



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/02.04.18.14-TDI

**DESENVOLVIMENTO DE UMA META-METODOLOGIA
PARA CLASSIFICAÇÃO CONTEXTUAL QUE
PRESERVE FEIÇÕES ESTREITAS (META-CCP) EM
IMAGENS DIGITAIS**

Willian Vieira de Oliveira

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Luciano Vieira Dutra,
e Sidnei João Siqueira Sant'Anna,
aprovada em 20 de fevereiro de
2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SMB245>>

INPE
São José dos Campos
2019

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):

Presidente:

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

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

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Murilo Luiz Silva Gino - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/02.04.18.14-TDI

**DESENVOLVIMENTO DE UMA META-METODOLOGIA
PARA CLASSIFICAÇÃO CONTEXTUAL QUE
PRESERVE FEIÇÕES ESTREITAS (META-CCP) EM
IMAGENS DIGITAIS**

Willian Vieira de Oliveira

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Luciano Vieira Dutra,
e Sidnei João Siqueira Sant'Anna,
aprovada em 20 de fevereiro de
2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SMB245>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Oliveira, Willian Vieira de.

O14d Desenvolvimento de uma meta-metodologia para classificação contextual que preserve feições estreitas (Meta-CCP) em imagens digitais / Willian Vieira de Oliveira. – São José dos Campos : INPE, 2019.

xxvi + 80 p. ; (sid.inpe.br/mtc-m21c/2019/02.04.18.14-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

Orientadores : Drs. Luciano Vieira Dutra, e Sidnei João Siqueira Sant'Anna.

1. Classificação contextual. 2. Remoção de ruídos.
3. Preservação de feições. 4. Sensoriamento Remoto. I.Título.

CDU 528.831.2



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/).

Aluno (a): **Willian Vieira de Oliveira**

Título: "DESENVOLVIMENTO DE UMA META-METODOLOGIA PARA CLASSIFICAÇÃO CONTEXTUAL QUE PRESERVE FEIÇÕES ESTREITAS (META-CCP) EM IMAGENS DIGITAIS"

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

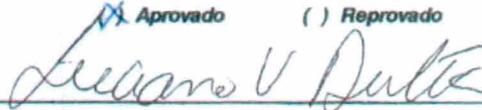
Dr. Camilo Daleles Rennó



Presidente / INPE / SJC Campos - SP

() Participação por Vídeo - Conferência

Dr. Luciano Vieira Dutra

Aprovado () Reprovado


Orientador(a) / INPE / SJC Campos - SP

() Participação por Vídeo - Conferência

Dr. Sidnei João Siqueira Sant'Anna

Aprovado () Reprovado


Orientador(a) / INPE / São José dos Campos - SP

() Participação por Vídeo - Conferência

Dr. Thales Sehn Körting

Aprovado () Reprovado


Membro da Banca / INPE / São José dos Campos - SP

() Participação por Vídeo - Conferência

Dra. Marinalva Dias Soares

Aprovado () Reprovado


Convidado(a) / UNIFESP / São José dos Campos - SP

() Participação por Vídeo - Conferência

Dr. Rogério Galante Negri

Aprovado () Reprovado


Convidado(a) / UNESP / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 20 de fevereiro de 2019

“Se a educação sozinha não transforma a sociedade, sem ela, tampouco, a sociedade muda”.

Pedagogia da Indignação

Paulo Freire

Ao meu pai Edmar, minha mãe Valdirene, minha
irmã Dayanne e minha namorada Daiane.

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, por ter me dado saúde e força para superar as dificuldades ao longo destes anos.

À minha família que, com muito carinho e apoio, me ajudaram a chegar até esta etapa de minha vida.

Aos meus orientadores, Dr. Luciano Vieira Dutra e Dr. Sidnei João Siqueira Sant'Anna, pelo apoio, confiança e ensinamentos.

Aos amigos que fiz durante esta pós-graduação, em especial aos amigos do ASA-35, com quem tive a honra de conviver diariamente durante este período.

Ao Instituto Nacional de Pesquisas Espaciais por fornecer toda a estrutura necessária para o desenvolvimento deste trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, pela concessão da bolsa de estudo.

E todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado!

RESUMO

Classificação de imagens multiespectrais representa um procedimento essencial na análise de dados de sensoriamento remoto. De forma geral, o processo de classificação tem por objetivo categorizar os pixels que compõem uma imagem em relação a um determinado conjunto de classes. Classificadores por pixel tradicionais, os quais se baseiam apenas em informação espectral, tendem a produzir produtos ruidosos, o que pode estar relacionado tanto à variabilidade das amostras consideradas, quanto à variabilidade espectral observada na superfície imageada. No intuito de remover estes ruídos, métodos contextuais de classificação e pós-classificação são comumente utilizados. Entretanto, nestes processamentos, algumas feições também são eliminadas. Neste contexto, o presente trabalho aborda o problema de preservação de feições durante a aplicação de métodos contextuais de classificação em imagens multiespectrais. Este trabalho introduz uma nova abordagem de classificação, denominada Meta-metodologia de Classificação Contextual que Preserve feições estreitas (META-CCP), a qual permite conciliar remoção de ruídos e preservação de feições finas. A META-CCP se baseia na identificação de pixels de alta discriminabilidade, ou seja, pixels onde a classe escolhida pelo classificador pode ser claramente distinguida das demais alternativas de classificação. Estes pixels são preservados durante a aplicação da abordagem contextual. Dessa forma, a META-CCP permite direcionar a aplicação de classificadores contextuais apenas às áreas mais susceptíveis a erros de classificação, de forma a favorecer a remoção de ruídos sem comprometer a representação das demais feições. Além disso, essa meta-metodologia permite a aplicação de diferentes métodos de classificação na etapa contextual. No intuito de validar o método desenvolvido, dois estudos de caso foram desenvolvidos, considerando tanto a classificação de imagens sintéticas quanto de imagem real de sensoriamento remoto. Em ambos os estudos realizados, a META-CCP foi aplicada considerando dois diferentes métodos contextuais de classificação: o filtro de maioria e o algoritmo ICM. Os resultados obtidos mostram que o método proposto permite reduzir eficientemente ruídos de classificação, sem resultar em danos significativos a feições estreitas.

Palavras-chave: Classificação contextual. Remoção de ruídos. Preservação de feições. Sensoriamento Remoto.

DEVELOPMENT OF A META-METHODOLOGY FOR CONTEXTUAL CLASSIFICATION THAT PRESERVES NARROW FEATURES IN DIGITAL IMAGES

ABSTRACT

Multispectral image classification represents an essential procedure in remote sensing data analysis. In general, the process of image classification aims to categorize the pixels that compose an image in relation to a certain set of classes. Traditional pixel-wise classifiers, based only on spectral information, tend to produce noisy products. This effect might be related to both the variability of the samples used and the spectral variability observed for the analysed surface. In order to remove these noises, contextual image classification and post classification methods are commonly used. In this context, this study addresses the problem of feature preservation during the application of contextual methods for multispectral image classification. This study introduces a new classification approach, named as Meta-methodology for Contextual Classification that Preserves narrow features (META-CCP, *Meta-Metodologia de Classificação Contextual que Preserve feições estreitas*), which allows integrating both noise removal and narrow feature preservation. The META-CCP identifies high discriminability pixels, in which the class defined by the classifier can be clearly distinguished from the other classification alternatives. The proposed method preserves these pixels during the contextual classification stage. Therefore, the META-CCP allows directing the application of contextual classifiers only to pixels more susceptible to classification errors. This procedure favours the removal of noisy pixels without damaging the representation of other features. In addition, this meta-methodology allows using different methods in the contextual classification stage. In order to validate the presented method, we performed two case studies, considering the classification of both synthetic images and a real remote sensing image. In both cases, we applied the META-CCP considering two different contextual classifiers: the majority filter and the ICM algorithm. The experimental results show that the proposed method is capable of efficiently reducing classification noises, without resulting in significant damage to narrow features.

Keywords: Contextual classification. Noise removal. Feature preservation. Remote Sensing.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Modalidades de aplicação da classificação contextual.	10
Figura 2.2 – Funcionamento do filtro de maioria.	12
Figura 2.3 – Princípio de funcionamento do algoritmo ICM.	14
Figura 3.1 – Organização da META-CCP.	19
Figura 3.2 – Fluxograma para construção de modelos de classificação.	20
Figura 3.3 – Fluxograma para cálculo da variabilidade por classe.	22
Figura 3.4 – Fluxograma para obtenção dos modelos representantes.	23
Figura 3.5 – Fluxograma para classificação por pixel e geração da MPAD.	24
Figura 3.6 – Intervalo de variação do Fator C.	26
Figura 3.7 – Fluxograma para classificação contextual.	27
Figura 3.8 – Fluxograma para geração da MPAD.	28
Figura 4.1 – (a) Imagem base e (b) áreas para coleta de amostras de treinamento.	31
Figura 4.2 – Áreas destinadas a coleta de amostras de teste para (a) feições largas (estatísticas globais) e (b) feições estreitas (estatísticas locais).	32
Figura 4.3 – Imagem Landsat-8/OLI e amostras utilizadas para compor imagens sintéticas.	34
Figura 4.4 – Imagens sintéticas com (a) baixo contraste (amostras de pasto limpo e solo exposto) e (b) médio contraste (amostras de pasto sujo e solo exposto).	35
Figura 4.5 – Pixels rotulados definidos para a (a) imagem sintética com baixo contraste e a (b) imagem sintética com médio contraste.	36
Figura 4.6 – Mapas de classificação MAXVER obtidos para a (a) imagem sintética com baixo contraste e a (b) imagem sintética com médio contraste. .	37
Figura 4.7 – Exemplos de máscaras de pixels de alta discriminabilidade obtidas para a imagem sintética com médio contraste.	37
Figura 4.8 – Exemplos de máscaras de pixels de alta discriminabilidade obtidas para a imagem sintética com baixo contraste.	38

Figura 4.9 – Produtos oriundos de classificação convencional, obtidos para a imagem sintética com baixo contraste.	39
Figura 4.10 – Produto de classificação obtido pelo algoritmo ICM convencional, para a imagem sintética com baixo contraste.	40
Figura 4.11 – Produtos oriundos de classificação convencional, obtidos para a imagem sintética com médio contraste.	41
Figura 4.12 – Exemplos de produtos gerados para a imagem com baixo contraste, utilizando o filtro de maioria 5x5 (META-CCP-FM5), para diferentes fatores C.....	42
Figura 4.13 – Estatísticas obtidas para os mapas de classificação referentes à imagem sintética com baixo contraste, ao se adotarem diferentes classificadores contextuais.....	44
Figura 4.14 – Estatísticas obtidas para os mapas de classificação referentes à imagem sintética com médio contraste, ao se adotarem diferentes classificadores contextuais.....	45
Figura 4.15 – Comparação entre mapas gerados por abordagens convencionais e mapas resultantes da META-CCP, para a imagem com baixo contraste.....	46
Figura 4.16 – Comparação entre mapas gerados por abordagens convencionais e mapas resultantes da META-CCP, para a imagem com médio contraste.....	48
Figura 4.17 – Recorte de imagem Landsat-8/OLI.	50
Figura 4.18 – Dados iniciais de classificação: (a) Amostras de treinamento/teste e (b) pixels rotulados.	51
Figura 4.19 – Mapa de classificação pontual gerado pelo classificador MAXVER.	53
Figura 4.20 – Exemplos de máscaras MPAD obtidas para a imagem Landsat-8/OLI.	54
Figura 4.21 – Estatísticas referentes a imagem Landsat-8/OLI, para áreas centrais (acurácia global) e feições estreitas de solo exposto (acurácia do produtor).....	56

Figura 4.22 – Comparação entre produtos de classificação obtidos ao se aplicar o filtro de maioria considerando a META-CCP e pelo método convencional. ..	58
Figura 4.23 – Imagem diferença obtida entre os produtos gerados pela META-CCP, com Fator C de 13 e filtro de maioria 3x3, e pelo filtro de maioria 3x3 convencional.	61
Figura 4.24 – Comparação entre produtos de classificação obtidos pelo algoritmo ICM considerando a META-CCP e pelo método convencional.	62

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Lista de configurações possíveis para vizinhança 8.....	15
Tabela 4.1 – Estudo de caso II: principais características da imagem classificada.....	49
Tabela 4.2 – Combinações de pares de classes considerados para obtenção de fatores C representativos.	52
Tabela 4.3 - Fatores C representativos computados para diferentes pares de classes de cobertura da terra, por meio de amostras adquiridas em imagem Landsat-8/OLI.....	55

LISTA DE SIGLAS E ABREVIATURAS

INPE	Instituto Nacional de Pesquisas Espaciais
AG	Acurácia Global
AP	Acurácia do Produtor
FDR	Razão Discriminante de Fisher (<i>Fisher Discriminant Ratio</i>)
FM	Filtro de Maioria
ICM	Modas Condicionais Iterativas (<i>Iterated Conditional Modes</i>)
MAP	Máximo A Posteriori (<i>Maximum A Posteriori</i>)
MAXVER	Máxima Verossimilhança
MPAD	Máscara de Pixels de Alta Discriminabilidade
MPM	Moda da Marginal a Posteriori (<i>Marginal Posterior Mode</i>)
MRF	Campo Aleatório Markoviano (<i>Markov Random Field</i>)
OLI	<i>Operational Land Imager</i>
PDF	Função de Densidade de Probabilidade (<i>Probability Density Function</i>)
META-CCP-FM3	Filtro de maioria 3x3, considerando a META-CCP
META-CCP-FM5	Filtro de maioria 5x5, considerando a META-CCP
META-CCP-FM7	Filtro de maioria 7x7, considerando a META-CCP
META-CCP-ICM	Algoritmo ICM, considerando a META-CCP

LISTA DE SÍMBOLOS

x	Vetor de atributos de um determinado pixel
K	Número de classes para classificação
k	Índice que varia de 1 a K
ω_k	Classe k
$P(\omega_k x)$	Probabilidade de associação de um pixel x à classe ω_k
$p(\omega_k)$	Probabilidade a priori
$E[\cdot]$	Esperança matemática
μ_k	Vetor de média para a classe k
nb	Número de bandas espectrais
V_k	Matriz de covariância para a classe k
$ V_k $	Determinante da matriz V_k
V_k^{-1}	Matriz inversa da matriz V_k
$[\cdot]^T$	Transposta da matriz contida em $[\cdot]$
$g_k(x)$	Função discriminante para um pixel x , referente a uma classe k
v	Matriz de verossimilhança
y_{MAXVER}	Mapa de classificação pontual, obtido pelo classificador MAXVER
Max_{iter}	Número máximo de iterações permitidas no Algoritmo ICM
Min_{Alt}	Percentual mínimo de mudança requerido para convergência da classificação no Algoritmo ICM
β	Parâmetro Beta adotado no algoritmo ICM
y	Mapa de classificação adotado para inicialização do algoritmo ICM
y_I	Mapa intermediário de classificação ICM
P_{Alt}	Percentual de mudança observado entre os mapas y e y_p
Viz	Vetor de contadores do número de ocorrência de todas as configurações possíveis para vizinhança 8 (e.g.: Viz_{08} , Viz_{611})
$Nviz_{classe}$	Vetor com o número de vizinho por classe, para uma determinada posição da janela móvel no algoritmo ICM
e_β	Vetor de pesos (e_β) adotado no algoritmo ICM
J	Número de modelos de classificação
j	Índice que varia de 1 a J
N	Número de pixels amostrados por classe, para geração de cada modelo de classificação

I	Número de pixels rotulados considerados cálculo da variabilidade por classe
i	Contador que varia de 1 a I
$x_{i,k}$	Pixel rotulado i , de classe k
$g_{j,k}(x_{i,k})$	Função discriminante gerada pelo modelo j , referente a classe k , para um determinado pixel $x_{i,k}$
$\sigma_k^2(x_{i,k})$	Variância dos valores obtidos para o pixel $x_{i,k}$, considerando os diversos modelos gerados para a classe k do pixel analisado
σ_k	Desvio padrão obtido para a classe k
$\bar{g}_{j,k}$	Valor médio de verossimilhança, por classe k e modelo j , ou seja, considerando a variação dos valores para todos os pixels rotulados
\bar{g}_k	Valor médio de verossimilhança, por classe k , considerando a variação dos valores contidos em $\bar{g}_{j,k}$
g_k^*	Modelo de classificação representante, definido para a classe k
R	Imagem a ser classificada
$R_{Lin,Col}$	Vetor de atributos de um determinado pixel da imagem R , referente a linha Lin e coluna Col
$g_k^*(R_{Lin,col})$	Função discriminante gerada pelo modelo representante referente a classe k , calculada para um determinado pixel $R_{Lin,Col}$
C	Fator C
FDR	Razão Discriminante de Fisher (do inglês, <i>Fisher Discriminant Ratio</i>)

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Hipótese de trabalho	3
1.2 Objetivos	4
1.3 Organização do documento	4
2 CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO.....	5
2.1 Conceitos gerais	5
2.2 Classificação supervisionada por máxima verossimilhança.....	7
2.3 Classificadores contextuais.....	9
2.3.1 Filtro de maioria	12
2.3.2 Algoritmo ICM	13
3 FORMALIZAÇÃO DA META-CCP PARA CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO	19
3.1 Construção de instâncias de modelos de classificação	20
3.2 Cálculo da variabilidade por classe.....	21
3.3 Escolha do modelo de classificação representante	22
3.4 Classificação por pixel e geração da máscara (MPAD)	23
3.5 Classificação contextual.....	27
4 EXPERIMENTOS E RESULTADOS.....	29
4.1 Estudo de caso I: classificação de imagens sintéticas.....	30
4.1.1 Simulação de imagens	30
4.1.2 Classificação das imagens com baixo e médio contraste	35
4.1.3 Análise dos resultados e definição dos mapas de classificação	43
4.2 Estudo de caso II: classificação de imagem de SR.....	49
4.2.1 Classificação de imagem Landsat-8/OLI	49
4.2.1.1 Descrição e análise dos produtos de classificação	52
5 CONCLUSÕES E PERSPECTIVAS FUTURAS	65
REFERÊNCIAS BIBLIOGRÁFICAS	67

GLOSSÁRIO	71
APÊNDICE A – PSEUDOCÓDIGOS PARA CLASSIFICAÇÃO UTILIZANDO A META-CCP.....	73
ANEXO A – EQUAÇÃO PARA ESTIMAÇÃO DE β PARA VIZINHANÇA 8	77

1 INTRODUÇÃO

Classificação de imagens pode ser definido como um processo de extração de informação voltado à rotulação de objetos (normalmente pixels) em imagens digitais (THEODORIDIS; KOUTROUMBAS, 2003). Em sensoriamento remoto, imagens provenientes de sensores orbitais são utilizadas para se obter informação acerca dos mais variados objetos e feições presentes na superfície terrestre, atendendo às necessidades de diversas áreas de aplicação. Exemplos de aplicações podem ser citados no âmbito do planejamento urbano (ALMEIDA, 2010; SOUZA, 2012) e no monitoramento de fenômenos ambientais (AFFONSO; ESCADA, 2017; SHIMABUKURO et al., 2017).

