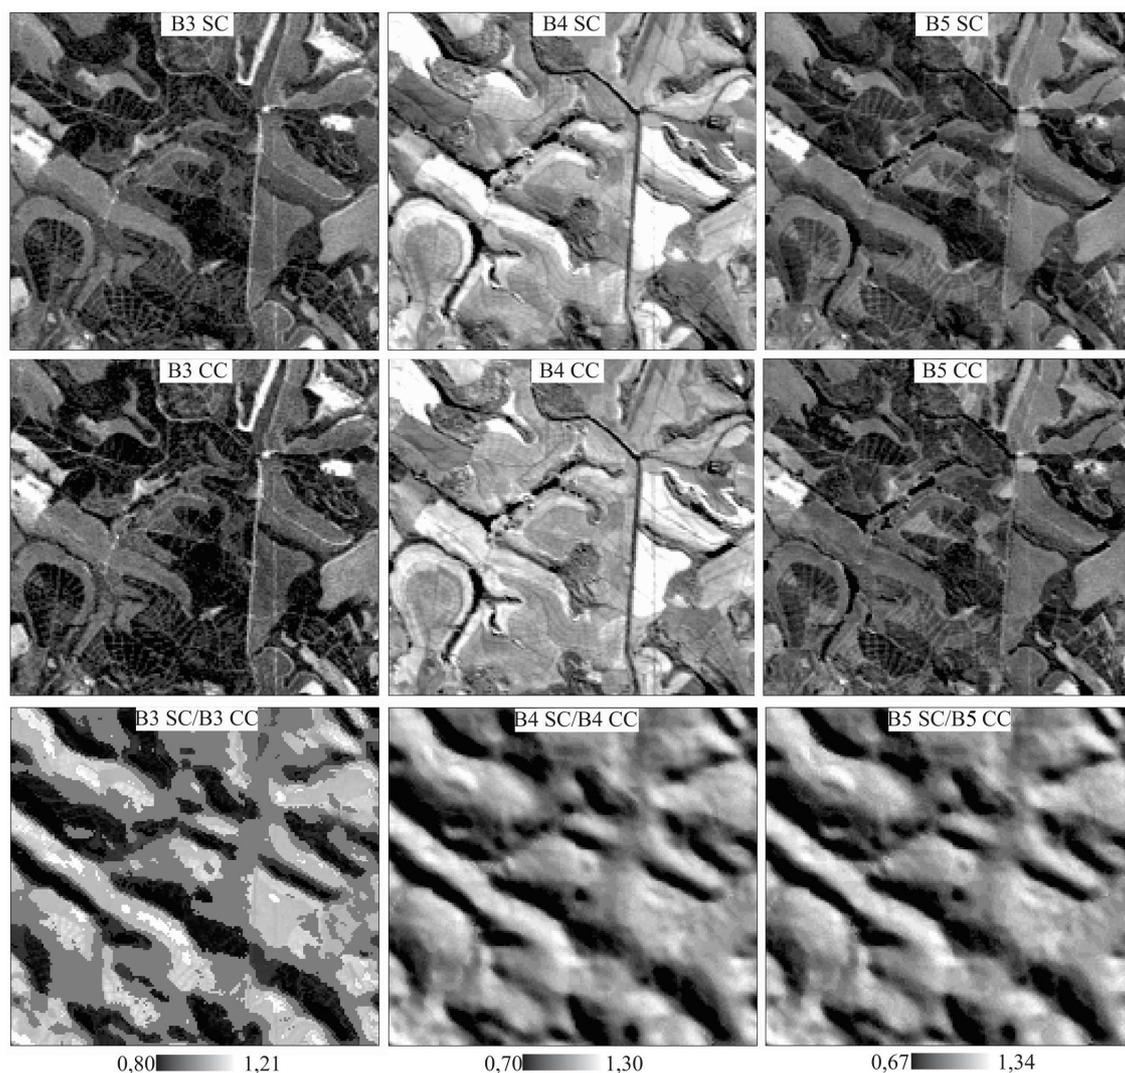


Figura 4.8 - Bandas 3, 4 e 5 sem correção (SC), com correção (CC) e razão entre SC e CC.

Os histogramas, a média e o desvio padrão das bandas espectrais antes e após correção encontram-se na Figura 4.9. Em geral, as médias antes e após correção são similares entre si. Já os desvios padrões diminuíram após correção. É observado nos histogramas que os NC menores (lado esquerdo dos histogramas) e maiores (lado direito dos histogramas) têm suas frequências reduzidas e os valores intermediários têm suas frequências aumentadas após correção. A diminuição da variância dos níveis radiométricos com a correção evidenciada pelos desvios padrões e pelos histogramas das bandas é um fator positivo da correção, indicando que o efeito topográfico foi minimizado.

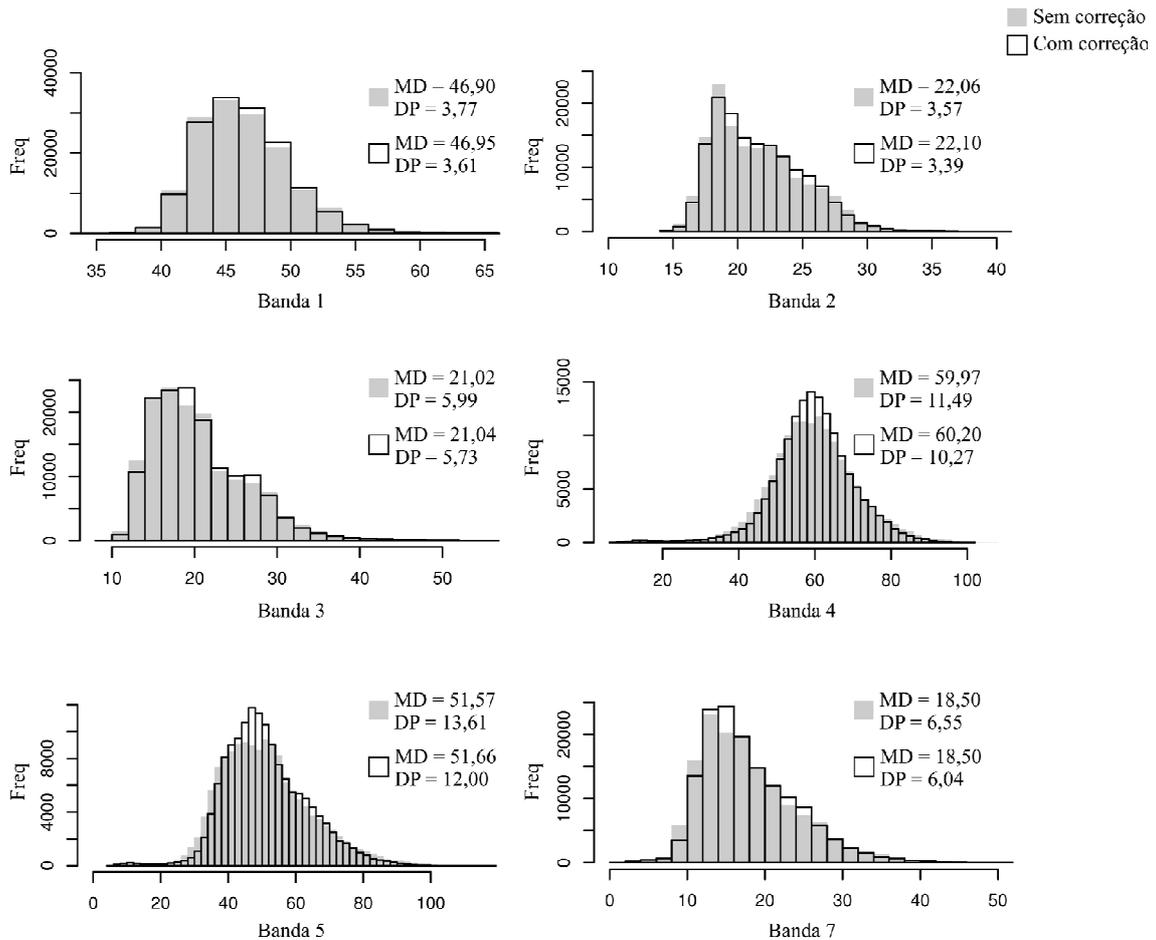


Figura 4.9 - Histogramas, médias (MD) e desvios padrões (DP) das bandas espectrais antes e após correção topográfica.

Algumas estatísticas de amostras das bandas antes e após correção para as principais classes de cobertura da área encontram-se na Tabela 4.3. A média dos NC teve uma ligeira redução após a correção topográfica para a classe de milho e solo, enquanto que para o café adulto e para a floresta a média aumentou. Esse comportamento é devido à distribuição das amostras em relação à iluminação solar (fator cosseno) (Figura 4.3). As amostras de milho e solo por estarem em regiões relativamente mais iluminadas têm suas médias radiométricas diminuídas após correção. O café e a floresta têm suas médias aumentadas por se localizarem em áreas relativamente menos iluminadas, como foi discutido na seção 4.2.