Ao longo dos anos, sistemas sensores são desenvolvidos visando favorecer a obtenção de dados de sensoriamento remoto com maior nível de detalhes, seja em termos de resolução espacial, espectral, temporal ou radiométrica. Neste contexto, onde observa-se a coleta de um maior volume de dados, intensifica-se a necessidade de técnicas e métodos de classificação que favoreçam uma análise e manipulação eficiente destes conjuntos de dados.

De forma geral, classificadores de imagens visam associar cada pixel a uma das diversas classes de cobertura do solo de interesse. Na literatura, diversos são os classificadores propostos, sendo estes normalmente categorizados quanto ao tipo de aprendizado adotado (e.g., supervisionado ou não supervisionado), ou ainda, quanto ao objeto de classificação (e.g., pixel a pixel ou por regiões). Os classificadores podem também ser denominados contextuais, em casos onde incorpora-se informação de vizinhança.

Alguns autores destacam que classificadores contextuais podem proporcionar resultados mais acurados em relação a classificadores não contextuais (BINAGHI et al., 2003; CHEN et al., 2018; NEGRI, 2013), uma vez que fazem uso de uma maior quantidade de informação. Esta característica pode favorecer a identificação de padrões complexos que formam os diversos tipos de cobertura da terra. Em geral, objetos mais próximos tendem a ser mais correlacionados do que aqueles mais distantes espacialmente (MILLER, 2004; TOBLER, 1970). Esta relação pode ser explicada pelo fato de que, geralmente,

são representados em pixels vizinhos tipos de coberturas que formam uma região geográfica. Desse modo, a classificação da cobertura da terra para um determinado pixel tende a ser mais acurada ao se considerarem as características apresentadas por sua vizinhança.

Além disso, métodos contextuais podem ainda ser aplicados para remoção de ruídos em classificações. Independentemente do paradigma de aprendizado adotado, classificadores baseados essencialmente em informação espectral de pixels individuais tendem a produzir classificações ruidosas (LU; WENG, 2007; QIAN et al., 2005; RODRIGUEZ-CUENCA et al., 2013). Este efeito é comumente encontrado, por exemplo, em produtos gerados pelo classificador por máxima verossimilhança (MAXVER), o qual representa um dos algoritmos mais utilizados de classificação supervisionada, do tipo pixel a pixel.

A importância da utilização de abordagens para eliminação de ruídos oriundos de classificação pontual é ainda mais enfatizada com o surgimento de sistemas sensores mais modernos, com resolução espacial mais fina. Segundo Tso e Mather (2009), os avanços em termos de resolução espacial não resultam necessariamente na obtenção de classificações mais precisas. Isto se deve a maior variabilidade espectral observada em áreas locais das imagens, a qual se torna ainda mais aparente com o refinamento da resolução espacial.

Em muitos casos, estes ruídos podem ser minimizados por meio de operações contextuais de classificação e pós-classificação. Entretanto, neste processo, independentemente do método adotado, a representação de algumas classes também pode ser afetada, sendo este efeito evidente na representação de feições lineares (RODRIGUEZ-CUENCA et al., 2013). Porém, apesar dos diversos métodos contextuais propostos na literatura, a maioria dos estudos não consideram o efeito de técnicas contextuais em feições estreitas. À medida que métodos contextuais são aplicados, a representação de feições estreitas tende a ser danificada ou removida. A intensidade deste efeito depende das características do método utilizado e das dimensões das feições. Além disso, a associação de feições geográficas a feições estreitas varia conforme a resolução espacial do sensor utilizado para aquisição das imagens.

Neste contexto, o presente trabalho busca soluções para o problema de preservação de feições estreitas lineares ao serem aplicados classificadores contextuais. A definição de feições estreitas varia conforme a resolução espacial do sensor responsável pela aquisição da imagem analisada. Neste trabalho, consideram-se como feições estreitas, feições com até 7 pixels de largura. Este estudo é orientado pela seguinte pergunta científica: de que forma é possível aperfeiçoar a capacidade apresentada por métodos contextuais para remoção de ruídos de classificação, sem que estes danifiquem estruturas estreitas? Em outras palavras, busca-se identificar uma abordagem de classificação que utilize da capacidade apresentada por métodos contextuais para remoção de ruídos, de forma a preservar feições que não representem ruídos de classificação, tais como feições associadas a estruturas estreitas.

Para responder esta pergunta, essa dissertação apresenta uma abordagem de classificação que permite conciliar remoção de ruídos e preservação de feições estreitas. Este trabalho apresenta uma **meta**-metodologia de classificação, denominada Meta-metodologia de Classificação Contextual que Preserve feições estreitas (META-CCP), a qual permite aprimorar a acurácia em produtos de classificação pixel a pixel, por meio de abordagens contextuais, sem deteriorar a representação de feições estreitas. O termo **meta** é adotado uma vez que a META-CCP permite o uso de diferentes métodos contextuais. A META-CCP se baseia na identificação de pixels menos susceptíveis a erros de classificação, a serem preservados durante a abordagem contextual. Estes pixels são referidos como áreas de alta discriminabilidade entre a classe escolhida pelo classificador e as demais alternativas de classificação. Demais pixels, definidos como áreas de baixa discriminabilidade, podem ser reclassificados pela abordagem contextual. Neste trabalho, produtos de classificação são denominados mapas de classificação.

1.1 Hipótese de trabalho

A representação de feições estreitas também pode ser preservada ao se preservarem pixels com classificação claramente distinta das demais alternativas de classificação, observadas para os mesmos pixels ou objetos, ou

seja, pixels de alta discriminabilidade entre classes. A aplicação de classificadores contextuais apenas em pixels de baixa discriminabilidade possibilita que ruídos oriundos do processo de classificação pontual sejam removidos sem resultar na eliminação de outras feições.

1.2 Objetivos

Essa dissertação tem como objetivo principal desenvolver uma meta-metodologia de classificação que permita reduzir ruídos de classificação em produtos oriundos de classificação pontual, por meio da utilização de métodos contextuais, sem prejudicar a representação de feições estreitas. Neste objetivo geral estão inseridos como objetivos específicos:

- a) estabelecer um critério para identificar pixels menos susceptíveis a erros de classificação, ou seja, pixels classificados com alta discriminabilidade entre classes;
- b) avaliar a eficiência da META-CCP na eliminação de ruídos, por meio de estatísticas computadas considerando apenas amostras de teste em regiões centrais, ou seja, longe de bordas;
- c) avaliar a eficiência da META-CCP na preservação de feições finas, por meio de estatísticas computadas considerando apenas amostras de teste coletadas em regiões estreitas.

1.3 Organização do documento

Este documento está estruturado em cinco capítulos. No Capítulo 2, são introduzidos conceitos gerais sobre classificação de imagens de sensoriamento remoto, bem como a descrição do método de classificação por máxima verossimilhança. Neste capítulo são também fornecidos detalhes sobre métodos contextuais de classificação, com foco no filtro de maioria e no algoritmo ICM (*Iterated Conditional Modes*). No Capítulo 3, é descrita detalhadamente a META-CCP. No capítulo 4, são apresentados dois estudos de casos realizados com o objetivo de avaliar a eficiência da META-CCP. Por fim, o Capítulo 5 apresenta um resumo do trabalho, as conclusões e perspectivas para trabalhos futuros.

2 CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

Antes de descrever a metodologia desenvolvida para alcançar os objetivos propostos, uma revisão bibliográfica sobre classificação de imagens de sensoriamento remoto é apresentada. Aqui são discutidos, além de conceitos gerais sobre classificação de imagens, o classificador pontual por máxima verossimilhança e alguns dos principais métodos contextuais de classificação.

2.1 Conceitos gerais

Diversos são os métodos de classificação propostos na literatura, os quais variam de acordo com a modelagem das regras de decisão adotada para identificação dos alvos para um determinado número de classes temáticas (KHEDAM et al., 2002; NEGRI, 2013). Este processo de modelagem é determinado inicialmente pelo paradigma de aprendizado, o qual pode ser, por exemplo, supervisionado ou não supervisionado.

Os classificadores que permitem a definição a priori destas classes são definidos como classificadores supervisionados. Neste caso, considera-se que o analista apresente conhecimento prévio acerca das classes de interesse, uma vez que esta abordagem requer o fornecimento de amostras referentes a cada uma das classes (RICHARDS; JIA, 2006). Neste procedimento de rotulagem, as propriedades numéricas dos pixels amostrados para cada classe são utilizadas visando a obtenção de parâmetros de classificação que permitam a detecção de outros pixels com características semelhantes.

Em contrapartida, os métodos de classificação não supervisionados se baseiam em um reconhecimento de estruturas internas ao conjunto de dados, ou seja, não dependem da definição de classes para mapeamento e nem do fornecimento de amostras para realização da classificação (THEODORIDIS; KOUTROUMBAS, 2003). Desta forma, como resultado são gerados conjuntos compostos por pixels com características similares, os quais podem ser posteriormente associados a classes pelo analista. Para mais detalhes acerca deste tipo de classificação, recomendam-se Richards e Jia (2006) e Theodoridis e Koutroumbas (2003).

Na classificação supervisionada, respostas espectrais obtidas a partir de conjunto de amostras conhecidas são analisadas a fim de se caracterizarem as classes temáticas de interesse. As respostas obtidas neste processo – conjunto de parâmetros – variam conforme a metodologia adotada e permitem que o algoritmo reconheça padrões espectrais característicos de cada classe. No caso do classificador gaussiano por máxima verossimilhança, por exemplo, os parâmetros do modelo a serem obtidos são a matriz de covariância e o vetor de médias das classes (RICHARDS; JIA, 2006).

Em geral, independentemente do classificador utilizado, as principais etapas envolvidas na classificação supervisionada são: (i) definir os tipos de elementos (classes) nos quais a imagem será particionada; (ii) formar conjuntos de amostras (pixels) que representem cada uma das classes definidas, visando o treinamento do classificador; (iii) estimar os parâmetros requeridos pelo algoritmo classificador a ser utilizado (treinamento); (iv) aplicar o classificador em toda a imagem; e, (v) produzir índices ou imagens temáticas que sintetizem os resultados obtidos (RICHARDS; JIA, 2006; VIEIRA, 1996).

Os classificadores podem ainda ser divididos quanto ao tipo do objeto a ser rotulado: pixel ou região. Na abordagem pixel a pixel, cada pixel é classificado baseando-se apenas na informação do pixel, enquanto que em uma abordagem por regiões é considerada a classificação de regiões homogêneas (RICHARDS; JIA, 2006). Além disso, alguns métodos de classificação levam também em consideração a informação contida nos pixels de uma pré-determinada vizinhança, sendo estes denominados classificadores contextuais.

Negri (2013) destaca que classificadores por pixel, por fazerem uso de uma quantidade limitada de informação, tendem a apresentar resultados não tão precisos quanto os métodos contextuais na identificação de padrões complexos. Esta relação entre pixels vizinhos representa uma rica fonte de informação, a qual tem sido alvo de estudo de diversos pesquisadores, visando o aprimoramento do processo de classificação de imagens (RODRIGUEZ-CUENCA et al., 2013; NEGRI et al., 2016; QIAN et al., 2005).

2.2 Classificação supervisionada por máxima verossimilhança

O classificador por máxima verossimilhança é considerado um dos métodos de classificação supervisionada mais comumente utilizados em dados provenientes de sensores remotos (MAXWELL, 2018; YU et al., 2014). Neste classificador, do tipo pixel a pixel, uma amostragem adequada para cada uma das classes de interesse possibilita que sejam estimados os parâmetros que caracterizam uma dada distribuição probabilística.

De acordo com o teorema de Bayes, no qual o classificador MAXVER é baseado, um pixel é designado para a classe que apresentou maior probabilidade de associação (TSO; MATHER, 2009). Assim, considerando um conjunto composto por K classes ($\omega_1, \omega_2 \dots \omega_K$), a probabilidade de associação de um determinado pixel a cada uma das classes é $P(\omega_k|\mathbf{x})$, onde \mathbf{x} representa um vetor com valores de um atributo para cada banda e k varia de 1 a K . Conforme a regra de classificação de Bayes, a classificação é realizada da seguinte forma, onde k_2 representa uma classe diferente de k :

$$\mathbf{x} \in \omega_k, \text{ se } P(\omega_k|\mathbf{x}) > P(\omega_{k_2}|\mathbf{x}), \forall k_2 \neq k. \quad (2.1)$$

Entretanto, conforme mencionado anteriormente, esta probabilidade não é diretamente conhecida. Para estimá-la, aplica-se (TSO; MATHER, 2009):

$$P(\omega_k|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_k)p(\omega_k)}{p(\mathbf{x})}, \quad (2.2)$$

onde $p(\mathbf{x}|\omega_k)$ representa a probabilidade condicional do vetor do pixel \mathbf{x} pertencer a classe ω_k , equivalente à função de densidade de probabilidade, $p(\omega_k)$ é a probabilidade da classe ω_k ocorrer na imagem (probabilidade a priori), e $p(\mathbf{x})$ é a probabilidade de ocorrência de \mathbf{x} . Porém, como $p(\mathbf{x})$ pode representar um fator comum para todas as classes, tem-se que:

$$\mathbf{x} \in \omega_k, \text{ se } p(\mathbf{x}|\omega_k)p(\omega_k) > p(\mathbf{x}|\omega_{k_2})p(\omega_{k_2}), \forall k_2 \neq k. \quad (2.3)$$

A função de densidade de probabilidade (PDF, *Probability Density Function*) pode ser obtida por meio de modelagem estatística. Em diversas aplicações de sensoriamento remoto considera-se que a PDF seja uma distribuição

Gaussiana multivariada, já que esta permite uma modelagem adequada para um grande conjunto de casos (CAMPS-VALLS; BRUZZONE, 2009; RICHARDS; JIA, 2006; THEODORIDIS; KOUTROUMBAS, 2003).

Conforme apresentado por Duda et al. (2010), a função de densidade de probabilidade normal para casos multidimensionais (imagens multiespectrais) pode ser obtida da seguinte forma:

$$p(\mathbf{x}|\omega_k) = \frac{1}{(2\pi)^{\frac{nb}{2}} * \sqrt{|\mathbf{V}_k|}} * \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_k)^T \mathbf{V}_k^{-1}(\mathbf{x} - \boldsymbol{\mu}_k)\right], \quad (2.4)$$

onde nb representa o número de bandas espectrais, $\boldsymbol{\mu}_k$ indica o vetor de média para a classe ω_k , \mathbf{V}_k é a matriz de covariância para a classe ω_k e $|\mathbf{V}_k|$ seu determinante. Os expoentes T e -1 indicam a transposição e inversão matricial, respectivamente. A matriz de covariância é definida conforme apresentado a seguir, sendo $E[\cdot]$ a esperança matemática da variável aleatória:

$$\mathbf{V}_k = E[(\mathbf{x} - \boldsymbol{\mu}_k)(\mathbf{x} - \boldsymbol{\mu}_k)^T]. \quad (2.5)$$

Normalmente, em trabalhos de classificação de imagens de sensoriamento remoto, admite-se que todas as classes possuem a mesma probabilidade de ocorrerem (classes equiprováveis). Neste caso, em que se considera que a probabilidade *a priori* $p(\omega_k)$ seja igual entre as classes, o classificador MAXVER baseia-se apenas na função de densidade de probabilidade. Dessa forma, a função discriminante da classificação por máxima verossimilhança pode ser descrita da seguinte forma (DUDA et al., 2000):

$$g_k(\mathbf{x}) = -\ln|\mathbf{V}_k| - (\mathbf{x} - \boldsymbol{\mu}_k)^T \mathbf{V}_k^{-1}(\mathbf{x} - \boldsymbol{\mu}_k), \quad (2.6)$$

onde k varia de 1 a K . Nesse caso, a classificação pode ser realizada da seguinte forma:

$$\mathbf{x} \in \omega_k, \text{ se } g_k(\mathbf{x}) > g_{k2}(\mathbf{x}), \forall k2 \neq k. \quad (2.7)$$

A efetividade do classificador MAXVER gaussiano depende significativamente de uma estimativa acurada do vetor de médias e da matriz de covariância para cada classe, sendo estes, por sua vez, dependentes da aquisição de um número suficiente de amostras de treinamento (TSO; MATHER, 2009). Estes

fatores refletem diretamente na acurácia da classificação. Richards e Jia (2006) destacam que para um espaço multiespectral nb -dimensional são necessárias pelo menos $nb + 1$ amostras para evitar que a matriz seja singular (não admita matriz inversa), indicando-se a aquisição de $100 \cdot nb$ amostras independentes.

2.3 Classificadores contextuais

Segundo Tso e Mather (2009), o contexto de um pixel, ou grupo de pixels, pode ser entendido como a probabilidade de ocorrência deste, baseado na natureza dos pixels adjacentes. Dessa forma, os pixels não são tratados isoladamente, mas considera-se também a relação destes com os pixels vizinhos. A definição de uma vizinhança estabelece a área em torno de cada objeto/pixel a ser utilizada durante o processo de classificação contextual de cada pixel/objeto.

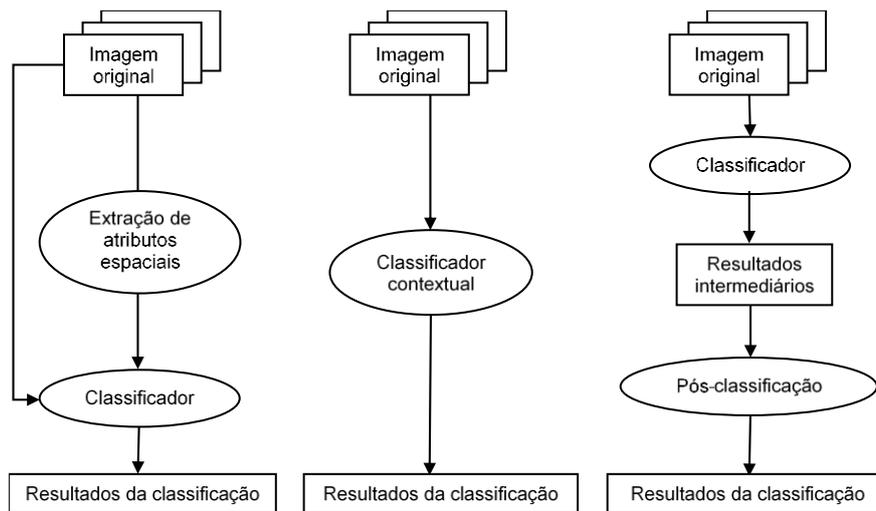
Tratando-se de imagens de sensoriamento remoto, pixels adjacentes tendem a ser relacionados ou correlacionados (KHEDAM; AISSA, 2004). Primeiramente, fenômenos geográficos e ecológicos apresentam uma variação gradual no espaço (LEGENDRE, 1993), sendo que muitas feições terrestres normalmente ocorrem em regiões de dimensões superiores à área coberta por um pixel. Além disso, no processo de imageamento, são adquiridas porções significativas de energia provenientes de regiões adjacentes a cada pixel. Este efeito tende a aumentar a similaridade de atributos geográficos de regiões vizinhas em imagens de sensoriamento remoto (RICHARDS; JIA, 2006).

A utilização de classificadores contextuais em estudos de sensoriamento remoto pode ser justificada por dois fatores: a estrutura complexa dos elementos geográficos presentes na superfície terrestre, onde diferentes tipos de cobertura da terra podem ser encontrados em uma única região; e, a necessidade de se analisar informação contextual para análise dos padrões complexos de cobertura da terra (BINAGHI et al., 2003).

Ao se considerar informação contextual, alguns erros podem ser evitados na classificação de pixels, tais como aqueles resultantes de dados ruidosos. Os classificadores contextuais ainda tendem a ser mais eficientes na identificação de padrões complexos (NEGRI, 2013). A aplicação de métodos contextuais

pode ser incorporada em três diferentes estágios: no pré-processamento, a partir da extração de atributos espaciais; diretamente na classificação, por meio de classificadores contextuais; ou, na etapa de pós-processamento, ao se utilizar informação contextual para melhorar o resultado de uma determinada classificação. Estes diferentes estágios são ilustrados na Figura 2.1.

Figura 2.1 – Modalidades de aplicação da classificação contextual.



Fonte: adaptada de Gong e Xu (2006).

Para Gong e Xu (2006), na classificação de imagens, o envolvimento de atributos espaciais é um processo essencial para a etapa de pré-processamento. Os autores destacam que, a partir da extração de atributos espaciais qualquer algoritmo de classificação por pixel pode ser utilizado. No estágio de pré-processamento, o contexto espacial pode ser explorado, por exemplo, por meio de: filtros de mediana, os quais permitem a redução de ruídos do tipo sal e pimenta (do inglês, *salt and pepper noise*); a partir de filtros de média, os quais são aplicados visando uma maior homogeneidade dos valores de brilho entre pixels adjacentes; ou ainda por algoritmos mais avançados de análise de textura.

Por outro lado, ao serem aplicados diretamente na imagem original, os classificadores contextuais fazem uso da informação contextual para rotulagem dos pixels. Neste tipo de classificador, o grau de correlação entre pixels adjacentes varia conforme a resolução espacial do sensor (RICHARDS; JIA, 2006). Por exemplo, pixels adjacentes em imagens provenientes do sensor

Landsat-8/OLI, com resolução espacial de 30m, podem não demonstrar tanta correlação quanto pixels adjacentes em imagens provenientes de sensores com maior resolução espacial, ou seja, maior nível de detalhes. Richards e Jia (2006) destacam também a necessidade de considerar as características da área analisada. Regiões agrícolas, por exemplo, tendem a ser representadas por pixels fortemente correlacionados, ao contrário do que ocorre para áreas urbanas, devido à heterogeneidade de elementos, mesmo se tratando de imagens provenientes de um mesmo sensor.

Para a etapa de pós-processamento, os métodos contextuais requerem análise espacial baseada nos resultados de classificação intermediária realizada sobre a imagem multiespectral original (GONG; XU, 2006). Dentre os pós-processamentos contextuais, o filtro de maioria destaca-se por sua simplicidade. Neste método, emprega-se uma janela móvel sobre a imagem, atribuindo-se a cada pixel central a classe observada para a maioria dos pixels contidos na janela (CANTY, 2010). Uma desvantagem deste método é a perda de detalhes na imagem, principalmente em áreas com feições lineares.

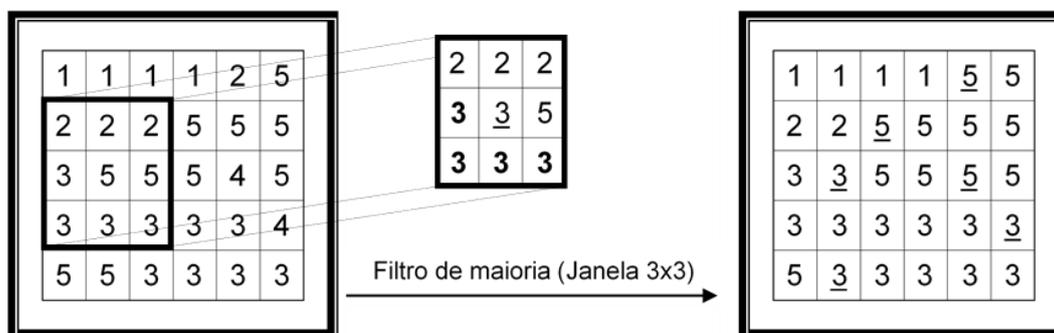
Além deste filtro, algumas técnicas de pós-processamento são fundamentadas na modificação dos valores de probabilidade de cada pixel baseada na compatibilidade probabilística entre pixels vizinhos (GONG; XU, 2006). Estas são conhecidas como técnicas de relaxação probabilística. Mais detalhes sobre estas técnicas podem ser encontrados em Richards e Jia (2006).

Classificadores contextuais podem ser divididos em duas categorias principais (CORTIJO; BLANCA, 1998), conforme a suposição teórica adotada: baseados em técnicas de suavização; ou, baseados na suposição da existência de um campo aleatório Markoviano (do inglês *Markov Random Field* – MRF). Nas técnicas de suavização, Negri (2013) menciona a utilização de filtros sobre a imagem classificada e de medidas de textura antes do processo de classificação pontual. Já para os estimadores relacionados às técnicas Markovianas destaca-se o algoritmo ICM, além dos estimadores Máximo A Posteriori (*Maximum A Posteriori* – MAP) e Moda da Marginal a Posteriori (*Marginal Posterior Mode* – MPM) (FRERY, 1993).

2.3.1 Filtro de maioria

Conhecido por sua facilidade de implementação, o filtro de maioria – ou filtro de moda, como também é conhecido – baseia-se na reclassificação dos pixels de acordo com sua vizinhança. Nesta operação, uma janela móvel é aplicada sobre a imagem. Caso a classe do pixel central não represente a classe da maioria dos pixels contidos na janela, este pixel é reclassificado para esta classe. Por outro lado, caso não haja uma classe principal única, uma solução comumente adotada é a preservação da classe do pixel central. A medida que a janela móvel é deslocada, as classes originais dos pixels vizinhos continuam a ser utilizadas, ou seja, não consideram-se as alterações realizadas nas posições anteriores da janela (EASTMAN et al., 1995). Na Figura 2.2, é exemplificada a aplicação do filtro de maioria, com janela 3x3, em uma parte central de uma imagem. Neste exemplo, os valores sublinhados indicam os pixels que foram reclassificados.

Figura 2.2 – Funcionamento do filtro de maioria.



Fonte: Produção do autor.

Este método tem sido utilizado por diversos autores visando incorporar informação contextual à classificação, no intuito de aprimorar a acurácia dos produtos gerados na classificação de imagens (CARAS et al., 2017; KIM, 1996; MYEONG et al., 2001). Este filtro permite que ruídos oriundos do processo de classificação, bem como da alta variabilidade espectral que pode ser observada na área representada por um único pixel, sejam removidos (CARAS et al., 2017). Entretanto, neste processo algumas informações nos dados classificados podem ser afetadas, como ocorre, por exemplo, com a representação de feições lineares (RODRIGUEZ-CUENCA et al., 2013).

2.3.2 Algoritmo ICM

O algoritmo ICM, definido em Besag (1986), representa um método de classificação supervisionado e contextual, baseado num processo iterativo onde cada pixel é classificado em função de seu valor espectral e das classes de pixels vizinhos. De forma geral, este classificador se baseia na substituição da classe associada a cada pixel de uma determinada imagem por aquela classe que maximiza a distribuição a posteriori da classe, considerando-se a configuração de vizinhança de cada pixel analisado (SANT'ANNA et al., 1996).

Dentre as vantagens da aplicação do algoritmo ICM, Frery (1993) destaca o fato de apresentar uma implementação amigável para o usuário. De acordo com o autor, o algoritmo não requer mais conhecimento do que o necessário para a utilização do classificador MAXVER. Além disso, este método é determinístico, o que garante, por definição, a unicidade de sua solução (ERTHAL; FRERY, 1993). Uma peculiaridade deste algoritmo está no fato de assegurar bons resultados em poucas iterações, sendo destaque a garantia de convergência para um máximo local (BESAG, 1986; MARTINS, 2007). De acordo com Vieira (1996), a influência das classes vizinhas, geralmente computada para quatro ou oito vizinhos, é quantificada por um parâmetro estimado iterativamente a partir da suposição de um modelo para a distribuição espacial das classes.

Quanto às limitações do algoritmo, Lin et al. (2014) afirmam que a obtenção de um resultado satisfatório depende significativamente da classificação inicial obtida e que a acurácia ainda pode ser aprimorada. A depender da inicialização realizada, a área referente ao erro tende a se espalhar pela imagem à medida que as iterações são realizadas.

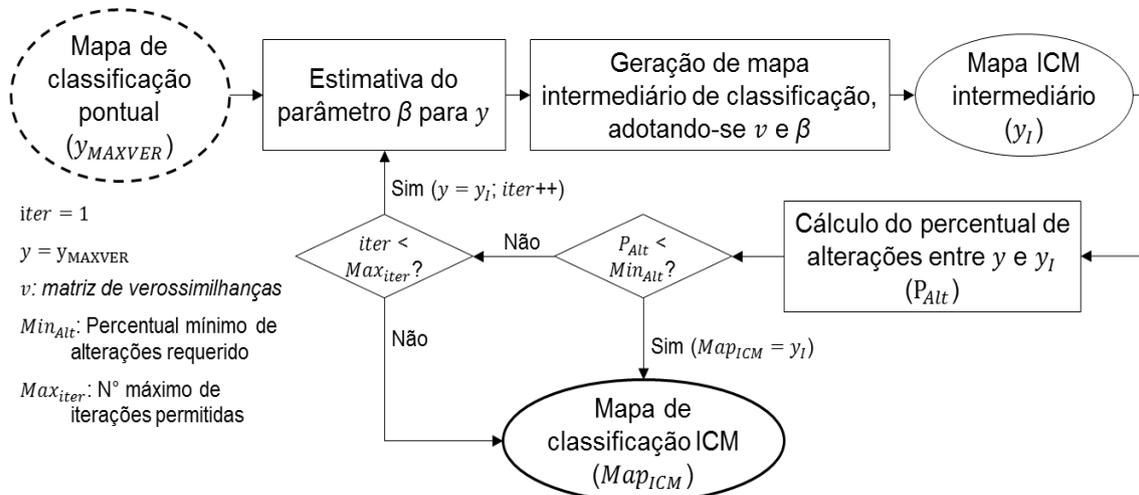
Para implementação do algoritmo ICM, conforme apresentado por Vieira (1996), são adotados como dados de entrada:

- uma estimativa inicial da cena original; sendo normalmente adotado o classificador MAXVER para obtenção da matriz de valores de verossimilhança (v) e do mapa de classificação pontual (y_{MAXVER});

- o número máximo de iterações permitidas (Max_{iter}), o qual é definido empiricamente e representa um dos critérios de parada do processo de classificação; e,
- o percentual mínimo de mudança (Min_{Alt}), a ser adotado como critério de convergência para a classificação.

De forma geral, o algoritmo ICM é implementado por meio dos procedimentos descritos na Figura 2.3. Primeiramente, realiza-se a estimativa do parâmetro β adotando o mapa de classificação pontual. Em seguida, gera-se o mapa intermediário de classificação, considerando o parâmetro β estimado, para obtenção de um vetor de pesos, e a matriz de verossimilhanças, obtida no processo de classificação pontual. Após a obtenção do mapa ICM intermediário, identifica-se o percentual de mudanças obtidos neste mapa intermediário, em relação ao mapa adotado no início da iteração. No caso da primeira iteração, o mapa intermediário é comparado com o mapa de classificação pontual. Este processo é repetido até que um dos critérios de parada seja alcançado. O primeiro critério de parada é a obtenção de um mapa de classificação que apresente um percentual de mudança, em relação ao mapa obtido na iteração anterior, inferior àquele pré-estabelecido. Caso este critério de parada não seja alcançado, é verificado também se foi realizado o número máximo de iterações permitidas.