Tabela 4.3 - Média, desvio padrão e parâmetros de regressão (bandas vs. fator cosseno) de amostras das bandas Landsat 5 TM sem e com correção topográfica

Classe de cobertura	Sem correção (Com correção)					
	Banda espectral					
	1	2	3	4	5	7
	----- Média -----					
Milho	48,5 (48,2)	24,4 (24,1)	20,7 (20,4)	79,0 (77,1)	50,6 (49,2)	15,7 (15,3)
Solo	52,5 (52,4)	27,0 (26,9)	31,5 (31,5)	56,8 (57,0)	71,9 (71,5)	29,7 (29,4)
Café ad.	43,0 (43,1)	18,0 (18,1)	14,5 (14,6)	60,7 (61,6)	37,6 (38,3)	11,8 (12,0)
Floresta	43,2 (43,5)	18,1 (18,5)	14,3 (14,6)	55,6 (57,7)	38,1 (39,9)	12,1 (12,7)
	----- Desvio padrão -----					
Milho	1,83 (1,59)	1,89 (1,61)	1,65 (1,21)	9,09 (5,83)	5,94 (3,15)	2,17 (1,59)
Solo	4,07 (3,56)	3,03 (2,54)	5,87 (5,11)	8,29 (6,68)	14,37 (8,77)	7,46 (5,39)
Café ad.	1,58 (1,74)	0,91 (1,02)	1,32 (1,35)	5,95 (4,04)	4,22 (3,41)	1,69 (1,57)
Floresta	1,79 (1,72)	1,02 (1,03)	1,22 (1,24)	8,47 (6,67)	4,86 (3,54)	1,61 (1,35)
	----- Coeficiente de determinação (r ²) em % - bandas vs. fator cosseno -----					
Milho	28,8 (0,1 ^{ns})	32,5 (0,3 ^{ns})	48,8 (0,2 ^{ns})	57,8 (0,0 ^{ns})	72,6 (0,1 ^{ns})	48,7 (0,0 ^{ns})
Solo	28,0 (8,3)	30,4 (2,4 ^{ns})	27,0 (6,0)	35,1 (1,2 ^{ns})	70,8 (25,1)	59,6 (27,3)
Café ad.	0,6 ^{ns} (13,0)	8,6 (19,8)	6,1 (8,5)	54,0 (0,1 ^{ns})	38,0 (3,3)	24,4 (0,9 ^{ns})
Floresta	13,8 (0,8 ^{ns})	21,6 (8,4)	14,8 (5,7)	44,6 (2,1 ^{ns})	52,2 (0,5 ^{ns})	37,7 (1,4 ^{ns})

ns: valor-p do teste F da análise de regressão é não significativo (ou maior que 0,05).

O coeficiente de determinação (r^2) é alto principalmente para as bandas do infravermelho, indicando uma relação de dependência entre NC e fator cosseno (Tabela 4.3). Nas bandas do visível essa relação é mais fraca, talvez devido ao maior efeito de espalhamento atmosférico nestas bandas espectrais (SLATER, 1980), mascarando o efeito topográfico.

O desvio padrão das amostras e o r^2 em geral são reduzidos após correção (Tabela 4.3). Isso indica a eficácia da correção do efeito topográfico, diminuindo as variações espectrais causadas pelas características da topografia (RIAÑO et al., 2003). No entanto, é evidente após correção uma redução maior do desvio padrão e do r^2 para a classe de cobertura milho em relação às demais classes. Pode-se considerar que a correção foi mais eficiente para esta classe que para as demais. Essa classe foi favorecida pelo fato de ter sido usada para estimativa do parâmetro de correção c_λ do método de correção C. Isso sugere certa dependência do parâmetro de correção em

relação ao tipo de cobertura da terra, o que foi relatado por outros autores (CIVCO, 1989; MCDONALD, 2000; TEILLET et al., 1982).

A primeira componente principal (PCA1), obtida antes e após correção das bandas espectrais encontram-se na Figura 4.10. A Figura 4.11 apresenta o diagrama de dispersão e parâmetros da análise de regressão linear entre PCA1 e fator cosseno realizada com amostras da classe de cobertura milho (Figura 4.3). São percebidas as características da topografia na PCA1 sem correção, o que não é evidente na PCA1 com correção. A análise de regressão demonstra que 60% das variações das amostras de milho são explicadas pelo fator cosseno na PCA1 sem correção. Após correção este valor é reduzido para 0%. Esses resultados reforçam a intensidade do efeito topográfico nas bandas espectrais e a eficiência de sua correção pela metodologia abordada.

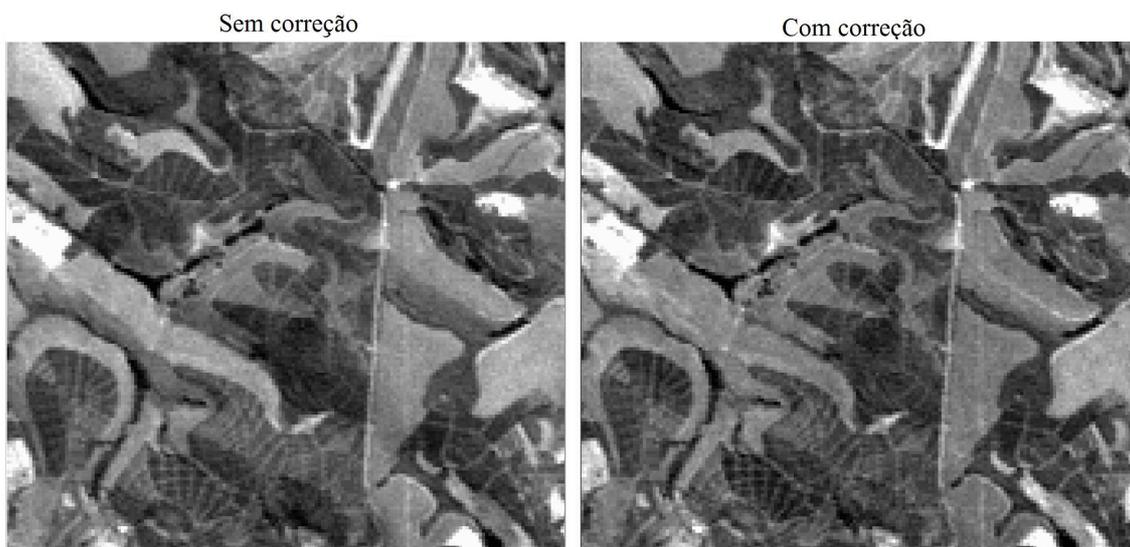


Figura 4.10 - Primeira componente principal (PCA1), gerada antes e após correção topográfica das bandas espectrais.

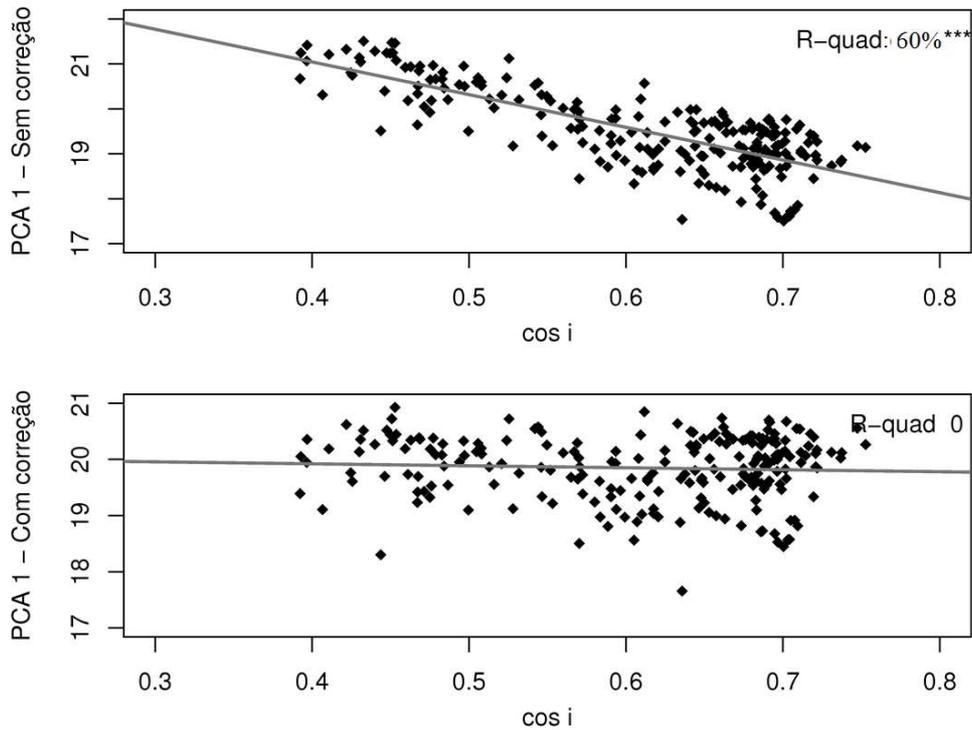


Figura 4.11 - Diagramas de dispersão entre primeira componente principal (PCA1), gerada antes e após correção topográfica das bandas espectrais, e fator cosseno ($\cos i$). *** O valor-p do teste F da análise de regressão é menor que 0,01.