Figura 2.3 – Princípio de funcionamento do algoritmo ICM.



Fonte: Produção do autor.

Conforme descrito por Vieira (1996), o parâmetro β é obtido pela raiz quadrada da equação de pseudoverossimilhança, descrita no anexo A. Esta equação leva em consideração o número de ocorrência de todas as configurações possíveis de vizinhança (*Viz*). No caso deste trabalho, é descrito e implementado o algoritmo ICM para vizinhança 8, ou seja, com uma janela móvel de 3x3 pixels. Neste caso, são possíveis no máximo 67 configurações de vizinhança, para uma classificação com pelo menos 9 classes. Estas configurações são descritas na Tabela 2.1. Na descrição de cada configuração, o primeiro valor (à esquerda) representa o número de pixels vizinhos atribuídos à mesma classe do pixel central. Os demais dígitos representam o número de pixels vizinhos referentes a outras classes, ordenados em ordem decrescente.

Tabela 2.1 – Lista de configurações possíveis para vizinhança 8.

<i>Viz</i> ₈	<i>Viz</i> ₇₁	<i>Viz</i> ₆₂	<i>Viz</i> ₆₁₁	<i>Viz</i> ₅₃	<i>Viz</i> ₅₂₁	<i>Viz</i> ₅₁₁₁
<i>Viz</i> ₄₄	<i>Viz</i> ₄₃₁	<i>Viz</i> ₄₂₂	<i>Viz</i> ₄₂₁₁	<i>Viz</i> ₄₁₁₁₁	<i>Viz</i> ₃₅	<i>Viz</i> ₃₄₁
<i>Viz</i> ₃₃₂	<i>Viz</i> ₃₃₁₁	<i>Viz</i> ₃₂₂₁	<i>Viz</i> ₃₂₁₁₁	<i>Viz</i> ₃₁₁₁₁₁	<i>Viz</i> ₂₆	<i>Viz</i> ₂₅₁
<i>Viz</i> ₂₄₂	<i>Viz</i> ₂₄₁₁	<i>Viz</i> ₂₃₃	<i>Viz</i> ₂₃₂₁	<i>Viz</i> ₂₃₁₁₁	<i>Viz</i> ₂₂₂₂	<i>Viz</i> ₂₂₂₁₁
<i>Viz</i> ₂₂₁₁₁₁	<i>Viz</i> ₂₁₁₁₁₁₁	<i>Viz</i> ₁₇	<i>Viz</i> ₁₆₁	<i>Viz</i> ₁₅₂	<i>Viz</i> ₁₅₁₁	<i>Viz</i> ₁₄₃
<i>Viz</i> ₁₄₂₁	<i>Viz</i> ₁₄₁₁₁	<i>Viz</i> ₁₃₃₁	<i>Viz</i> ₁₃₂₂	<i>Viz</i> ₁₃₂₁₁	<i>Viz</i> ₁₃₁₁₁₁	<i>Viz</i> ₁₂₂₂₁
<i>Viz</i> ₁₂₂₁₁₁	<i>Viz</i> ₁₂₁₁₁₁₁	<i>Viz</i> ₁₁₁₁₁₁₁₁	<i>Viz</i> ₀₈	<i>Viz</i> ₀₇₁	<i>Viz</i> ₀₆₂	<i>Viz</i> ₀₆₁₁
<i>Viz</i> ₀₅₃	<i>Viz</i> ₀₅₂₁	<i>Viz</i> ₀₅₁₁₁	<i>Viz</i> ₀₄₄	<i>Viz</i> ₀₄₃₁	<i>Viz</i> ₀₄₂₂	<i>Viz</i> ₀₄₂₁₁
<i>Viz</i> ₀₄₁₁₁₁	<i>Viz</i> ₀₃₃₂	<i>Viz</i> ₀₃₃₁₁	<i>Viz</i> ₀₃₂₂₁	<i>Viz</i> ₀₃₂₁₁₁	<i>Viz</i> ₀₃₁₁₁₁₁	<i>Viz</i> ₀₂₂₂₂
<i>Viz</i> ₀₂₂₂₁₁	<i>Viz</i> ₀₂₂₁₁₁₁	<i>Viz</i> ₀₂₁₁₁₁₁₁	<i>Viz</i> ₀₁₁₁₁₁₁₁₁			

Fonte: Produção do autor.

Após contabilizar o número de ocorrência de cada configuração de vizinhança, para toda a imagem, realiza-se o cálculo da raiz quadrada da equação de verossimilhança. Esta equação, adotada para estimação de β para vizinhança 8, é descrita no Anexo A, conforme apresentada por Vieira (1996). Para o cálculo desta equação é necessário a utilização de um parâmetro β inicial. Para a primeira iteração, pode ser adotado um valor inicial próximo de zero (e.g., 0,1). Para as demais iterações, considera-se o parâmetro β obtido na iteração anterior. Portanto, o processo para estimação de β ocorre conforme o pseudocódigo apresentado a seguir, no Algoritmo 1.

Algoritmo 1: Estimativa do parâmetro β

Entrada: Mapa de classificação (y)Saída: Parâmetro β

```
1  $Viz = 0$  #Vetor de contadores para todas as 67 configurações possíveis
2 Para  $lin = 1, \dots, Nr\_linhas(y)$  faça
3   Para  $col = 1, \dots, Nr\_colunas(y)$  faça
4     Determinar a configuração da vizinhança 3x3 do pixel  $y[lin, col]$ 
5     Incrementar o contador de coeficiente da configuração observada
6   Fim-Para
7 Fim-Para
8  $\beta =$  Raiz quadrada da equação de pseudoverossimilhança ( $Viz$ )
9 Retorna  $\beta$ 
```

Fonte: Adaptado de Vieira (1996).

Após a obtenção do parâmetro β , realiza-se a geração o mapa ICM intermediário. Este processo é realizado conforme o pseudocódigo descrito no Algoritmo 2. Nesta etapa, o parâmetro β é utilizado na obtenção de um vetor de pesos (e_β). Cada elemento deste vetor representa um peso a ser ponderado na matriz de verossimilhanças, considerando-se, para cada pixel, o número de pixels vizinhos referentes a cada classe. Por exemplo, caso um pixel $y[lin, col]$ possua três vizinhos referentes a uma determinada classe, o elemento da matriz de verossimilhanças referente a este pixel e classe será multiplicado pelo peso correspondente a este número de vizinhos (neste caso, $e^{-3\beta}$). Dessa forma, obtém-se uma nova matriz de verossimilhanças a ser adotada para geração de um novo mapa de classificação.

Algoritmo 2: Geração do mapa ICM intermediário

Entrada: Matriz de verossimilhanças (v)Mapa de classificação (y)Parâmetro β Saída: Mapa intermediário de classificação ICM (y_I)

```
1  $e_\beta = [1, e^{-\beta}, e^{-2\beta}, e^{-3\beta}, e^{-4\beta}, e^{-5\beta}, e^{-6\beta}, e^{-7\beta}, e^{-8\beta}]$ 
2  $y_I =$  Matriz de mesma dimensão do mapa  $y$ , sem valores atribuídos
3 Para  $lin = 1, \dots, Nr\_linhas(y)$  faça
4   Para  $col = 1, \dots, Nr\_colunas(y)$  faça
5      $Nviz_{classe} =$  vetor com o número de vizinhos por classe do pixel  $y[lin, col]$ 
6      $v_{pixel} = v(y[lin, col])$  # Vetor de verossimilhanças do pixel  $y[lin, col]$ 
7      $icm = e_\beta(Nviz_{classe}) * v_{pixel}$  # Resultado da multiplicação entre os elementos
8     dos vetores, considerando os mesmos índices
9      $y_I[lin, col] =$  Classe referente ao maior índice apresentado pelo vetor  $icm$ 
10   Fim-Para
11 Retorna  $Raster(y_I)$  # Mapa ICM intermediário no formato Raster
```

Fonte: Adaptado de Vieira (1996).

O mapa intermediário obtido (y_I) é então comparado ao mapa utilizado no início da iteração (y), a fim de se obter um percentual de mudanças. Em seguida, analisam-se os critérios de parada. Caso seja alcançado um dos critérios de parada, y_I representa o mapa final de classificação ICM. Por outro lado, caso não tenha alcançado um dos critérios de parada, o mapa ICM obtido nesta iteração é utilizado para obtenção de um novo parâmetro β . Neste caso, repete-se todo o processo até que ocorra convergência ou alcance o número máximo permitido de iterações.

Note que, em casos em que o β estimado é nulo, o algoritmo ICM resulta apenas na classificação pontual, enquanto que ao tender-se ao infinito ($\beta \rightarrow \infty$) o algoritmo representa o filtro de moda (CORREIA, 1998; VIEIRA, 1996). Mais detalhes sobre a formalização do algoritmo ICM, bem como de sua implementação, podem ser encontrados em Vieira (1996) e Correia (1998).

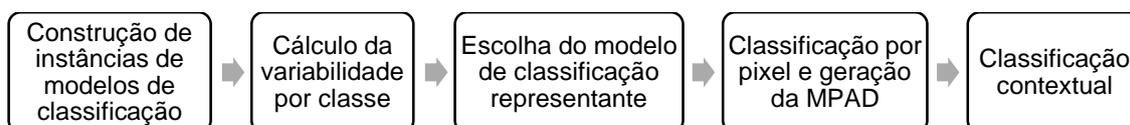
3 FORMALIZAÇÃO DA META-CCP PARA CLASSIFICAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO

Neste capítulo, é introduzida uma nova abordagem de classificação pixel a pixel, com integração de informação contextual, para classificação de imagens de sensoriamento remoto. A META-CCP é proposta visando permitir que ruídos oriundos do processo de classificação sejam eliminados durante a aplicação de classificadores contextuais, sem que a representação de outras feições, tais como feições estreitas, sejam afetadas. Além dos fluxogramas mostrados ao longo desta seção, a meta-metodologia proposta também é descrita na forma de pseudocódigos, apresentados no Apêndice A.

A META-CCP envolve o desenvolvimento de uma máscara de pixels de alta discriminabilidade (MPAD), a serem preservados durante a aplicação de métodos contextuais. Para obtenção desta máscara, é utilizado o classificador MAXVER. Porém, algumas alterações são adotadas em relação ao processo convencional de classificação. Normalmente, neste classificador se considera todo o conjunto de amostras de treinamento para se obter um modelo de classificação por classe. Porém, na abordagem proposta, diversas instâncias de modelos de classificação são geradas para cada classe de interesse.

A META-CCP é estruturada e distribuída nas fases apresentadas na Figura 3.1. Primeiramente, diferentes instâncias de modelos de classificação são construídas considerando diferentes subconjuntos de amostras. Posteriormente, calcula-se a variabilidade da modelagem da classe, seguido pela escolha de um modelo de classificação representante para cada classe. Em seguida, realiza-se a classificação pontual, além de serem identificados os pixels de alta discriminabilidade, a comporem a MPAD. Por fim, efetua-se a classificação contextual da imagem, utilizando a máscara gerada.

Figura 3.1 – Organização da META-CCP.



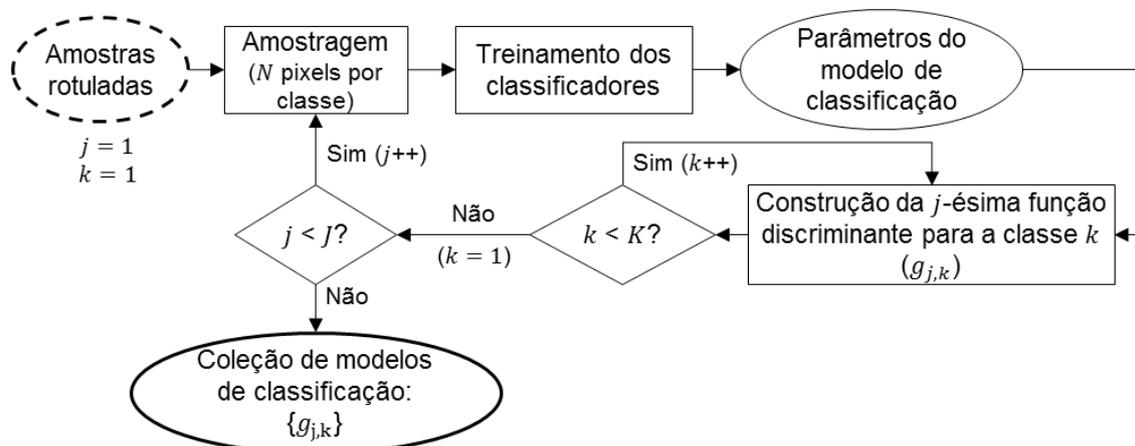
Fonte: Produção do autor.

3.1 Construção de instâncias de modelos de classificação

Nesta fase, a entrada é composta por um conjunto de amostras rotuladas, ou seja, de classes conhecidas. As amostras rotuladas são utilizadas para treinamento do classificador e construção de diversas instâncias de modelos de classificação. A cada iteração, o algoritmo considera um novo subconjunto de amostras por classe, obtido aleatoriamente a partir do conjunto total de amostras de treinamento, com reposição das amostras. Todos os subconjuntos são obtidos considerando um mesmo número de amostras, definido pelo usuário. Assim, a partir de cada subconjunto, obtém-se uma matriz de covariância e um vetor contendo a média dos valores amostrados por classe do subconjunto, em cada uma das bandas que compõem a imagem analisada. Estes são os parâmetros requeridos para estimar as funções discriminantes de máxima verossimilhança (conforme descrito na Equação 2.6).

Os procedimentos adotados para construção das instâncias de modelos de classificação são apresentados na Figura 3.2. Veja também o pseudocódigo apresentado no Apêndice A.1. Os parâmetros obtidos pelo treinamento do classificador são a matriz de covariância e o vetor de médias por classe. Neste fluxograma, o termo J define a quantidade total de modelos a serem gerados por classe (com $1 \leq j \leq J$) e K indica o número de classes (com $1 \leq k \leq K$). Nas etapas subsequentes, os modelos gerados são utilizados para cálculo da variabilidade observada em cada classe, conforme descrito na Seção 3.2.

Figura 3.2 – Fluxograma para construção de modelos de classificação.



Fonte: Produção do autor.

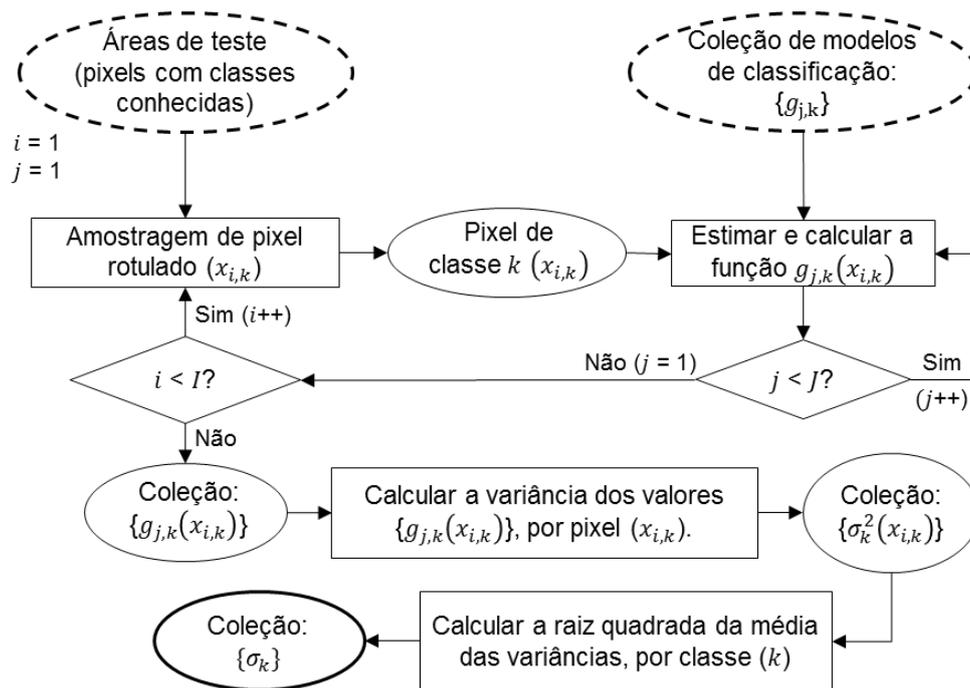
Destaca-se que a quantidade e qualidade de amostras consideradas em métodos supervisionados de classificação influencia diretamente os resultados obtidos (MAXWELL et al., 2018). A eficiência do classificador MAXVER depende de uma estimativa acurada da matriz de covariância e do vetor de médias, durante a etapa de treinamento, para cada classe de interesse. Ao se considerar poucas amostras, a variabilidade da média dos valores amostrados tende a ser maior, uma vez que o número de amostras não permite representar adequadamente a classe analisada. Além disso, o processo de classificação adotado neste trabalho, baseado na geração de múltiplos modelos de classificação por classe, permite reduzir da classificação a variabilidade ocasionada devido ao processo de amostragem, uma vez que são considerados diversos subconjuntos de amostras. Portanto, valores que melhor representam uma determinada classe tendem a serem obtidos à medida que se aumenta a quantidade de amostras e de iterações da reamostragem.

3.2 Cálculo da variabilidade por classe

Nesta fase, funções discriminantes de máxima verossimilhança são estimadas considerando os modelos de classificação obtidos anteriormente. As funções estimadas são calculadas considerando um conjunto de pixels rotulados, ou seja, de classes já conhecidas, inserido separadamente pelo usuário. A partir dos valores obtidos, é possível analisar a variabilidade das verossimilhanças para cada uma das classes analisadas. Nesse trabalho, o desvio padrão é adotado como medida de dispersão. Os desvios padrões obtidos serão utilizados, posteriormente, para identificação de pixels de alta discriminabilidade.

Os procedimentos adotados nesta fase são descritos na Figura 3.3, bem como no Apêndice A.2, na forma de pseudocódigo. São utilizados como dados de entrada: áreas de teste/validação, contendo pixels de classes já conhecidas para todas as classes analisadas; e, a coleção de modelos de classificação. Neste fluxograma, a quantidade de pixels rotulados a serem considerados é representada pelo termo I (com $1 \leq i \leq I$), enquanto que a quantidade de modelos de classificação é representada pelo termo J (com $1 \leq j \leq J$). A classe de cada pixel é indicada pelo termo k (com $1 \leq k \leq K$).

Figura 3.3 – Fluxograma para cálculo da variabilidade por classe.



Fonte: Produção do autor.

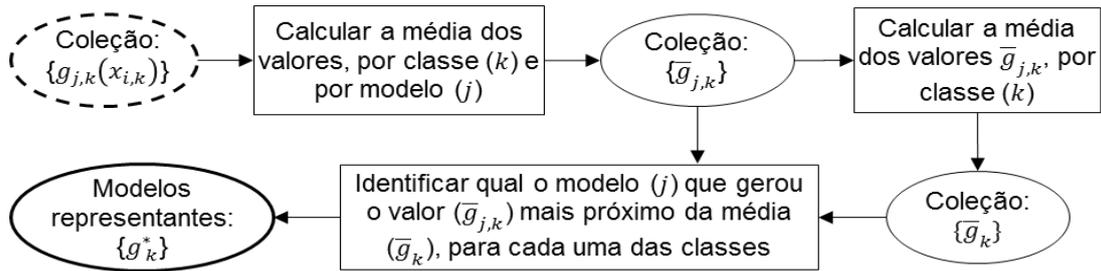
Dessa forma, para cada pixel amostrado ($x_{i,k}$), calcula-se um conjunto de funções discriminantes, considerando todos os J modelos de classificação $\{g_{j,k}\}$, obtidos na etapa anterior, para a classe (k) do pixel amostrado. Nesse sentido, $g_{j,k}(x_{i,k})$ representa o valor de verossimilhança calculado para um pixel $x_{i,k}$ em função de sua classe k e do modelo de classificação j .

Após a obtenção da coleção $\{g_{j,k}(x_{i,k})\}$, calcula-se a variância dos valores obtidos por pixel ($\sigma_k^2(x_{i,k})$), ou seja, considerando a variabilidade observada nos diversos modelos de classificação gerados para a classe k observada. Por fim, a partir desta coleção $\{\sigma_k^2(x_{i,k})\}$ é calculada a raiz quadrada da média das variâncias, obtendo-se um desvio padrão por classe (σ_k). Estes parâmetros são utilizados para identificação de pixels de alta discriminabilidade.

3.3 Escolha do modelo de classificação representante

Nesta fase, é identificado qual modelo de classificação será adotado para representar cada classe analisadas durante o processo de classificação por pixel. A escolha dos modelos representantes $\{g_k^*\}$ é realizada conforme descrito na Figura 3.4 (veja também o pseudocódigo no Apêndice A.3).

Figura 3.4 – Fluxograma para obtenção dos modelos representantes.



Fonte: Produção do autor.

Primeiramente, a coleção de valores de verossimilhança $\{g_{j,k}(x_{i,k})\}$, obtida na fase anterior, é utilizada visando-se obter uma média por classe e modelo ($\bar{g}_{j,k}$), ou seja, considerando-se a variação dos valores obtidos para todos os pixels rotulados. Em seguida, por meio dos valores contidos no conjunto $\{\bar{g}_{j,k}\}$, calcula-se o valor médio obtido para cada classe (\bar{g}_k). Por fim, identifica-se qual modelo de classificação (j) originou o valor contido na coleção $\{\bar{g}_{j,k}\}$ mais próximo do valor médio obtido para cada classe (\bar{g}_k), observando a diferença absoluta entre os valores. Os modelos selecionados nesta fase são utilizados para classificação da imagem completa.

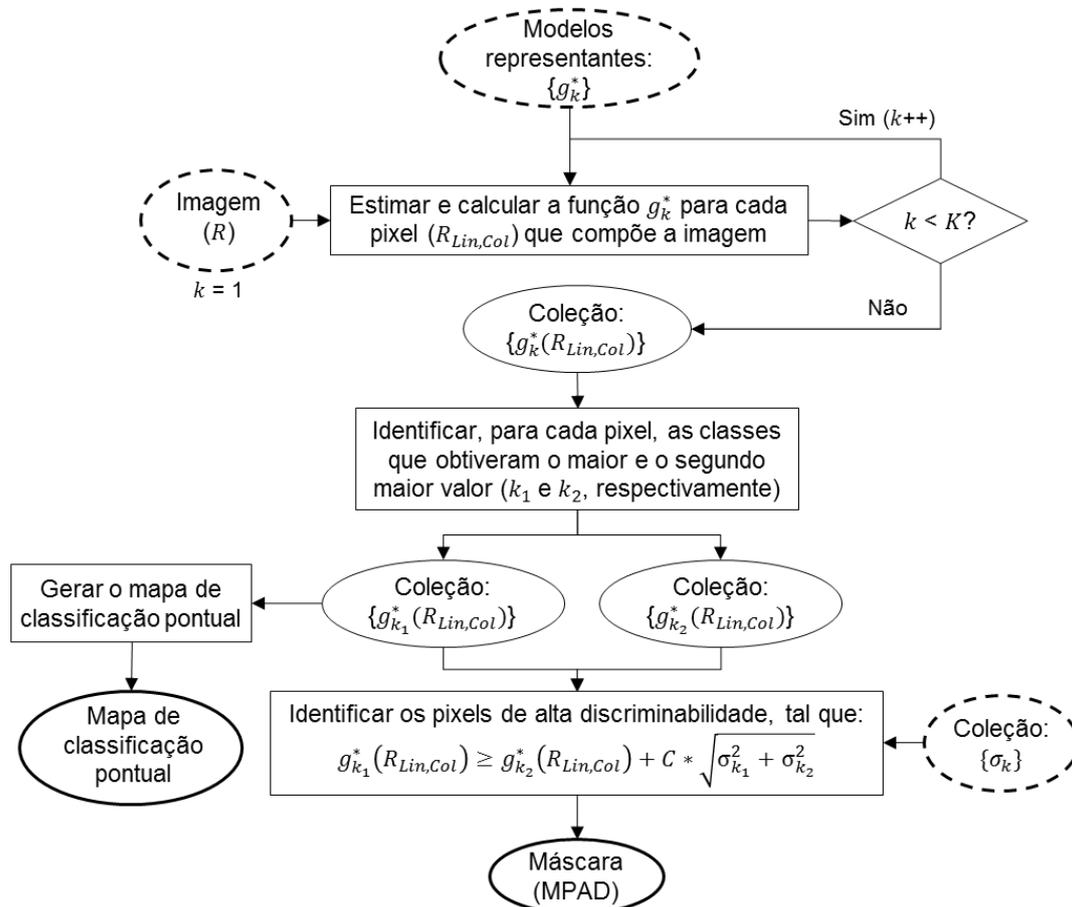
Destaca-se que, apesar do critério definido neste trabalho para escolha dos modelos representantes, outras abordagens podem ser consideradas. Por exemplo, pode ser gerado um modelo de classificação usando todo o conjunto de amostras de treinamento, a ser utilizado na classificação pixel a pixel.

3.4 Classificação por pixel e geração da máscara (MPAD)

Após a realização das fases anteriores, realiza-se a classificação pixel a pixel da imagem de interesse e a identificação dos pixels que irão compor a MPAD. Nesta fase, os dados de entrada são: a imagem a ser classificada (R); os modelos representantes $\{g_k^*\}$, obtidos anteriormente; e, a coleção contendo o desvio padrão obtido para cada classe $\{\sigma_k\}$, calculado anteriormente. Além desses, uma variável definida como fator C também é requerida. Este fator visa permitir que usuários modifiquem o limiar que define os pixels a serem considerados como de alta discriminabilidade. Mais detalhes sobre esta variável são fornecidos a seguir.

Esta fase é realizada seguindo as etapas apresentadas na Figura 3.5. Além disso, o pseudocódigo referente a esta fase é apresentado no Apêndice A.4. Primeiramente, é realizado o cálculo das funções discriminantes para cada pixel que compõe a imagem, adotando os modelos representantes definidos anteriormente. Por meio deste procedimento, obtém-se para cada pixel da imagem, uma coleção de valores de verossimilhança $\{g_k^*(R_{Lin,Col})\}$, referentes a todas as classes analisadas. A partir desses valores, é gerado o mapa de classificação pontual, atribuindo a cada pixel do mapa temático a classe à qual o pixel obteve seu maior valor de verossimilhança (máxima verossimilhança).

Figura 3.5 – Fluxograma para classificação por pixel e geração da MPAD.



Fonte: Produção do autor.

Em seguida, os pixels de alta discriminabilidade são identificados. Para cada pixel $(R_{Lin,Col})$ que compõe a imagem, consideram-se os dois maiores valores de verossimilhança obtidos. A META-CCP analisa, em cada pixel, a diferença entre o valor de máxima verossimilhança, relacionado à classe atribuída ao

pixel (referente ao maior valor), e o segundo maior valor obtido. Esta abordagem baseia-se na suposição de que quanto mais próximos forem os valores resultantes das funções discriminantes, maior é a probabilidade de ocorrência de um erro de classificação.

O fator C é definido neste trabalho como uma alternativa para se alterar o limiar que define os pixels de alta discriminabilidade. Este fator foi estabelecido com base na Razão Discriminante de Fisher (FDR, *Fisher Discriminant Ratio*). A FDR representa uma medida de divergência que permite computar o poder discriminatório entre elementos de duas classes normalmente distribuídas (THEODORIDIS et al., 2010). Quanto maior a FDR, maior o poder discriminatório entre os elementos. Esta medida é obtida pela relação entre a diferença quadrática entre duas médias (μ_1 e μ_2) e a soma das variâncias de suas respectivas classes (σ_1^2 e σ_2^2). A FDR é descrita da seguinte forma:

$$FDR = \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2 + \sigma_2^2} \quad (3.1)$$

Ao se substituir μ_1 e μ_2 pelos valores de verossimilhança obtidos utilizando os modelos representantes, esta medida de divergência pode ser utilizada a fim de se analisar o poder discriminatório entre duas classes (k_1 e k_2), para cada pixel que compõe a imagem analisada. Neste caso, define-se, para cada pixel da imagem, k_1 como a classe atribuída ao pixel e k_2 como a classe que apresentou o segundo maior valor de verossimilhança. Assim, a equação da FDR é manipulada da seguinte forma:

$$FDR = \frac{\left(g_{k_1}^*(R_{Lin,Col}) - g_{k_2}^*(R_{Lin,Col})\right)^2}{\sigma_{k_1}^2 + \sigma_{k_2}^2} \quad (3.2)$$

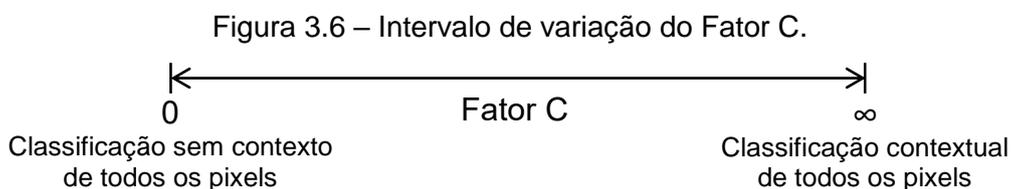
$$g_{k_1}^*(R_{Lin,Col}) = g_{k_2}^*(R_{Lin,Col}) + \sqrt{FDR} * \sqrt{\sigma_{k_1}^2 + \sigma_{k_2}^2} \quad (3.3)$$

Portanto, a fim de determinar pixels de alta discriminabilidade, o algoritmo proposto analisa a distância entre as duas maiores verossimilhanças obtidas para cada pixel. Para simplificar, define-se a raiz quadrada da FDR como o fator C. **O fator C pode ser interpretado como quantas vezes a distância**

normalizada da divergência, o usuário deseja que o valor $g_{k_1}^*$ seja maior do que $g_{k_2}^*$ para que o pixel seja considerado como um pixel de alta discriminabilidade. Assim, um pixel é considerado como de alta discriminabilidade, caso o valor $g_{k_1}^*$ associado a este pixel seja maior do que seu valor $g_{k_2}^*$, somado à raiz quadrada da soma das variâncias das classes, ponderada pelo fator C. Portanto, para identificação de pixels de alta discriminabilidade, a comporem a máscara a ser gerada, considera-se a equação descrita a seguir.

$$g_{k_1}^*(R_{Lin,Col}) \geq g_{k_2}^*(R_{Lin,Col}) + C * \sqrt{\sigma_{k_1}^2 + \sigma_{k_2}^2} \quad (3.4)$$

O fator C varia de zero a infinito, conforme apresentado na Figura 3.6. Caso esta variável seja zero, todos os pixels são considerados como pixels de alta discriminabilidade, uma vez que, por definição, $g_{k_1}^*(R_{Lin,Col})$ será sempre maior do que $g_{k_2}^*(R_{Lin,Col})$. Conseqüentemente, todos os pixels serão preservados durante a abordagem contextual, e o mapa temático final será equivalente ao mapa de classificação por pixel, ou seja, sem consideração do contexto. Por outro lado, à medida que o fator C aumenta, o limiar tende a considerar um menor número de pixels como sendo de alta discriminabilidade. Conseqüentemente, mais pixels podem ser reclassificados pela abordagem contextual. Após o fator C atingir um determinado valor, o qual varia de acordo com a imagem analisada, o limiar não abrange nenhum pixel. Neste caso, o mapa final de classificação será equivalente ao mapa obtido pela aplicação convencional do método de classificação contextual considerado.



Fonte: Produção do autor.

O fator C a ser utilizado varia de acordo com as classes. Em geral, valores menores são indicados caso o interesse principal seja preservar feições estreitas. Neste caso, alguns pixels ruidosos podem ser reclassificados, sem

que representações de feições estreitas sejam danificadas. Por outro lado, caso o foco principal seja remover o máximo possível ruídos de classificação, maiores valores podem ser utilizados.

Neste estudo, alguns experimentos foram realizados visando avaliar a meta-metodologia de classificação proposta ao se considerar diferentes métodos contextuais de classificação. Além disso, os experimentos permitiram estabelecer exemplos de valores que podem ser utilizados como fator C. Estes experimentos são discutidos nas próximas seções.

3.5 Classificação contextual

A META-CCP permite que sejam considerados diferentes classificadores na etapa de classificação contextual. Neste trabalho, considera-se a aplicação de duas abordagens contextuais: o filtro de maioria e o algoritmo ICM. Nesta fase, a aplicação do classificador contextual é destinada apenas às áreas da imagem em que a classificação definida não é claramente distinta das demais alternativas, ou seja, aos pixels que podem ter sido erroneamente classificados. Para estes casos, onde foi observada uma baixa discriminabilidade entre as classes, será também integrada a informação espacial durante o processo de classificação. De forma geral, os procedimentos adotados nesta fase são descritos na Figura 3.7. Além disso, o pseudocódigo referente a esta fase é apresentado no Apêndice A.5.

Figura 3.7 – Fluxograma para classificação contextual.