4.3.2 Análise da classificação do uso e cobertura da terra

Foram geradas três classificações do uso e cobertura da terra conforme explicado na metodologia: classificação da imagem sem correção topográfica (classificação sem correção), classificação da imagem corrigida (classificação com correção) e classificação utilizando dados sem e com correção (classificação mista). A segmentação da classificação mista foi realizada somente com as bandas não corrigidas, mas a mineração de dados para gerar a árvore de decisão foi realizada com atributos de ambas as imagens, sem e com correção topográfica.

As classificações (somente a sem e a com correção) do uso e cobertura da terra e as respectivas áreas em porcentagem de suas classes apresentam-se na Figura 4.12. A classe solo é a mais representativa em termos de área, com cerca de 30 e 29% da área nas classificações sem e com correção, respectivamente. Essa proporção é devido à

classe solo incluir solo arado, solo com palha seca e áreas de pastagens. A área de milho que ocupa 16% da área na classificação sem correção, representa 19% na classificação com correção. Essa variação de 16 para 19% equivale a aproximadamente 18% de diferença em termos de área total da classe milho nas duas classificações.

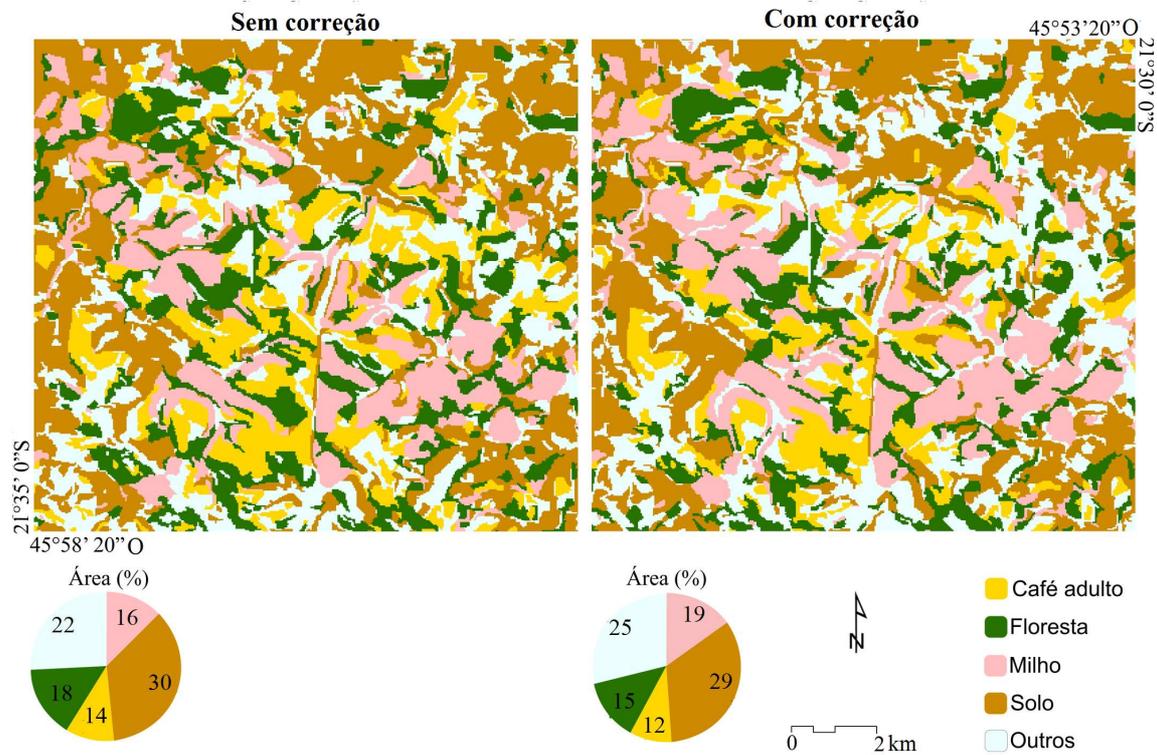


Figura 4.12 - Classificação do uso e cobertura da terra da imagem sem correção e da com correção, e suas respectivas áreas em porcentagem.

O mapeamento e a quantificação das diferenças existentes entre classificação sem e com correção indicam que em 26% da área as duas classificações são diferentes (Figura 4.13). Portanto, as duas classificações alcançaram um nível de diferença bastante significativo em termos de área, o que demonstra que o efeito topográfico e sua correção são importantes para a classificação.

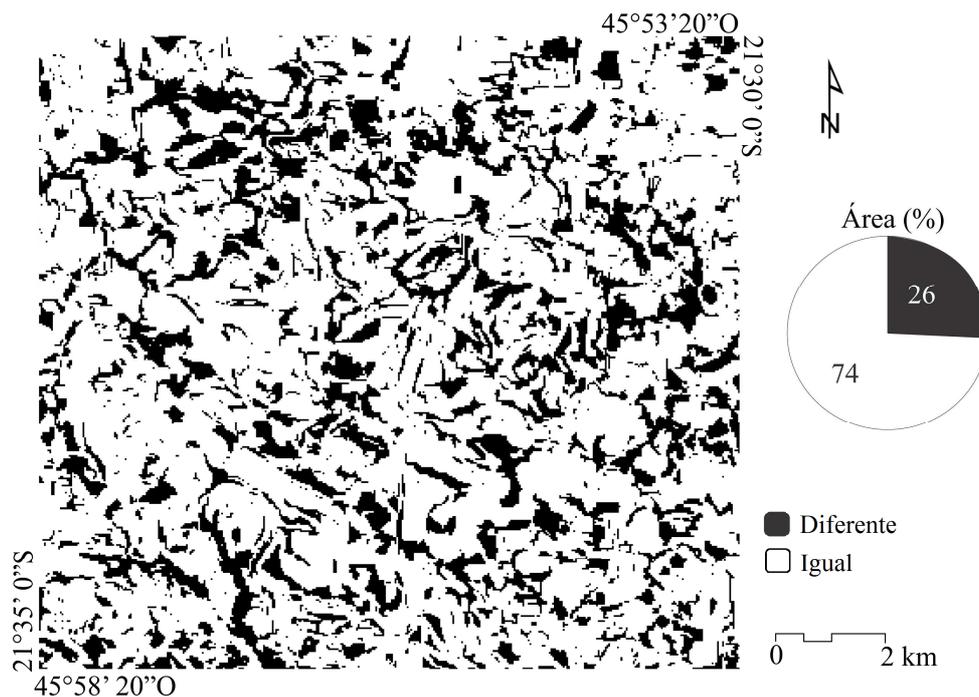


Figura 4.13 - Distribuição e quantificação das áreas onde a classificação da imagem sem correção é diferente da classificação da imagem com correção.

A matriz de confusão entre classificação sem e com correção topográfica (a matriz foi elaborada com base em toda a área de estudo) indica as confusões existentes entre essas duas classificações para cada classe de cobertura analisada. Nota-se que, tomando como referência a classificação com correção, a classe milho é mais confundida com a classe floresta do que com as demais classes, enquanto que, a floresta foi confundida mais frequentemente com café adulto (Tabela 4.4).

Tabela 4.4 - Matriz de confusão que relaciona a área total (em porcentagem) da classificação da imagem sem correção com a da classificação da imagem com correção

CLASSIFICAÇÃO		C/ correção					TOTAL
		Cafê ad.	Floresta	Milho	Solo	Outros	
S/ correção	Cafê ad.	8,6	2,3	0,6	0,1	2,4	14,1
	Floresta	1,8	11,4	2,1	0,3	2,6	18,0
	Milho	0,2	0,4	14,1	0,5	0,4	15,6
	Solo	0,0	0,2	1,4	24,2	4,2	30,1
	Outros	1,2	1,0	0,5	3,8	15,7	22,2
	TOTAL	11,9	15,3	18,6	28,9	25,3	100,0

Exatidão Global: 74%

A representação em detalhe das classificações sem e com correção e as imagens Landsat TM 453 utilizadas para ambas às classificações encontram-se na Figura 4.14. A seta 1 evidencia uma diferença entre as duas classificações: na classificação sem correção observa-se que uma área de milho (com iluminação solar fraca) foi classificada erroneamente como floresta, e na classificação com correção essa confusão não ocorreu. A seta 2 aponta para o mesmo tipo de erro da 1. Já a seta 3 mostra uma área de café jovem, pouco iluminado, que foi classificada como café adulto na sem correção, no entanto na com correção foi corretamente classificada. Na seta 4 observa-se que há um aumento do detalhamento da classificação após correção topográfica.

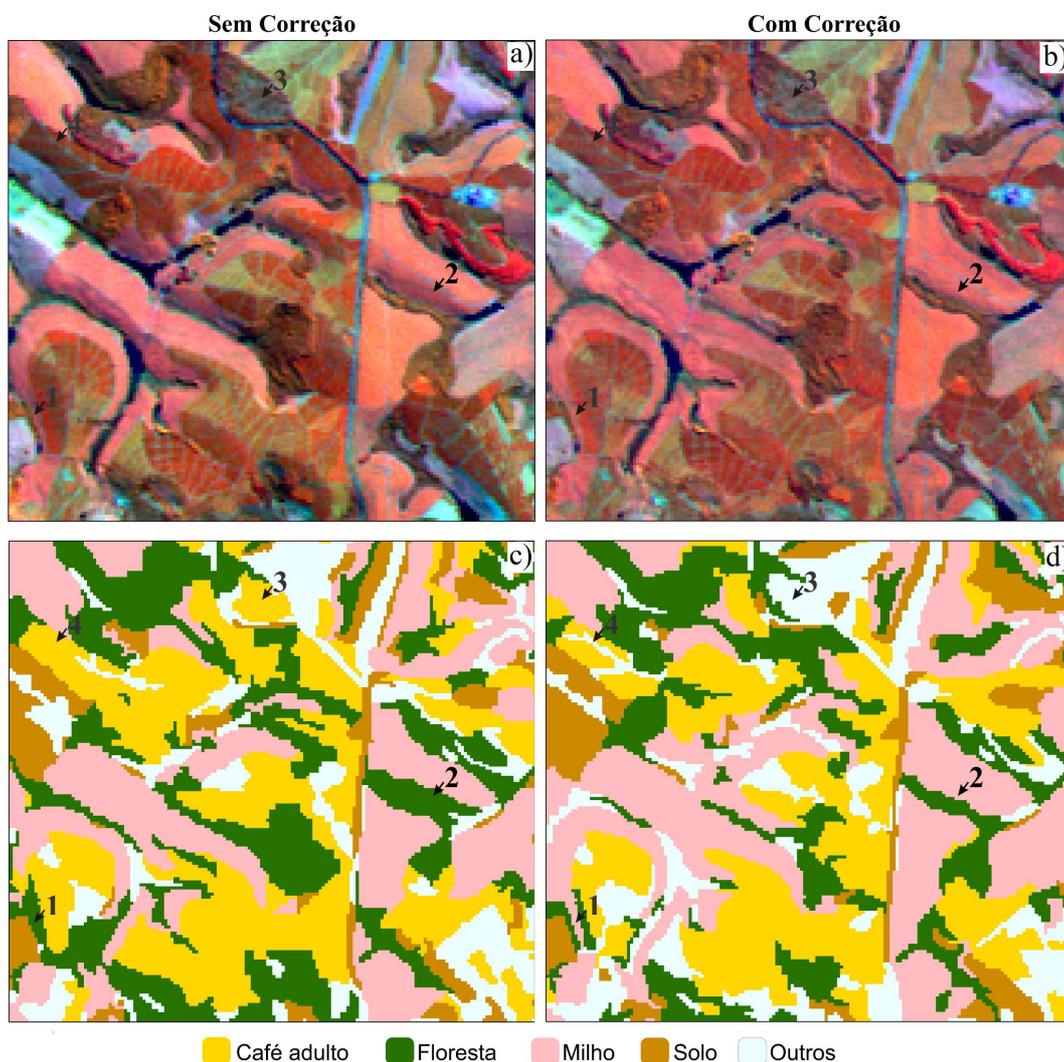


Figura 4.14 - Representação da área em detalhe para apontar diferenças na classificação sem correção e na com correção topográfica: a) Imagem sem correção; b) Imagem corrigida; c) Classificação da imagem sem correção e; d) Classificação da imagem com correção.

As árvores de decisão da classificação sem e com correção são apresentadas nas Figuras 4.15. A sem correção possui 9 nós e 10 folhas, e a com correção 8 nós e 9 folhas. O nó e a folha que a árvore sem correção possui a mais é responsável pela distinção de café adulto, floresta e “outros”, ou seja, foi necessário um atributo a mais para classificá-los. Além disso, as árvores diferenciam-se em relação a alguns atributos presentes nos nós. O atributo CVB4 (coeficiente de variação da banda 4), MediaB4 e B7/B3 estão presentes somente na árvore sem correção, e Wetness e B5/B4 somente na com correção.

Em relação ao valor-p presente nos nós das árvores de decisão, nota-se que existem na árvore de decisão sem correção valores que se aproximam de 0,05, que é o valor máximo estabelecido para que ocorra a partição que resulta em dois nós ou folhas. Na árvore de decisão com correção, todos os valor-p são menores ou iguais a 0,01, enquanto que na sem correção existem quatro nós que possuem valor-p maiores que 0,01. Portanto, pode-se considerar que existe maior nível de impureza em alguns nós da árvore sem correção em relação à com correção, o que pode significar maiores confusões entre classes de cobertura da terra.

A árvore de decisão mista, que foi realizada com atributos de ambas as imagens sem e com correção, está representada na Figura 4.16. Pelo processo de mineração de dados foram selecionados (automaticamente) somente atributos da imagem corrigida, ainda que a segmentação tenha sido conduzida somente com a imagem sem correção. Isso significa que os dados corrigidos foram eleitos como mais apropriados para a classificação do que os não corrigidos.

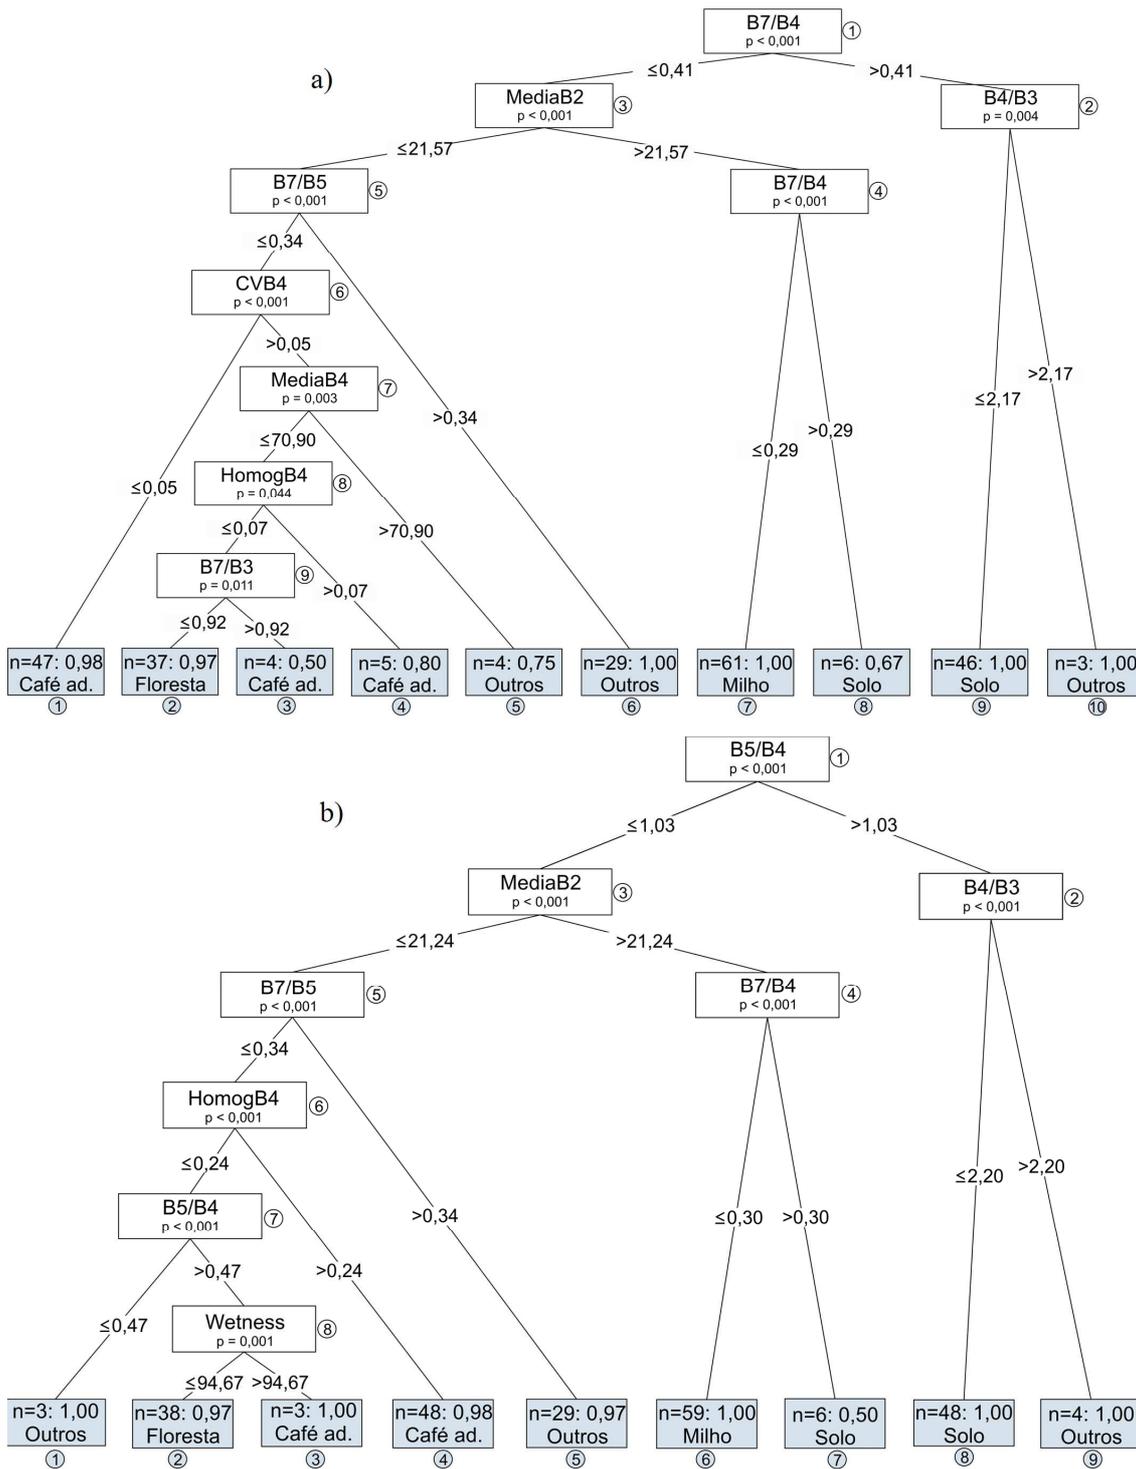


Figura 4.15 - Árvores de decisão da classificação: a) da imagem sem correção; e b) da imagem com correção.