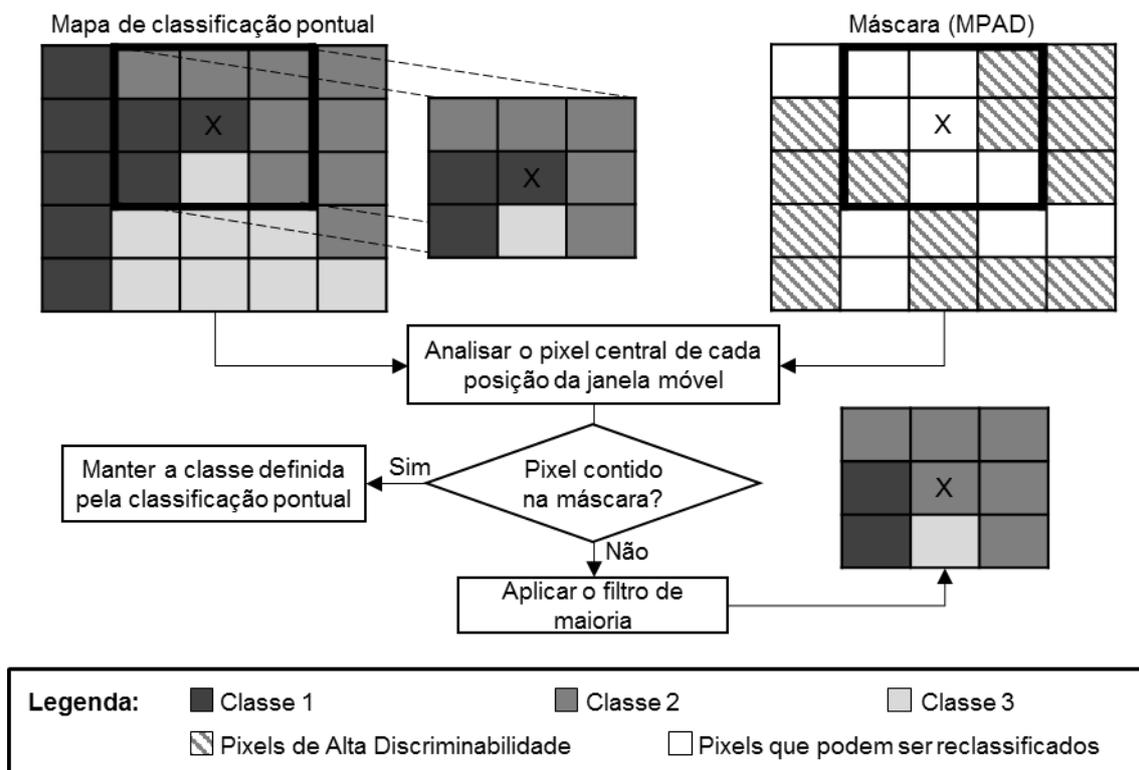


Fonte: Produção do autor.

No caso do filtro de maioria, por exemplo, ao se deslocar a janela móvel sobre a imagem, aplica-se a filtragem apenas nas posições da janela móvel em que o pixel central não tenha sido identificado, na máscara gerada, como um pixel de alta discriminabilidade. Este procedimento, ilustrado na Figura 3.8, visa

remover os ruídos oriundos da classificação pontual sem afetar a resolução obtida pelo classificador para este conjunto de pixels. O tamanho da janela móvel a ser considerada durante a aplicação do filtro de maioria varia conforme o estudo realizado. O exemplo apresentado abaixo considera uma janela móvel com dimensão de 3x3 pixels. Neste exemplo, o filtro de maioria é aplicado e o pixel central alterado para a classe da maioria.

Figura 3.8 – Fluxograma para geração da MPAD.



Fonte: Produção do autor.

Em relação à abordagem de filtragem baseada no algoritmo ICM, a adaptação necessária para preservação dos pixels de alta discriminabilidade seguiu a mesma lógica usada para aplicação do filtro de maioria. Porém, neste trabalho considera-se apenas a aplicação do algoritmo ICM, que é iterativo, com janela móvel de 3x3 pixels (vizinhança 8), ao contrário do filtro de maioria, em que testa-se a utilização de janelas móveis quadradas de diferentes dimensões. O algoritmo ICM foi implementado conforme descrito por Vieira (1996).

4 EXPERIMENTOS E RESULTADOS

Neste capítulo, são descritos alguns experimentos realizados visando avaliar a eficiência da META-CCP, tanto em relação à remoção de ruídos de classificação quanto à preservação de feições estreitas. Além disso, este capítulo descreve os procedimentos adotados para geração de imagens sintéticas. Essas imagens sintéticas, as quais apresentam comportamento conhecido, foram geradas a fim de favorecer uma avaliação inicial da META-CCP, antes do processamento de uma imagem real de sensoriamento remoto.

Em todos os experimentos realizados, os resultados de classificação gerados pela META-CCP foram comparados aos resultados obtidos a partir das abordagens convencionais utilizando:

- o classificador MAXVER, supervisionado e do tipo pixel a pixel, discutido na Seção 2.2. O produto gerado por este classificador foi comparado ao mapa de classificação pontual obtido por meio da abordagem proposta, onde adota-se a geração de diversos modelos de classificação para cada uma das classes de interesse;
- o filtro de maioria, aplicado sobre o mapa de classificação pontual gerado pelo algoritmo proposto, considerando janelas móveis quadradas de diferentes dimensões. Este método, discutido na Seção 2.3.1, representa uma das abordagens de classificação contextual adotadas neste trabalho. Nos experimentos realizados, foram consideradas janelas móveis quadradas de 3x3, 5x5 e 7x7 pixels;
- o algoritmo ICM, para vizinhança 8, ou seja, considerando uma janela móvel quadrada de 3x3 pixels, conforme descrito por Vieira (1996) e implementado por Correia (1998). Nesse trabalho, avaliou-se também a eficiência da abordagem de classificação proposta ao se utilizar o algoritmo ICM, descrito na Seção 2.3.1, durante a etapa de classificação contextual, com preservação de pixels de alta discriminabilidade. Os critérios de parada adotados foram: a obtenção de um percentual de mudança inferior a 5%; e, a realização de no máximo 20 iterações.

A meta-metodologia de classificação proposta, bem como os experimentos realizados, foram implementados utilizando a linguagem R. Este ambiente de programação, além de ser gratuito, destaca-se por oferecer funcionalidades que favorecem a implementação de diversas técnicas estatísticas, propiciando assim, o desenvolvimento de estudos que requerem análise e manipulação de grande quantidade de dados (R CORE TEAM, 2014). Além disso, o software ENVI (*Environment for Visualizing Images*) foi utilizado para coleta das amostras necessárias para classificação supervisionada.

4.1 Estudo de caso I: classificação de imagens sintéticas

Este estudo de caso tem por objetivo verificar a capacidade da META-CCP tanto na remoção de ruídos de classificação quanto na preservação de feições lineares estreitas, de diferentes larguras, em imagens sintéticas compostas por diferentes pares de classes. Os pares de classes foram definidos de forma a simular níveis variados de discriminabilidade entre classes. Na Seção 4.1.1, descreve-se o processo adotado para geração de imagens sintéticas. Detalhes sobre o processamento das imagens, bem como a apresentação e análise dos resultados obtidos, são descritos na Seções 4.1.2 e 4.1.3.

4.1.1 Simulação de imagens

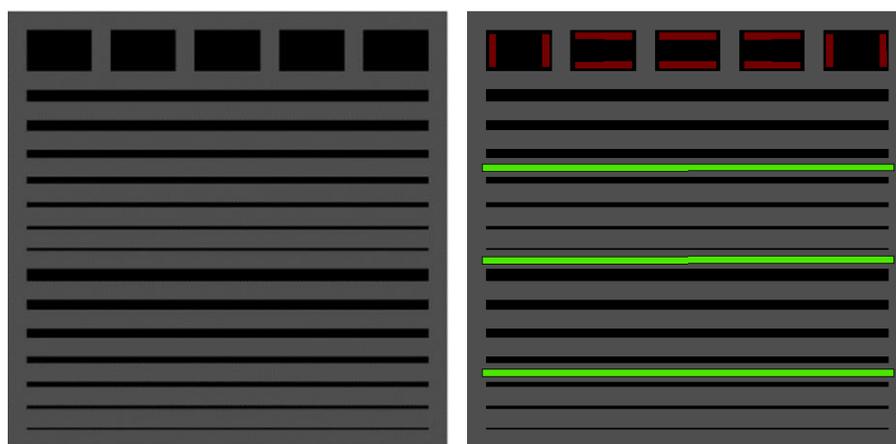
O uso de imagens sintéticas permite que diferentes situações sejam avaliadas por meio de experimentos controlados, ou seja, testes em que o comportamento dos dados é conhecido a priori. A metodologia adotada para geração de imagens sintéticas foi realizada conforme apresentado por Negri (2013). Nesta abordagem, o processo de simulação de imagens é dividido em duas etapas principais: obtenção da imagem base (modelo), com a distribuição dos alvos; e definição do comportamento espectral dos alvos que compõem a imagem base.

Embora em imagens reais de sensoriamento remoto diversos processos ocorram simultaneamente entre elementos de várias classes, neste estudo imagens sintéticas foram geradas atribuindo elementos referentes a apenas duas classes: uma referente ao plano de fundo e outra referente a elementos em primeiro plano. Nessas imagens sintéticas, a classe de fundo representa

aquela dominante ao longo da imagem. No contexto abordado neste trabalho, esta representa a classe a ser filtrada pela abordagem contextual. Por outro lado, a classe de primeiro plano representa a classe de interesse, que neste caso está associada a feições estreitas, tais como rios e estradas. Este tipo de imagem, com feições referentes a apenas duas classes, favorece a validação inicial da metodologia proposta.

A imagem base possui dimensão de 256 x 256 pixels e contém feições lineares com diferentes larguras. Além disso, a imagem também contém feições retangulares, de maior dimensão. Na parte superior da imagem localizam-se 5 estruturas retangulares com dimensão de 24 x 38 pixels. Estas feições maiores foram inseridas a fim de permitir avaliar a acurácia de classificações em regiões largas, referentes a áreas centrais, ou seja, longe de bordas. Logo abaixo das feições retangulares, estão inseridas estruturas lineares com larguras que variam de 1 a 7 pixels. Nesta imagem, estão distribuídas 2 estruturas lineares para cada uma dessas 7 diferentes larguras. Todas as feições de primeiro plano apresentam uma distância de 11 pixels entre si, incluindo a distância entre estas feições e as bordas da imagem. A imagem base é apresentada na Figura 4.1(a). As áreas destinadas a coleta de amostras de treinamento são definidas na Figura 4.1(b).

Figura 4.1 – (a) Imagem base e (b) áreas para coleta de amostras de treinamento.



(a)

(b)

■ Classe de fundo

■ Classe de primeiro plano

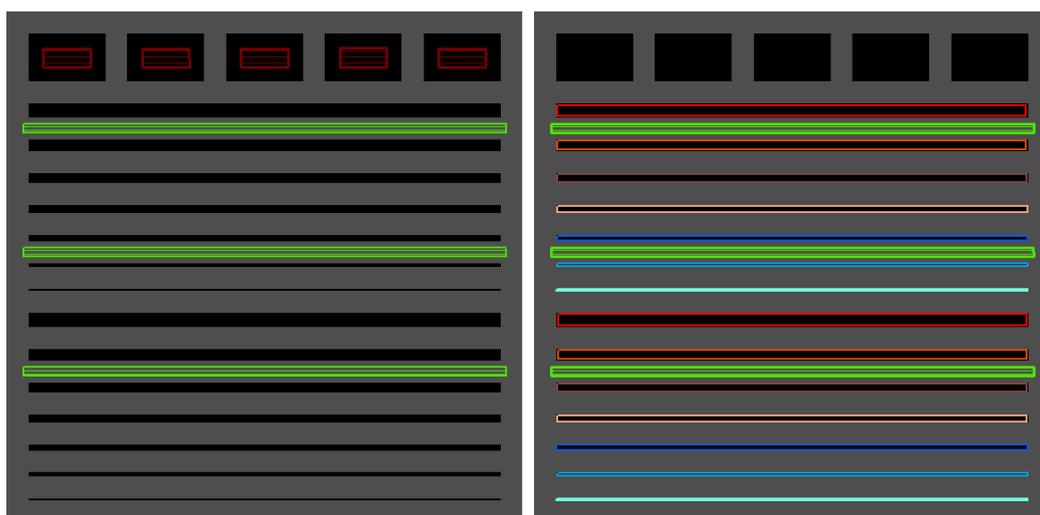
Amostras de treinamento: ■ classe de fundo ■ classe de primeiro plano

Fonte: Produção do autor.

Destaca-se que a obtenção de amostras de treinamento em áreas próximas às bordas das feições não afeta o processo de classificação, uma vez que o processo de geração das imagens baseia-se em uma reamostragem aleatória dos pixels. Mais detalhes sobre este processo são apresentados a seguir. Áreas centrais das feições largas foram destinadas à coleta de amostras de teste. Neste trabalho, estatísticas computadas considerando estas amostras são definidas como estatísticas globais.

Além disso, são geradas também estatísticas referentes às feições estreitas, denominadas como estatísticas locais. Estas estatísticas são computadas separadamente para cada uma das 7 diferentes larguras das estruturas lineares. Para cada estatística (referente a cada largura), considera-se o mesmo número de amostras referente às feições estreitas e à classe de fundo. Na Figura 4.2(a) são apresentadas as áreas destinadas à coleta de amostras de teste para as estatísticas globais. Na Figura 4.2(b) apresentam-se as áreas destinadas à coleta de amostras de teste para estatísticas locais, coletadas sobre as áreas definidas pelas próprias feições estreitas. Neste caso, para a classe de fundo, mantém-se as áreas definidas para as estatísticas globais.

Figura 4.2 – Áreas destinadas a coleta de amostras de teste para (a) feições largas (estatísticas globais) e (b) feições estreitas (estatísticas locais).



(a)

(b)

Feições largas: ■ Classe de fundo ■ Classe de primeiro plano

Feições por largura: ■ 1px ■ 2px ■ 3px ■ 4px ■ 5px ■ 6px ■ 7px

Fonte: Produção do autor.

Após a definição da imagem base, define-se o comportamento espectral de todos os pixels que compõem a imagem. Este processo é realizado a partir da reamostragem de atributos de pixels coletados sobre uma imagem real de sensoriamento remoto, para os alvos de interesse. Neste processo, cada classe da imagem sintética é associada a uma classe de cobertura da terra amostrada em imagem real. O valor digital associado a cada pixel na imagem sintética é definido aleatoriamente a partir do conjunto de amostras para sua classe. Neste processo, foram compostas imagens sintéticas multiespectrais, compostas por 4 canais. Portanto, dado um pixel, recuperam-se os valores das bandas correspondentes, mantendo-se assim a correlação entre bandas, mas perdendo-se a auto correlação espacial.

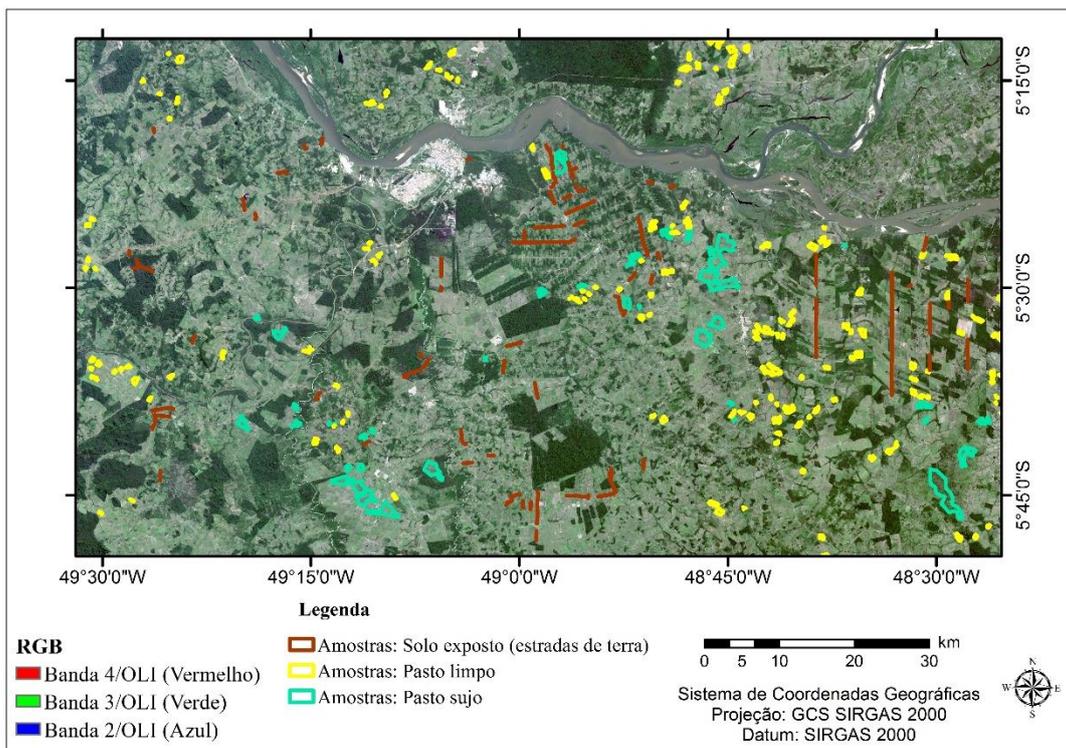
Os canais espectrais e os pares de classes escolhidos para compor as imagens sintéticas foram definidos de forma a se obter imagens com diferentes contrastes entre os alvos. Esta diferença de contraste permite a obtenção de mapas de classificação pontual com diferentes níveis de confusão entre as classes. As amostras utilizadas para composição das imagens sintéticas foram adquiridas a partir de um recorte de imagem Landsat-8/OLI, com dimensão de 2319 x 4142 pixels. Nessa imagem, amostras foram coletadas considerando as bandas espectrais referentes à faixa do visível (vermelho, verde e azul) e do infravermelho-próximo. Os pares de classes foram definidos de forma a se considerar sempre uma classe normalmente associada a feições estreitas em imagens Landsat-8/OLI. Este sensor possui resolução espacial de 30 metros.