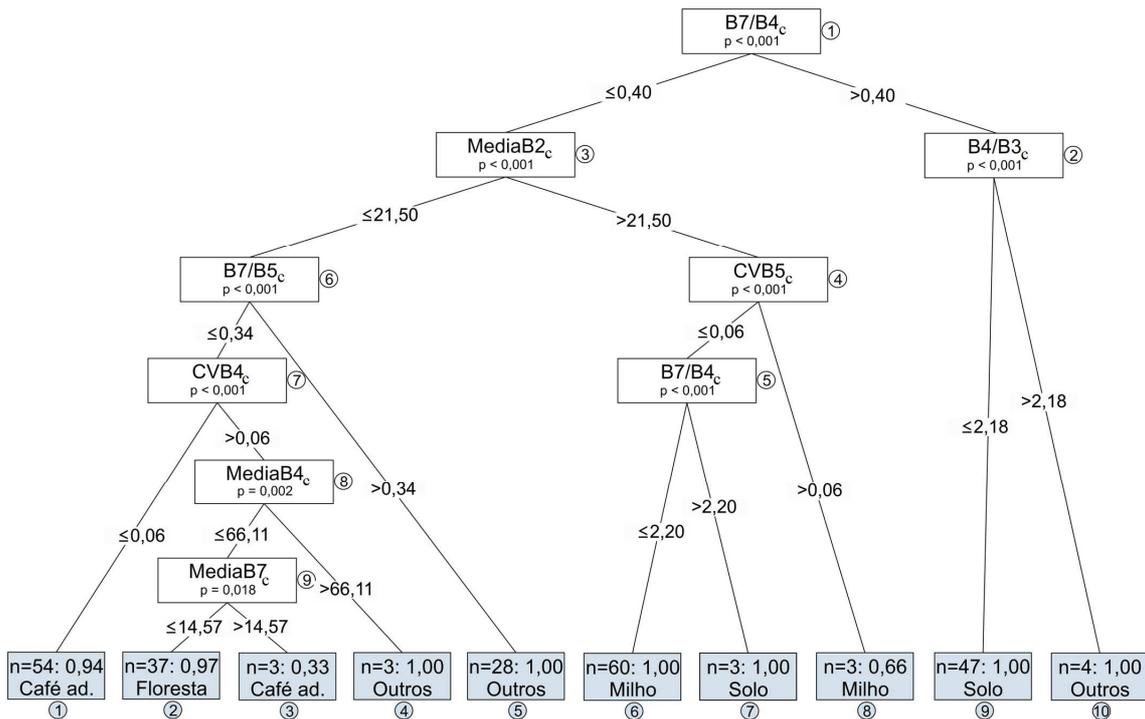


Figura 4.16 - Árvore de decisão da classificação cuja segmentação foi realizada com as bandas sem correção topográfica e a mineração de dados com atributos de todas as bandas, sem e com correção. Todos os atributos selecionados pela mineração presentes na árvore são das bandas corrigidas.

As matrizes de confusão da classificação sem correção, da com correção e da mista apresentam-se na Tabela 4.5. Pela observação das diagonais das matrizes observa-se que ocorreu maior confusão entre classes de uso e cobertura da terra para a classificação sem correção. Houve maior quantidade de acertos para todas as classes da classificação com correção em relação a sem correção, com exceção da classe solo, que foi igual para ambas às classificações.

Por uma análise detalhada das matrizes das classificações sem e com correção, percebe-se que a maior confusão ocorreu para a classe de café adulto. Essa classe foi confundida principalmente com a classe floresta. Apesar de essa confusão ter sido reduzida após correção topográfica, ela permaneceu relativamente alta comparando com as demais classes. Talvez isto possa ser explicado pela relativa similaridade espectral existente entre café e floresta, que não pôde ser minimizada com a correção do efeito topográfico.

Tabela 4.5 - Matrizes de confusão da classificação da imagem sem correção, classificação da imagem com correção e da classificação cuja segmentação foi realizada com as bandas sem correção topográfica e a mineração de dados com atributos de todas as bandas sem e com correção (classificação mista)

Classificação	Referência					
	Milho	Solo	Café ad.	Floresta	Outros	TOTAL
Classificação sem correção						
Milho	44	0	0	0	0	44
Solo	0	48	0	0	1	49
Café ad.	3	0	37	6	1	47
Floresta	3	0	9	41	4	57
Outros	0	2	4	3	44	53
Exatidão Global: 86%					Índice Kappa: 0,82	
Classificação com correção						
Milho	50	0	0	0	0	50
Solo	0	48	0	0	2	50
Café ad.	0	0	41	1	2	44
Floresta	0	0	6	47	1	54
Outros	0	2	3	2	45	52
Exatidão Global: 92%					Índice Kappa: 0,91	
Classificação mista						
Milho	49	3	0	1	1	54
Solo	0	45	0	0	0	45
Café ad.	0	0	38	5	3	46
Floresta	1	0	7	42	2	52
Outros	0	2	5	2	44	53
Exatidão Global: 87%					Índice Kappa: 0,84	
TOTAL	50	50	50	50	50	250

No que diz respeito à matriz de confusão mista, percebe-se redução da confusão somente em relação à matriz sem correção; em relação à com correção ocorreu aumento da confusão para todas as classes. Comparando as diagonais das matrizes mista e sem correção, a confusão da classe solo aumentou com a correção e para a classe “outros” a confusão é a mesma. A exatidão total e o índice de concordância Kappa demonstram as diferenças gerais entre as classificações sem correção, com correção e mista, que podem ser vistos na última linha das matrizes de confusão (Tabela 4.5).

Pela comparação das três classificações pelas matrizes de confusão presume-se que uma parte dos erros da classificação foi proveniente do processo de segmentação da imagem não corrigida: os atributos das bandas corrigidas calculados e incluídos na classificação mista não foram suficientes para diminuir a quantidade de erros a uma posição equivalente à da classificação com correção. Supõe-se que a segmentação da imagem sem correção topográfica não gera segmentos, ou objetos, que representam completamente uma determinada classe de uso ou cobertura. Isso também se notifica pelo tamanho médio dos segmentos, que aumentou considerando as classes de cobertura antes e após a correção do efeito topográfico (Figura 4.17).

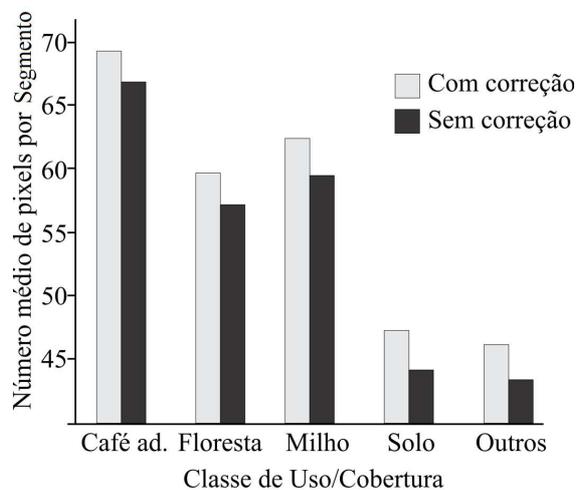


Figura 4.17 - Tamanho médio dos segmentos por classe de cobertura resultantes das classificações da imagem sem correção e da com correção topográfica.

O resultado da avaliação dos Kappa das classificações sem e com correção pelo método de Monte Carlo é apresentado na Tabela 4.6. Pode-se afirmar que o Kappa da classificação com correção é significativamente superior ao da classificação sem correção, com intervalo de credibilidade de 95%. Há um aumento de 0,1 no valor do Kappa, indicado por um número de 10.000 simulações.

Tabela 4.6 - Diferença entre Kappa das classificações com e sem correção topográfica obtida pelo método de Monte Carlo utilizando 10.000 simulações

Mínimo	Mediana	Máximo	Intervalo de Credibilidade (95%)	
			Mínimo	Máximo
-0,1	0,1	0,24	0,06	0,17

4.4 Considerações gerais

Embora os estudos que fornecem bases para o tratamento do efeito topográfico sobre imagens de satélite tenham sido desenvolvidos desde as primeiras observações orbitais, as condições tecnológicas atuais tornam oportunas as pesquisas voltadas à sua aplicação. Pode-se listar a multiplicidade dos recursos de sistemas de informação geográfica como fatores de constante evolução. Por outro lado, no estado atual de difusão e acesso ao uso de imagens, a perspectiva de operacionalização dos procedimentos de correção do efeito topográfico foi especialmente favorecida com a oferta de modelos digitais de elevação em ampla cobertura. Este contexto justifica, assim como possibilitou a este estudo, o desenvolvimento das seguintes contribuições principais:

- a) Uma fundamentação teórica sobre o efeito topográfico e, principalmente, sobre a correção topográfica abordando formas de aplicação de métodos de correção, avaliação da correção e efeitos sobre a classificação do uso e cobertura da terra;
- b) A aplicação e avaliação de um conjunto amplo de métodos de correção topográfica, com uma abordagem um pouco diferenciada da encontrada na literatura. Essa diferenciação é elucidada nos itens abaixo e na publicação Moreira e Valeriano (2014);
- c) A aplicação de vários métodos de correção semiempíricos adotando como estratégia a estimativa de seus parâmetros com base em uma única classe de cobertura (classe de cobertura principal) como alternativa para aplicação dos métodos onde não há um mapa de uso e cobertura prévio;
- d) A avaliação da correção considerando o impacto da correção na classificação do uso e cobertura da terra utilizando OBIA. Nesse âmbito foi utilizado a matriz de confusão, o tamanho médio dos segmentos e a análise visual dos segmentos classificados (ou objetos);
- e) A avaliação da correção considerando a estrutura da árvore de decisão gerada por mineração de dados. Na árvore de decisão foram analisados o número de nós e folhas, critério de divisão e valor-p da divisão;
- f) O efeito da correção topográfica sobre a análise de componente principal (PCA).

A correção do efeito topográfico resultou em melhorias sensíveis para o processamento de imagens, principalmente para a classificação do uso e cobertura da terra. Espera-se que a correção topográfica tenha também efeitos positivos sobre outros processamentos de imagens de áreas com relevo irregular, como para a estimativa de parâmetros biofísicos (HUDAK; WESSMAN, 1998) e sua correlação com índices obtidos com bandas espectrais (por exemplo, NDVI).

Em várias etapas desse estudo foi discutido o nível de eficácia que a correção alcançou considerando as análises abordadas. Considera-se que as metodologias de correção topográfica têm potencial para atingir níveis de eficiência mais altos em trabalhos futuros. Apontam-se algumas fontes potenciais de limitações ao desempenho da correção:

- a) Registro - o deslocamento geométrico entre os diferentes planos de informação deve ser reduzido.
- b) Escala dos dados - as escalas, ou resolução espacial, das variáveis topográficas e espectrais devem ser compatíveis entre si o quanto for possível.
- c) Método de correção - a eficiência da correção varia com o método aplicado.
- d) Metodologia de aplicação da correção (para os métodos semiempíricos) - a amostragem e a estratégia de aplicação da correção (seção 2.2.2) têm implicações sobre a eficiência da correção.

Em trabalhos posteriores, de avaliação da correção topográfica utilizando OBIA com dados sem/com correção topográfica, recomenda-se também considerar a possibilidade do uso de diferentes parâmetros de segmentação para dados com e sem correção. Para maior facilidade de comparação, foram utilizados neste estudo parâmetros iguais para todos os dados.

A metodologia de aplicação dos métodos analisados mostrou-se satisfatória para correção topográfica das diversas classes de cobertura estudadas. No entanto, os resultados referentes à classe de cobertura principal, aquela utilizada para estimativa dos parâmetros de correção, foram mais proeminentes. Portanto, o uso dessa metodologia de aplicação é mais apropriada para trabalhos cujo objetivo seja a caracterização de uma única classe de cobertura, isto é, da classe principal.

Por fim, considera-se que há a necessidade de estudos de avaliação que contemplem as diferentes estratégias de aplicação descritas na seção 2.2.2. Nesse sentido, outras questões poderão ser respondidas mais precisamente, tais como: as limitações de cada estratégia e, em quais situações cada estratégia é mais recomendável.

5 CONCLUSÕES

Os resultados obtidos com a metodologia desenvolvida nesse estudo reiteram que a topografia impõe efeitos radiométricos em imagens óticas de satélite e que alguns métodos de correção são propícios para sua correção e têm impactos positivos na classificação do uso e cobertura da terra. Com este estudo é possível concluir que:

- A redução da variância dos dados radiométricos e da correlação entre dados espectrais e ângulo de incidência solar na superfície (descrito pelo fator cosseno) foram confirmadas com a correção topográfica para alguns métodos avaliados, indicando que o efeito topográfico foi reduzido.
- Os métodos S2, Minnaert, E-Stat, C e SCS+C mostraram superioridade em relação aos métodos S1, SCS, Ad2S e Cosseno. Estes últimos apresentaram resultados inferiores inclusive em relação aos dados não corrigidos para algumas bandas espectrais do visível.
- Os métodos Minnaert, C e SCS+C foram similares entre si e superiores aos métodos S2 e E-Stat. Todas as correções realizadas com esses cinco métodos resultaram em classificações mais exatas e, em geral, com árvores de decisão menos complexas comparadas com a da classificação da imagem sem correção.
- Os resultados da comparação (por sobreposição espacial de dados) entre classificação da imagem sem correção topográfica e a da imagem com correção foram expressivamente diferentes em termos de área total, variando de 26% a 34% dependendo do método de correção.
- O tamanho médio dos segmentos diminuiu após correção topográfica, exceto para a correção C. O método S2 foi o que causou maior diminuição no tamanho médio dos segmentos. Os resultados também demonstram que este foi o método que mais aumentou o desvio padrão integrado em janelas de 3 por 3 *pixels* em relação aos dados não corrigidos.
- Na classificação da imagem não corrigida, ocorreu maior confusão em áreas com iluminação solar fraca. Após correção ocorreu um considerável aumento da exatidão nessas áreas.
- A mineração de dados com bandas originais e corrigidas apontou sistematicamente as últimas como mais adequadas para a classificação.

REFERÊNCIAS BIBLIOGRÁFICAS

ALFAYA, F. A. V. S. **Mapeamento de áreas alagáveis da calha Solimões/Amazonas utilizando análise de imagens baseada em objeto com dados MDE-SRTM**. 2012. 59p. (sid.inpe.br/mtc-m19/2012/04.10.11.22-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3BMAAGH>>. Acesso em 23 out. 2013.

APARICIO, N.; VILLEGAS, D.; ROYO, C.; CASADESUS, J.; ARAUS, J. L. Effect of sensor view angle on the assessment of agronomic traits by ground level hyper-spectral reflectance measurements in durum wheat under contrasting Mediterranean conditions. **International Journal of Remote Sensing**, v. 25, n. 6, p. 1131-1152, 2004. doi: 10.1080/0143116031000116967.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: ANGEWANDTE GEOGRAPHISCHE INFORMATIONSVERARBEITUNG, 12., 2000, Heidelberg, Germany. **Proceedings...** Heidelberg: Wichmann-Verlag, 2000. p. 2-23. Disponível em: <www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf>. Acesso em: 05 jul. 2013.

BALTHAZAR, V.; VANACKER, V.; LAMBIN, E. F. Evaluation and parameterization of ATCOR3 topographic correction method for forest cover mapping in mountain areas. **International Journal of Applied Earth Observation and Geoinformation**, v. 18, p. 436-450, 2012. doi: 10.1016/j.jag.2012.03.010.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, p. 239-258, 2004. doi: 10.1016/j.isprsjprs.2003.10.002.

BISHOP, M. P.; COLBY, J. D. Anisotropic reflectance correction of SPOT-3 HRV imagery. **International Journal of Remote Sensing**, v. 23, n. 10, p. 2125-2131, 2002. doi: 10.1080/01431160110097231.

BISHOP, M. P.; SHRODER, J. F.; COLBY, J. D. Remote sensing and geomorphometry for studying relief production in high mountains. **Geomorphology**, v. 55, p. 345-361, 2003.

BIVAND, R.; KEITT, T.; ROWLINGSON, B. **RGDAL**: bindings for the geospatial data abstraction library. Pacote R versão 0.8-10. Disponível em: <<http://CRAN.R-project.org/package=rgdal>>. Acesso em: 20 de out. 2013.

BIVAND, R., LEWIN-KOH, N. **Maptools**: tools for reading and handling spatial objects, pacote R versão 0.8-25. Disponível em: <<http://CRAN.R-project.org/package=maptools>>. Acesso em: 20 de out. 2013.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 2-16, 2010. doi: 10.1016/j.isprsjprs.2009.06.004.

BLESIOUS, L.; WEIRICH, F. The use of the minnaert correction for land-cover classification in mountainous terrain. **International Journal of Remote Sensing**, v. 26, p. 3831-3851, 2005. doi: 10.1080/01431160500104194.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and regression trees**. New York: Chapman and Hall, 1984.

BREUNIG, F. M.; GALVÃO, L. S.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Variation of MODIS Reflectance and Vegetation Indices with Viewing Geometry and Soybean Development. **Anais da Academia Brasileira de Ciências**, v. 84, n. 2, p. 263-274, 2012.

CIVCO, D. Topographic normalization of landsat thematic mapper digital imagery. **Photogrammetric Engineering & Remote Sensing**, v. 55, p. 1303-1309, 1989.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-40, 1960.