Os tipos de cobertura da terra identificados nessa imagem incluem: água, área urbana, floresta, pasto limpo, pasto sujo e vegetação secundária. Além disso, feições referentes a pequenos rios e estradas não pavimentadas (estradas de terra) também podem ser identificadas. Esta imagem foi gerada em 12 de Junho de 2014 pelo sensor OLI, a bordo do satélite Landsat-8, sobre uma região do município de Marabá (órbita/ponto: 223/064), no estado do Pará.

Dentre as classes de cobertura da terra observadas na imagem, foram obtidas amostras em áreas de: água, referente a pequenos rios; solo exposto, para classificação de estradas de terra; floresta, relativo a áreas de vegetação

primária; pasto limpo, referente a áreas de pastagem com ausência de indivíduos arbóreos; pasto sujo, relativo a áreas de pastagem com vegetação arbustiva esparsa; e, vegetação secundária, para áreas em estágio de regeneração. A partir de uma análise inicial do conjunto de amostras, definiram-se dois pares de classes que apresentam baixo e médio contraste para geração das imagens sintéticas. Estas características foram definidas visando a obtenção de mapas de classificação com diferentes níveis de ruídos. A Figura 4.3 ilustra a imagem utilizada para coleta das amostras, bem como os alvos amostrados para a composição das imagens sintéticas.

Figura 4.3 – Imagem Landsat-8/OLI e amostras utilizadas para compor imagens sintéticas.



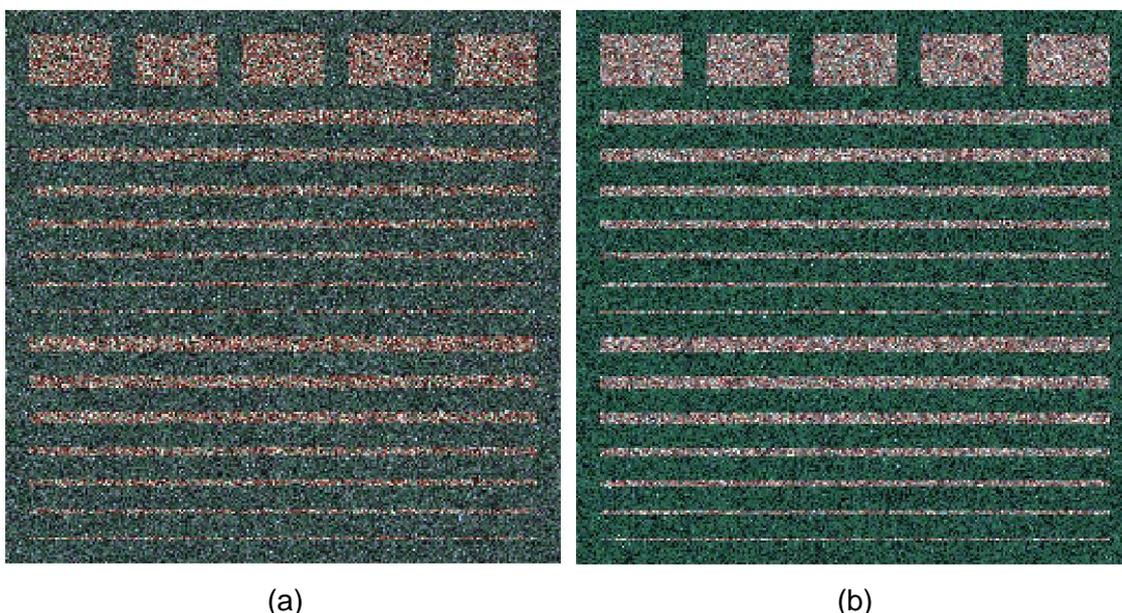
Fonte: Produção do autor.

Amostras referentes a áreas de pasto limpo e solo exposto (estradas de terra) foram utilizadas para geração de uma imagem sintética com baixo contraste. Destaca-se que áreas de pasto limpo podem também incluir vegetação esparsa e solo nu. Dessa forma, amostras coletadas nestas áreas podem resultar em muitos erros de classificação, devido à alta similaridade observada entre estes pixels e os pixels que representam áreas de estradas de terra, as quais são

geralmente compostas principalmente por solo exposto. A Figura 4.4(a) ilustra esta imagem sintética, composta por amostras de pasto limpo e solo exposto.

Por outro lado, amostras referentes a áreas de pasto sujo e de solo exposto foram utilizadas para geração de uma imagem com médio contraste. Devido ao fato de áreas de pasto sujo apresentarem maior cobertura vegetal, esta imagem sintética tende a apresentar um menor nível de ruído. Além disso, destaca-se que a resolução espacial do sensor OLI, responsável pela aquisição da imagem, é maior do que a largura das vias não pavimentadas observadas na imagem. Portanto, os pixels amostrados para esta classe sofrem grande influência do tipo de cobertura da terra em áreas adjacentes, as quais neste caso geralmente referem-se a áreas de pasto limpo e de solo exposto. Esta característica também contribui para a obtenção de produtos ruidosos, os quais favorecem a validação do método proposto. Esta imagem sintética, composta por amostras de pasto sujo e solo exposto, é apresentada na Figura 4.4(b).

Figura 4.4 – Imagens sintéticas com (a) baixo contraste (amostras de pasto limpo e solo exposto) e (b) médio contraste (amostras de pasto sujo e solo exposto).



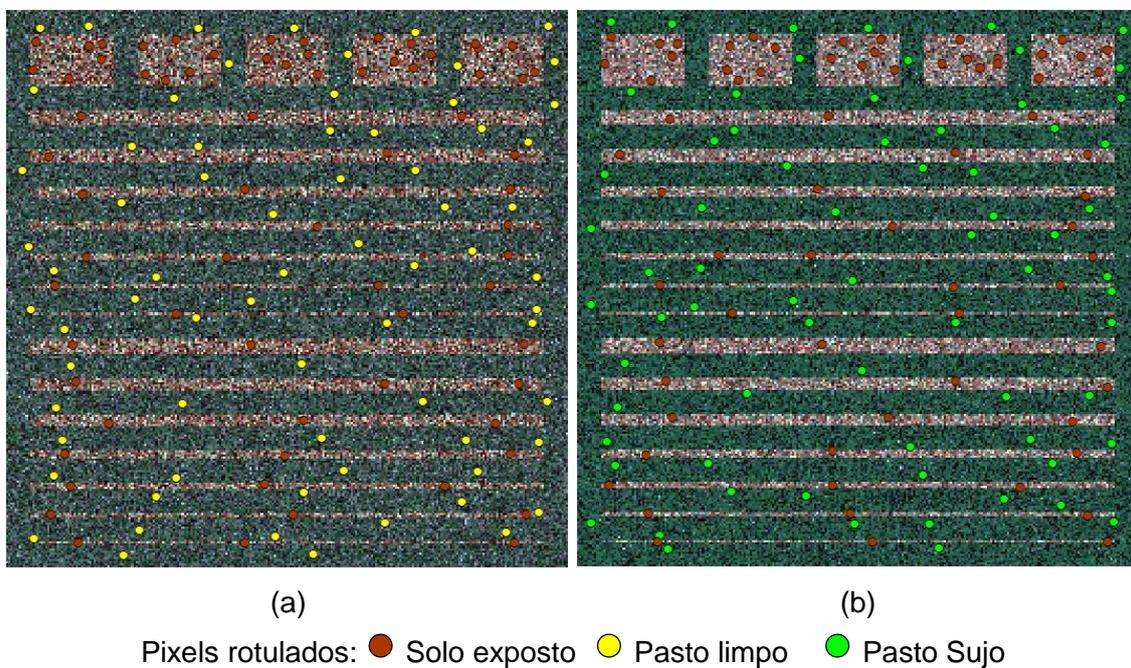
Fonte: Produção do autor.

4.1.2 Classificação das imagens com baixo e médio contraste

Ambas as imagens sintéticas geradas foram classificadas utilizando os procedimentos descritos na Seção 3. O primeiro passo foi a definição dos

dados de entrada: conjuntos de amostras de treinamento/teste e de pixels rotulados. As amostras de treinamento e de teste foram definidas considerando as áreas apresentadas na Seção 4.1.1 (Figuras 4.1 e 4.2). O conjunto de pixels rotulados definidos para ambas as imagens sintéticas são apresentados na Figura 4.5. Estes pixels foram utilizados para o cálculo da variabilidade de cada uma das classes, diminuindo-se a influência de pixels ruidosos. Para cada uma das classes analisadas, foram definidos 70 pixels que exemplificam o padrão observado na maioria das amostras que compõem as imagens sintéticas.

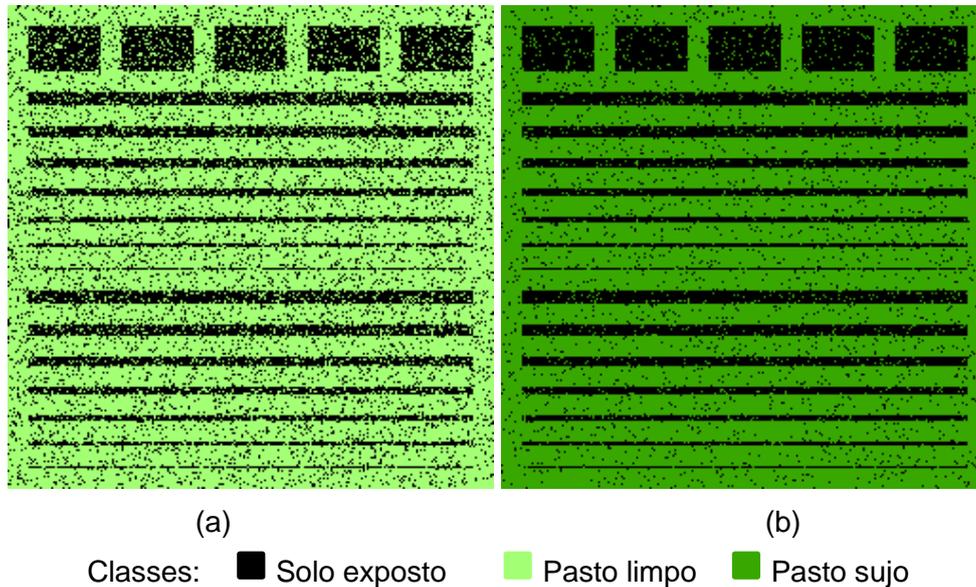
Figura 4.5 – Pixels rotulados definidos para a (a) imagem sintética com baixo contraste e a (b) imagem sintética com médio contraste.



Fonte: Produção do autor.

No primeiro estágio do processo de classificação por pixel, foram gerados 100 modelos de classificação. Para a obtenção de cada modelo, considerou-se um conjunto de 500 amostras por classe, sendo estas obtidas aleatoriamente a partir das regiões definidas para aquisição de amostras de treinamento. Os mapas de classificação pontual obtidos são apresentados na Figura 4.6. Note a diferença no nível de ruídos entre os mapas de classificação resultantes. O mapa temático resultante da classificação da imagem sintética com baixo contraste é significativamente mais ruidoso do que o produto de classificação obtido para a imagem sintética com médio contraste.

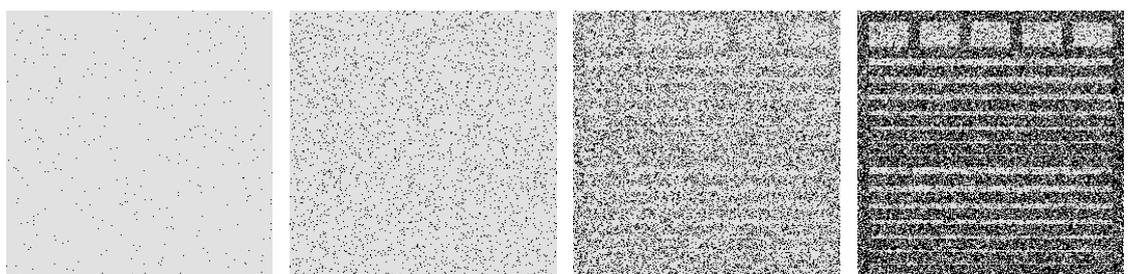
Figura 4.6 – Mapas de classificação MAXVER obtidos para a (a) imagem sintética com baixo contraste e a (b) imagem sintética com médio contraste.



Fonte: Produção do autor.

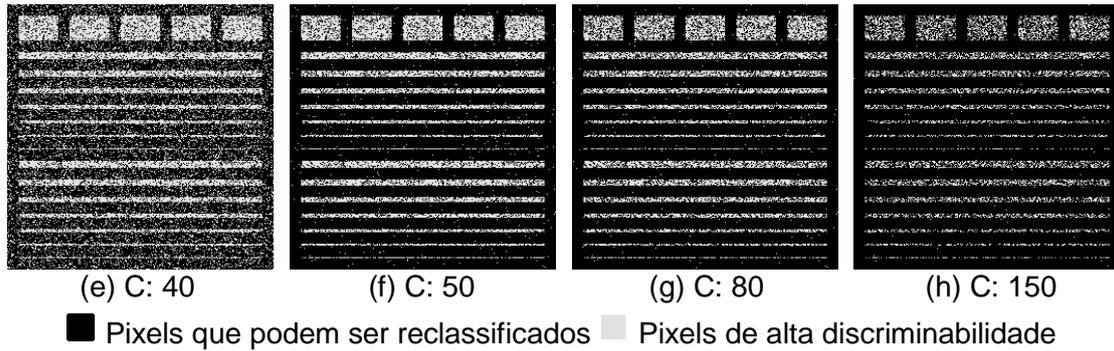
Quanto ao processo de identificação de pixels de alta discriminabilidade, diversas máscaras foram geradas a fim de avaliar o efeito da utilização de diferentes fatores C na abordagem de classificação proposta. Neste experimento, foram produzidas 150 máscaras, para cada imagem sintética, adotando fatores C de 1 a 150, com incremento de 1. Algumas das máscaras geradas para a imagem com médio contraste são apresentadas na Figura 4.7. Note que à medida que se aumenta o fator C , maior é o número de pixels que podem ser reclassificados pela abordagem contextual. Em outras palavras, quanto maior o fator C , mais próximo o produto final de classificação se torna do mapa obtido pela aplicação convencional do classificador contextual.

Figura 4.7 – Exemplos de máscaras de pixels de alta discriminabilidade obtidas para a imagem sintética com médio contraste.



(continua)

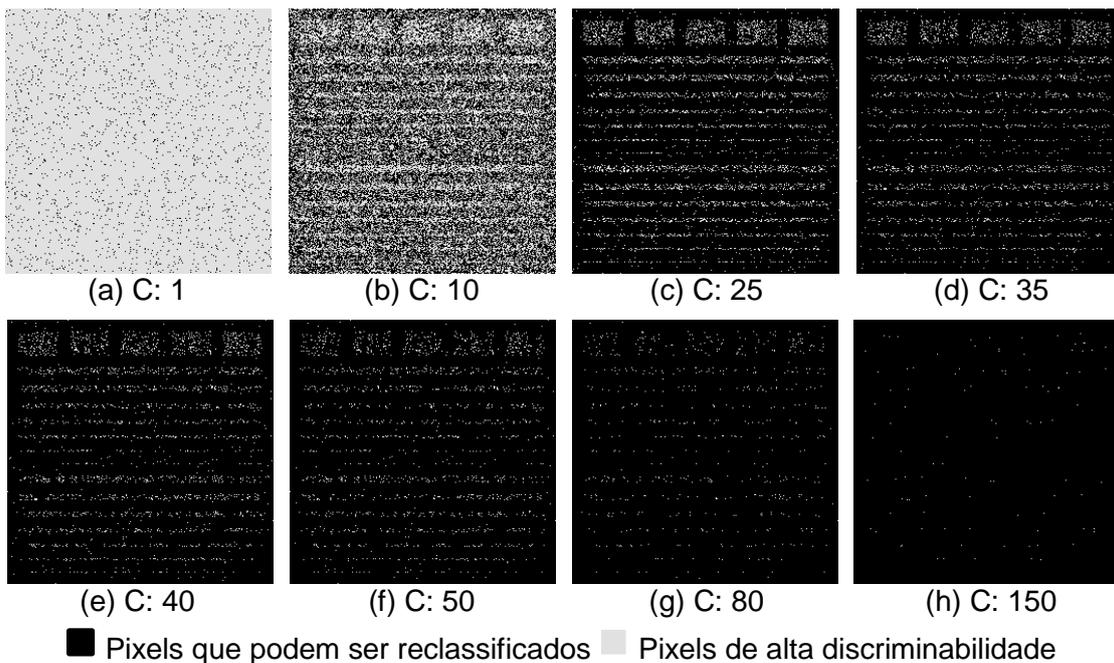
Figura 4.7 – Conclusão.