COLBY, J. D. Topographic normalization in rugged terrain. **Photogrammetric Engineering & Remote Sensing**, v. 57, n. 5, p. 531-537, 1991.

CONESE, C.; GILABERT, M. A.; MASELLI, F.; BOTTAI, L. Topographic normalization of TM scenes through the use of an atmospheric correction method and digital terrain models. **Photogrammetric Engineering and Remote Sensing**, v. 59, p. 1745-1753, 1993.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and Practices**. 2. ed. Boca Raton: CRC Press, 2009. 183p.

CUO, L.; VOGLER, J. B.; FOX, J. M. Topographic normalization for improving vegetation classification in a mountainous watershed in Northern Thailand. **International Journal of Remote Sensing**, v. 31, n. 11, p. 3037-3050, 2010. doi: 10.1080/01431160903154333.

DEFINIENS. **eCognition developer 8 user guide**. Munich: Definiens, 2009. 236p.

DOZIER, J.; MARKS, D. Snow mapping and classification from Landsat Thematic Mapper data. **International Glaciological Society**, v. 9, p. 97-103, 1987.

DUBAYAH, R.; DOZIER, J.; DAVIS, F. Topographic distribution of clear-sky radiation over the Konza Prairie, Kansas. **Water Resources Research**, v. 26, p. 679-690, 1990. doi: 10.1029/WR026i004p00679.

DUBAYAH, R.; RICH, P. M. Topographic solar radiation models for GIS. **International journal geographical information systems**, v. 9, n. 4, p. 405-419, 1995. doi: 10.1080/02693799508902046.

EKSTRAND, S. Landsat TM-Based Forest Damage Assessment: Correction for Topographic Effects. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 2, p. 151-161, 1996.

Earth Remote Sensing Data Analysis Center (ERSDAC). **ASTER global DEM validation summary report**. Tóquio: ERSDAC, 2009. 28 p. Disponível em: <<http://gdem.ersdac.jspacesystems.or.jp>>. Acesso em: 20 fev. de 2014.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: Embrapa Solos, 2006. 306p. ISBN: (978-85-7035-198-2).

ESPOSITO, F.; MALERBA, D.; SEMERARO, G. A Comparative analysis of methods for pruning decision trees. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 19, n. 5, p. 476-491, 1997.

GALVÃO, L. S.; ROBERTS, D. A.; FORMAGGIO, A. R.; NUMATA, I.; BREUNIG, F. M. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. **Remote Sensing of Environment**, v. 113, n. 4, 846-856, 2009. doi: 10.1016/j.rse.2008.12.010.

GAO, Y.; ZHANG, W. A simple empirical topographic correction method for ETM+ imagery. **International Journal of Remote Sensing**, v. 30, n. 9, p. 2259-2275, 2009a. doi: 10.1080/01431160802549336.

GAO, Y.; ZHANG, W. LULC Classification and topographic correction of Landsat-7 ETM+ imagery in the Yangjia River Watershed: the influence of DEM resolution. **Sensors**, v. 9, p. 1980-1995, 2009b. doi: 10.3390/s90301980.

GELFAND, S. B; RAVISHANKAR, C. S; DELP, E. J. An iterative growing and pruning algorithm for classification tree design. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 13, p. 163- 174, 1989.

GU, D.; GILLESPIE, A. Topographic normalization of Landsat TM images of forest based on subpixel sun-canopy-sensor geometry. **Remote Sensing of Environment**, v. 64, p. 166-175, 1998.

HAN, J.; KAMBER, M. **Data mining: concepts and techniques**. 2. ed. San Francisco: Morgan Kaufmann, 2006. 743p. ISBN: (978-1-55860-901-3).

HANSEN, M. C., LOVELAND, T. R. A review of large area monitoring of land cover change using Landsat data. *Remote Sensing of Environment*, n. 122, p. 66-74, 2012. doi: 10.1016/j.rse.2011.08.024.

HANTSON, S.; CHUVIECO, E. Evaluation of different topographic correction methods for Landsat imagery. **International Journal of Applied Earth Observation and Geoinformation**, n. 13, p. 691-700, 2011. doi: 10.1016/j.jag.2011.05.001.

HAWLICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786-804, 1979.

HAY, J. E. Solar energy system design: the impact of mesoscale variations in solar radiation. **Atmosphere-Ocean**, v. 21, p. 138-157, 1983.

HENGL, T.; REUTER, H. I. (Ed.). **Geomorphometry: concepts, software, applications**. Amsterdam: Elsevier, 722p. ISSN (9780123743459).

HIJMANS, R. J. **RASTER: geographic data analysis and modeling**. Pacote R versão 2.1-49. Disponível em: <<http://CRAN.R-project.org/package=raster>>. Acesso em: 20 de out. 2013.

HOLBEN, B. N.; JUSTICE, C. O. The topographic effect on spectral response from nadir-pointing sensors. **Photogrammetric Engineering and Remote Sensing**, v. 46, n. 9, p. 1191-1200, 1980.

HOLBEN, B. N.; JUSTICE, C. O. An examination of spectral band rationing to reduce the topographic effect on remotely sensed data. **International Journal of Remote Sensing**, v. 2, n. 2, p. 115-133, 1981.

HORN, B. K. P. Hill shading and the reflectance map. **Proceedings of the IEEE**, v. 69, n. 1, p. 14-47, 1981.

HOTHORN, T.; HORNIK, K.; ZEILEIS, A. Unbiased recursive partitioning: a conditional inference framework. **Journal of Computational and Graphical Statistics**, v. 15, n. 3, p. 651-674, 2006.

HUANG, H.; GONG, P.; CLINTON, C. N.; HUI, F. Reduction of atmospheric and topographic effect on Landsat TM data for forest classification. **International Journal of Remote Sensing**, v. 29, n. 19, p. 5623-5642, 2008. doi: 10.1080/01431160802082148.

HUDAK, A. T; WESSMAN, C. A. Textural analysis of historical aerial photography to characterize woody plant encroachment in South African savanna. **Remote Sensing of Environment**, v. 66, p. 317-330, 1998.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Produção agrícola municipal, Tabela 1612** - área plantada, área colhida, quantidade produzida e valor da produção da lavoura temporária. Disponível em: <http://www.sidra.ibge.gov.br>. Acesso em: 07 jul. 2013.

KAUTH, R. J.; THOMAS, G. S. The tasseled cap—a graphic description of the spectral-temporal development of agricultural crops as seen in Landsat. In: Symposium on Machine Processing of Remotely Sensed Data, 1976, Indiana. **Proceedings...** West L. Afayette: Purdue University, 1976. p. 41-51. Disponível em: < http://docs.lib.purdue.edu/lars_symp/159 >. Acesso em: 10 jul. 2013.

KIMES, D. S. Dynamics of directional reflectance factor distributions for vegetation canopies. **Applied Optics**, v. 22, n. 9, p. 1364-1372, 1983.

KOBAYASHI, S.; SANGA-NGOIE, K. A comparative study of radiometric correction methods for optical remote sensing imagery: the IRC vs. other image -based C-correction methods. **International Journal of Remote Sensing**, v. 30, n. 2, p. 285-314, 2009. doi: 10.1080/01431160802356781.

KONDRATYEV, K. Y. **Radiation in the atmosphere**. London: Academic, 1969. 912p. ISBN: (978-0-12-419050-4).

KRIEGLER, F. J.; MALILA, W. A.; NALEPKA, R. F.; RICHARDSON, W. Preprocessing transformations and their effects on multispectral recognition. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 6., 1969, Michigan, USA. **Proceedings...** Ann Arbor: Environmental Research Institute of Michigan, 1969. p. 97-131. Volume II.

LI, X.; STRAHLER, A. H. Geometric-optical bidirectional reflectance modeling of the discrete crown vegetation canopy: effect of crown shape and mutual shadowing. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 276-292, 1992.

LI, Z.; ZHU, Q.; GOLD, C. **Digital terrain modeling: principles and methodology**. Boca Raton: CRC PRESS, 2005. 318p. ISBN (0-415-32462-9).

MCDONALD, E. R.; WU, X; CACCETTA, P. A.; CAMPBELL, N. A., 2000. Illumination correction of Landsat TM data in south east NSW. In: AUSTRALASIAN REMOTE SENSING CONFERENCE, 10., 2000, Adelaide, South Australia. **Proceedings...** Adelaide: Environment Australia, 2000, p. 1-13. Disponível em: <<http://www.environment.gov.au/system/files/resources/b57d2a33-a947-480a-8682-7c4926cdca4e/files/illumination.pdf>>. Acesso em 15 de ago. 2013.

MEYER, P.; ITTEN, K. L.; KELLENBERGER, T.; SANDMEIER, S.; SANDMEIER, R. Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 48, p. 17-28, 1993.

- MINNAERT, M. G. J The reciprocity principle in Lunar photometry. **Astrophys journal**, v. 93, p. 403-410, 1941.
- MOREIRA, E. P.; VALERIANO, M. M. Application and evaluation of topographic correction methods to improve land cover mapping using object-based classification. *International Journal of Applied Earth Observations and Geoinformation*, v. 32, p. 208-217, 2014. doi: 10.1016/j.jag.2014.04.006.
- NICHOL, J.; HANG, L. K; SING, W. M. Empirical correction of low Sun angle images in steeply sloping terrain: a slope-matching technique. **International Journal of Remote Sensing**, v. 27, n. 3, p. 629-635, 2006. doi: 10.1080/02781070500293414.
- NICODEMUS, F. E.; RICHMOND, J. C.; HSIA, J. J.; GINSBERG, L W.; LIMPERIS, T. Geometrical considerations and nomenclature for reflectance. In: WOLFF, L. B.; SHAFER, S. A.; HEALEY, G. (Eds.). **Radiometry**. USA: Jones and Bartlett Publishers, Inc., 1977. p. 94-145.
- PROY, C.; TANRÉ, D.; DESCHAMPS, P. Y. Evaluation of Topographic Effects in Remotely Sensed Data. **Remote Sensing of Environment**, v. 30, p. 21-32, 1989.
- QUINLAN, J. R. **C4.5**: programs for machine learning. San Francisco: Morgan Kaufmann Publishers, Inc., 1993. ISBN: (1-55860-238-0).
- R CORE TEAM, 2013. **R: A language and environment for statistical computing**. Vienna, Austria: R Foundation for Statistical Computing. ISBN (3-900051-07-0).
- RABUS, B.; EINEDER, M.; ROTH, A.; BAMLER, R. The shuttle radar topography mission—a new class of digital elevation models acquired by spaceborne radar. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 57, p. 241-262, 2003. doi: 10.1016/S0924-2716(02)00124-7.
- REESE, H.; OLSSON, H. C-correction of optical satellite data over alpine vegetation areas: A comparison of sampling strategies for determining the empirical c-parameter.

Remote Sensing of Environment, v. 115, p. 1987-1400, 2011. doi:
10.1016/j.rse.2011.01.019.

RIAÑO, D.; CHUVIECO, E.; SALAS, J.; AGUADO, I. Assessment of Different Topographic Corrections in Landsat-TM Data for Mapping Vegetation Types. **IEEE Transactions on Geoscience and Remote Sensing**, v. 64, n. 5, p. 1056-1061, 2003. doi: 10.1109/TGRS.2003.811693.

RUDORFF, B.F.T.; AGUIAR, D.A.; SILVA, W.F.; SUGAWARA, L.M.; ADAMI, M.; MOREIRA, M.A. Studies on the Rapid Expansion of Sugarcane for Ethanol Production in São Paulo State (Brazil) Using Landsat Data. **Remote Sensing**, v. 2, n. 4, p. 1057-1076, 2010. doi:10.3390/rs2041057.

SANDMEIER, S.; ITTEN, K. A physically-based model to correct atmospheric and illumination effects in optical satellite data of rugged terrain. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, p. 708-717, 1997.

SELLERS, W. D. **Physical climatology**. Chicago: University of Chicago Press, 1965. 272p. ISBN: (978-0226746999).

SHEPHERD, J. D.; DYMOND, J. R. Correcting satellite imagery for the variance of reflectance and illumination with topography. **International Journal of Remote Sensing**, v. 24, n. 17, p. 3503-3514, 2003. doi: 10.1080/01431160210154029.

SLATER, P. N. **Remote sensing: optics and optical systems**. Reading, MA: Addison-Wesley, 1980. 575p.

SMITH, J. A.; LIN, T. L.; RANSON, K. J. The Lambertian assumption and Landsat data. **Photogrammetric Engineering and Remote Sensing**, v. 46, n. 9, p. 1183-1189, 1980.

SOENEN, S. A.; PEDDLE, D. R.; COBURN, C. A. SCS+C: a modified sun-canopy-sensor topographic correction in forested terrain. **IEEE Transactions on Geoscience**

and Remote Sensing, v. 43, n. 9, p. 2148-2159, 2005. doi:
10.1109/TGRS.2005.852480.

STROBL, C.; MALLEY, J.; TUTZ, G. An introduction to recursive partitioning: rationale, application and characteristics of classification and regression trees, bagging and random forests. **Psychol Methods**, v. 14, n. 4, p. 323-348, 2009. doi:
10.1037/a0016973.

TAN, B.; MASEK, J. G.; WOLFE, R.; GAO, F.; HUANG, C.; VERMOTE, E. F.; EDERER, G. Improved forest change detection with terrain illumination corrected Landsat. **Remote Sensing of Environment**, v. 136, p. 469-483, 2013. doi:
10.1016/j.rse.2013.05.013.

TEILLET, P. M. Image correction for radiometric effects in remote sensing. **International Journal of Remote Sensing**, v. 7, n. 12. p. 1637-1651, 1986.

TEILLET, P. M.; GUINDON, B.; GOODENOUGH, D. G. On the slope-aspect correction of multispectral scanner data. **Canadian Journal of Remote Sensing**, v. 8, p. 84-106, 1982.

U.S Geological Survey (USGS). **Landsat**. Disponível em: <http://www.usgs.gov/>. Acesso em: 23 jul. 2013.

VALERIANO, M. M. Cálculo do fator topográfico de iluminação solar para modelagem ecofisiológica a partir do processamento de Modelos Digitais de Elevação (MDE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 5933-5940. Disponível em: <www.dsr.inpe.br/sbsr2011/files/p0399.pdf>. Acesso em: 03 dez. 2013.

VALERIANO, M. M. Visualização de imagens topográficas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis, SC. **Anais...** São José dos Campos: INPE, 2007. p. 1377-1384. Disponível em:

<<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.14.18.02/doc/1377-1384.pdf>>. Acesso em: 15 out. 2013.

VALERIANO, M. M.; KUPLICH, T. M.; STORINO, M.; AMARAL, B. D.; MENDES JR., J. N.; LIMA, D. J. Modeling small watersheds in Brazilian Amazonia with shuttle radar topographic mission-90m data. **Computers & Geosciences**, v. 32, p. 1169-1181, 2006. doi: 10.1016/j.cageo.2005.10.019.

VALERIANO, M. M.; ROSSETTI, D. F. Topodata: Brazilian full coverage refinement of SRTM data. **Applied Geography**, v. 32, p. 300-309, 2012. doi: 10.1016/j.apgeog.2011.05.004.

VALERIANO, M. M. **TOPODATA**: guia para utilização de dados geomorfométricos locais. São José dos Campos: INPE, 2008. 72p. (CNPq, processo n. 306021/2004-8, NV). Disponível em <<http://www.dpi.inpe.br/topodata/documentos.php>>. Acesso em: 05 jan. 2013.

VALERIANO, M. M. **TOPODATA**: Processamento dos dados SRTM. São José dos Campos: INPE, 2010. 79p. (CNPq, processo n. 307530/2008-6(NV)). Disponível em <<http://urlib.net/sid.inpe.br/mtc-m19@80/2010/05.10.18.42>>. Acesso em: 05 jul. 2013.

VANONCKELEN, S.; LHERMITTE, S.; ROMPAEY, A. v. The effect of atmospheric and topographic correction methods on land cover classification accuracy. **International Journal of Applied Earth Observation and Geoinformation**, v. 24, p. 9-21, 2013. doi: 10.1016/j.jag.2013.02.003.

VERAVERBEKE, S.; VERSTRAETEN, W. W.; LHERMITTE, S.; GOOSSENS, R. Illumination effects on the differenced Normalized Burn Ratio's optimality for assessing fire severity. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, p. 60-70, 2010. doi: 10.1016/j.jag.2009.10.004.

VERMOTE, E. F.; TANRÉ, D.; DEUZÉ, J. L.; HERMAN, M.; MORCRETTE, J. Second Simulation of the Satellite Signal in the Solar Spectrum (6S). **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 675-686, 1997.

VIBRANS, A. C.; MCROBERTS, R. E.; MOSER, P.; NICOLETTI, A. L. Using satellite image-based maps and ground inventory data to estimate the area of the remaining Atlantic forest in the Brazilian state of Santa Catarina. **Remote Sensing of Environment**, v. 130, p. 87-95, 2013. doi: 10.1016/j.rse.2012.10.023.

VINCINI, M.; FRAZZI, E. Multitemporal Evaluation of Topographic Normalization Methods on Deciduous Forest TM Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 11, p. 2586-2590, 2003. doi: 10.1109/TGRS.2003.817272.

WEN, J.; LIU, Q.; LIU, Q.; XIAO, Q.; LI, X. Parametrized BRDF for atmospheric and topographic correction and albedo estimation in Jiangxi rugged terrain, China. **International Journal of Remote Sensing**, v. 30, n. 11, p. 2875-2896, 2009. doi: 10.1080/01431160802558618.

ZHANG, Z.; DE WULF, R. R.; VAN COILLIE, F. M. B.; VERBEKE, L. P. C.; DE CLERCQ, E. M.; OU, X. Influence of different topographic correction strategies on mountain vegetation classification accuracy in the Lancang Watershed, China. **Journal of Applied Remote Sensing**, v. 5, p. 1-22, 2011. doi: 10.1117/1.3569124.

ZHAO, Y. **R and data mining: examples and case studies**. Disponível em: <<http://www.RDataMining.com>>. Acesso em: 02 nov. 2013.