Fonte: Produção do autor.

Exemplos de máscaras geradas para a imagem com baixo contraste são apresentados na Figura 4.8. Note que o menor contraste entre os alvos presentes na imagem resultou em máscaras com um maior número de pixels que podem ser reclassificados, se comparado às máscaras obtidas na imagem com médio contraste, para os mesmos fatores C. Este efeito ocorre devido à maior proximidade dos valores de verossimilhança obtidos pelo classificador MAXVER, ou seja, pelo maior similaridade observada entre os alvos. Esta característica reduz o número de pixels a atenderem a condição descrita da equação 3.4 (Seção 3.4), para definição de pixels de alta discriminabilidade.

Figura 4.8 – Exemplos de máscaras de pixels de alta discriminabilidade obtidas para a imagem sintética com baixo contraste.

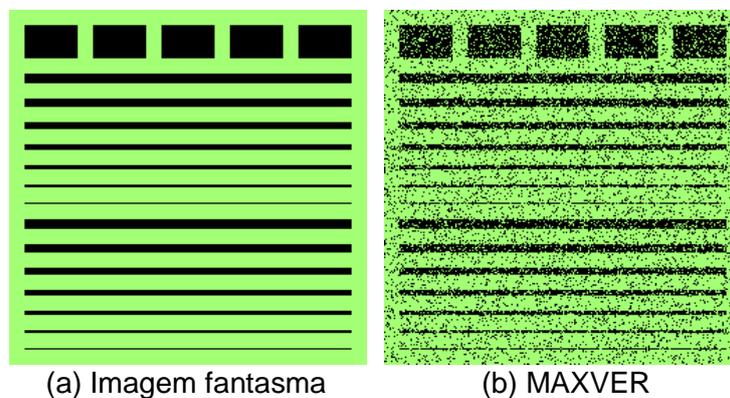


Fonte: Produção do autor.

Após a obtenção dos mapas de classificação pontual e das máscaras que definem os pixels a serem preservados e reclassificados, realiza-se o processo de classificação contextual. Neste experimento, classificações foram realizadas para todas as 150 MPAD geradas, para cada uma das imagens sintéticas. Esta etapa foi realizada considerando duas abordagens contextuais: filtro de maioria e algoritmo ICM. Para fins de comparação, os mapas de classificação obtidos foram também classificados considerando a aplicação convencional destes métodos contextuais. No caso do filtro de maioria, consideram-se nesse trabalho janelas móveis de 3x3, 5x5 e 7x7 pixels. O algoritmo ICM é aplicado apenas para vizinhança 8, ou seja, com janela móvel de 3x3 pixels.

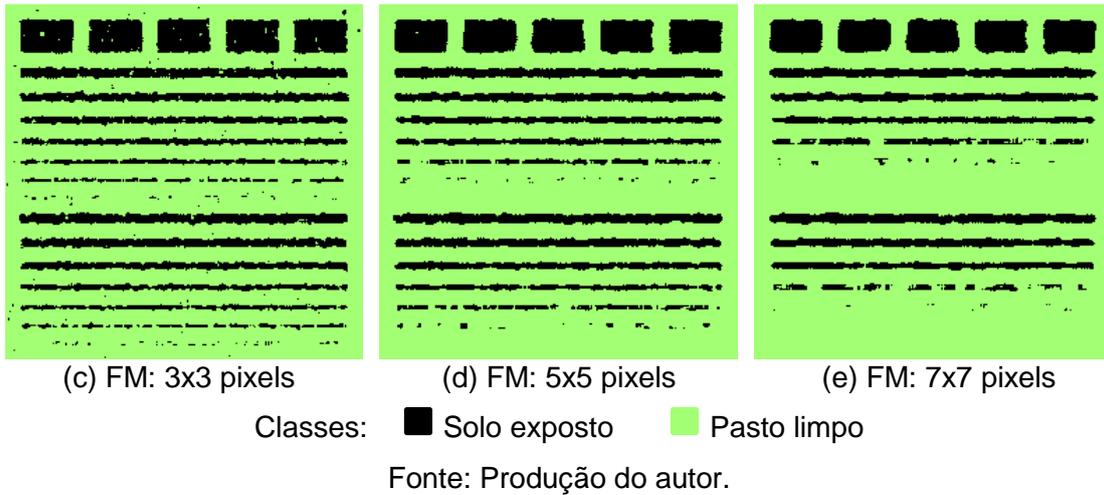
Primeiramente, observe os resultados obtidos a partir da aplicação convencional do filtro de maioria (FM). Estes produtos de classificação evidenciam o problema de retratado nesse trabalho. A Figura 4.9 apresenta os produtos obtidos pela classificação da imagem sintética com baixo contraste, considerando janelas móveis de 3x3, 5x5 e 7x7 pixels (Figura 4.9(c), Figura 4.9(d) e Figura 4.9(e), respectivamente). Por meio destes mapas é possível observar que a aplicação do filtro de maioria permite que grande parte dos ruídos presentes no produto de classificação pontual sejam removidos. Entretanto, este processo resulta também na deterioração de feições estreitas. A Figura 4.9(a) ilustra a imagem fantasma para a classificação da imagem sintética com baixo contraste. Esta imagem fantasma ilustra o resultado esperado em caso de uma classificação perfeita da imagem sintética.

Figura 4.9 – Produtos oriundos de classificação convencional, obtidos para a imagem sintética com baixo contraste.



(continua)

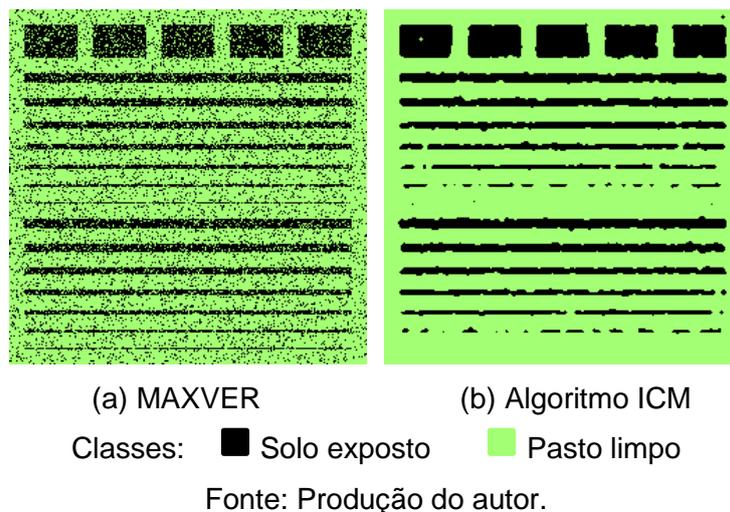
Figura 4.9 – Conclusão.



À medida que se aumenta o tamanho da janela móvel, aumenta-se também o tamanho das feições afetadas pela operação de filtragem. A aplicação do filtro de maioria com janela móvel de 3x3 pixels afetou principalmente a representação de feições com 1 pixel de largura. Porém, conforme apresentado na Figura 4.9, feições lineares com até 4 pixels de largura foram afetadas pelo filtro de maioria convencional, ao se adotar uma janela móvel de 7x7 pixels.

Estes efeitos podem ser também notados ao se adotar o algoritmo ICM como abordagem de classificação contextual, conforme apresentado na Figura 4.10.

Figura 4.10 – Produto de classificação obtido pelo algoritmo ICM convencional, para a imagem sintética com baixo contraste.

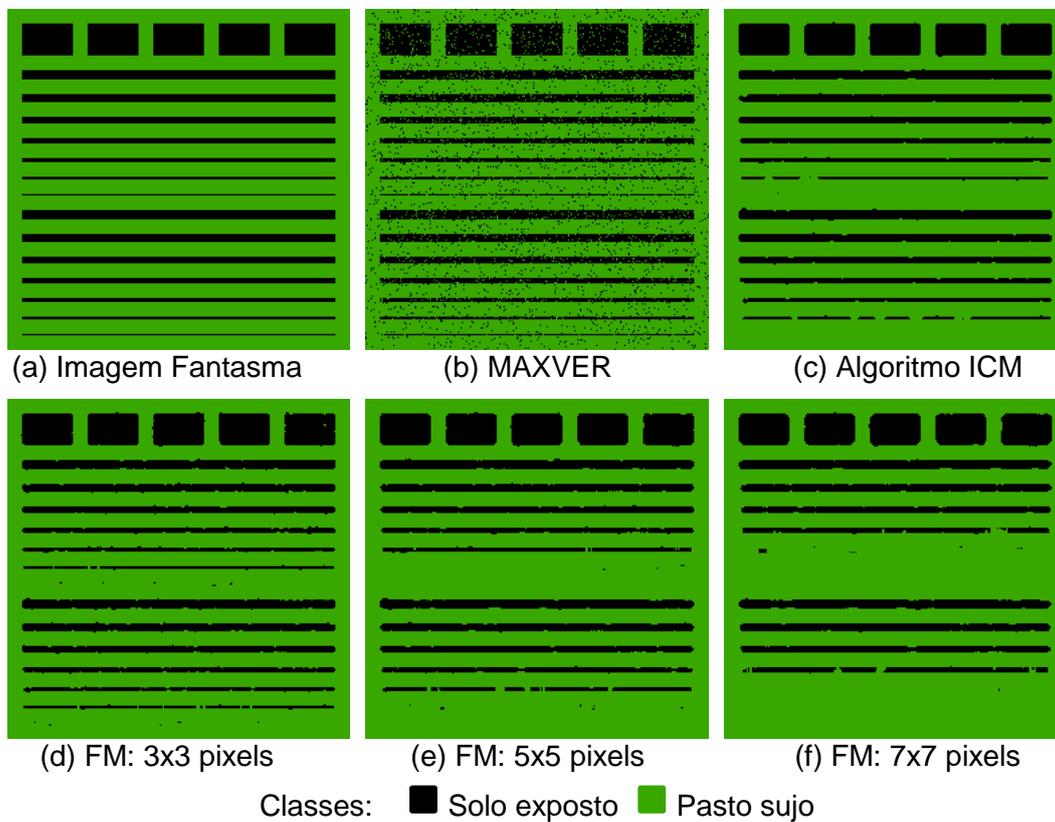


Neste caso, observa-se uma maior eficiência na eliminação de ruídos, em relação aos resultados gerados pelo filtro de maioria. Quanto à eliminação de

ruídos, o algoritmo ICM resultou na eliminação de feições lineares com até 2 pixels de largura. Note que, apesar de ser implementado considerando uma janela móvel de 3x3 pixels, o algoritmo ICM afeta feições mais largas do que aquelas afetadas pelo filtro de maioria com janela móvel de mesma dimensão, pelo fato de ser baseado em um processo iterativo.

Observe também resultados gerados a partir da aplicação convencional do filtro de maioria e do algoritmo ICM na imagem com médio contraste. Os produtos de classificação obtidos para esta imagem são apresentados na Figura 4.11.

Figura 4.11 – Produtos oriundos de classificação convencional, obtidos para a imagem sintética com médio contraste.

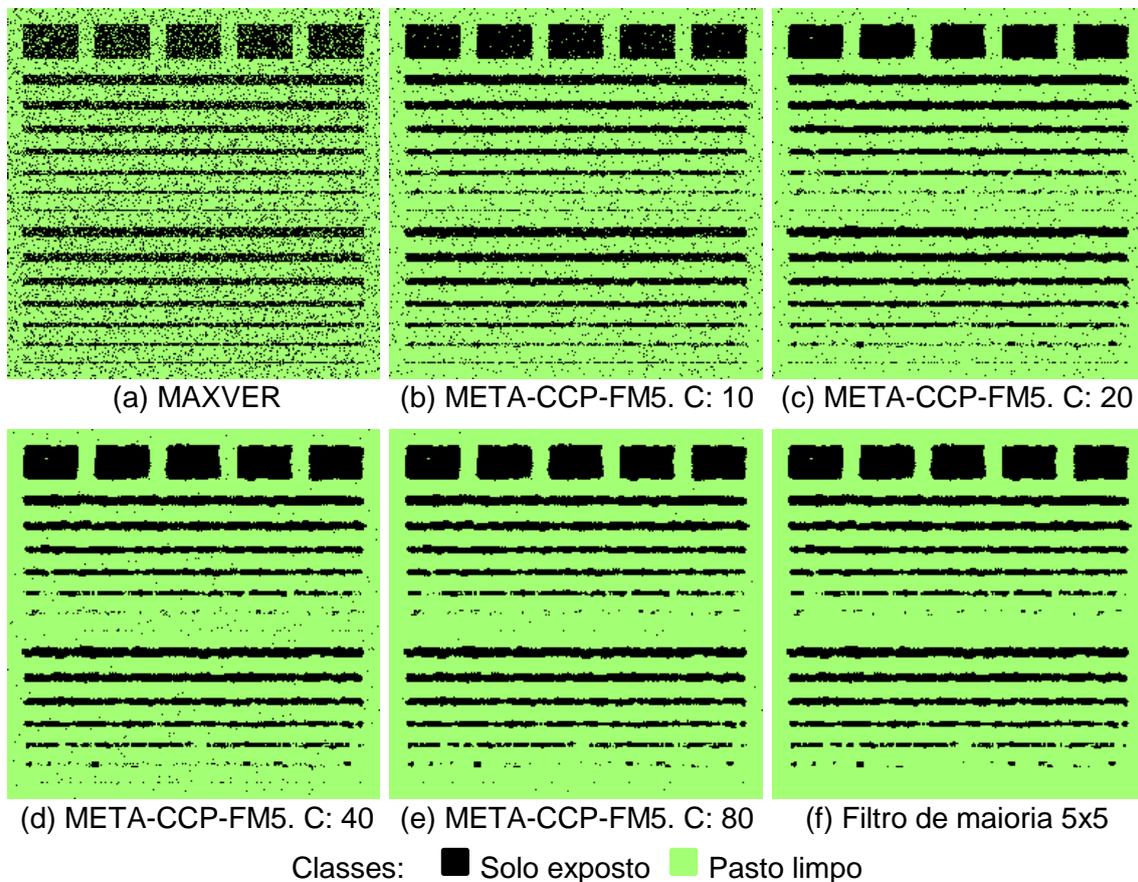


Fonte: Produção do autor.

Por outro lado, a META-CCP, proposta neste trabalho, permite conciliar eliminação de ruídos e preservação de feições estreitas. Neste experimento, cada uma das máscaras geradas permite a obtenção de um mapa de classificação, o qual pode ser considerado um produto intermediário entre o mapa resultante de classificação pontual e o mapa gerado pela abordagem convencional de classificação contextual. Conforme mencionado anteriormente,

o limiar que define os pixels de alta discriminabilidade é estabelecido conforme o fator C adotado. À medida que este fator aumenta, mais próximo o mapa resultante será do mapa gerado pelo classificador contextual convencional. A Figura 4.12 apresenta exemplos de mapas de classificação, gerados para a imagem sintética de baixo contraste, ao se adotar diferentes fatores C durante o processo de classificação contextual por meio do filtro de maioria 5x5.

Figura 4.12 – Exemplos de produtos gerados para a imagem com baixo contraste, utilizando o filtro de maioria 5x5 (META-CCP-FM5), para diferentes fatores C.



Fonte: Produção do autor.

Para se definir qual das máscara geradas proporcionou maior eficiência para remoção de ruídos e preservação de feições em cada imagem, para cada método contextual considerado, analisam-se as acurácias obtidas em cada mapa. Estatísticas foram computadas para todos os produtos de classificação gerados neste experimento, incluindo os mapas de classificação por pixel, os mapas resultantes dos métodos convencionais e os mapas gerados pela META-CCP. Estas estatísticas são apresentadas e analisadas na Seção 4.1.3.

4.1.3 Análise dos resultados e definição dos mapas de classificação

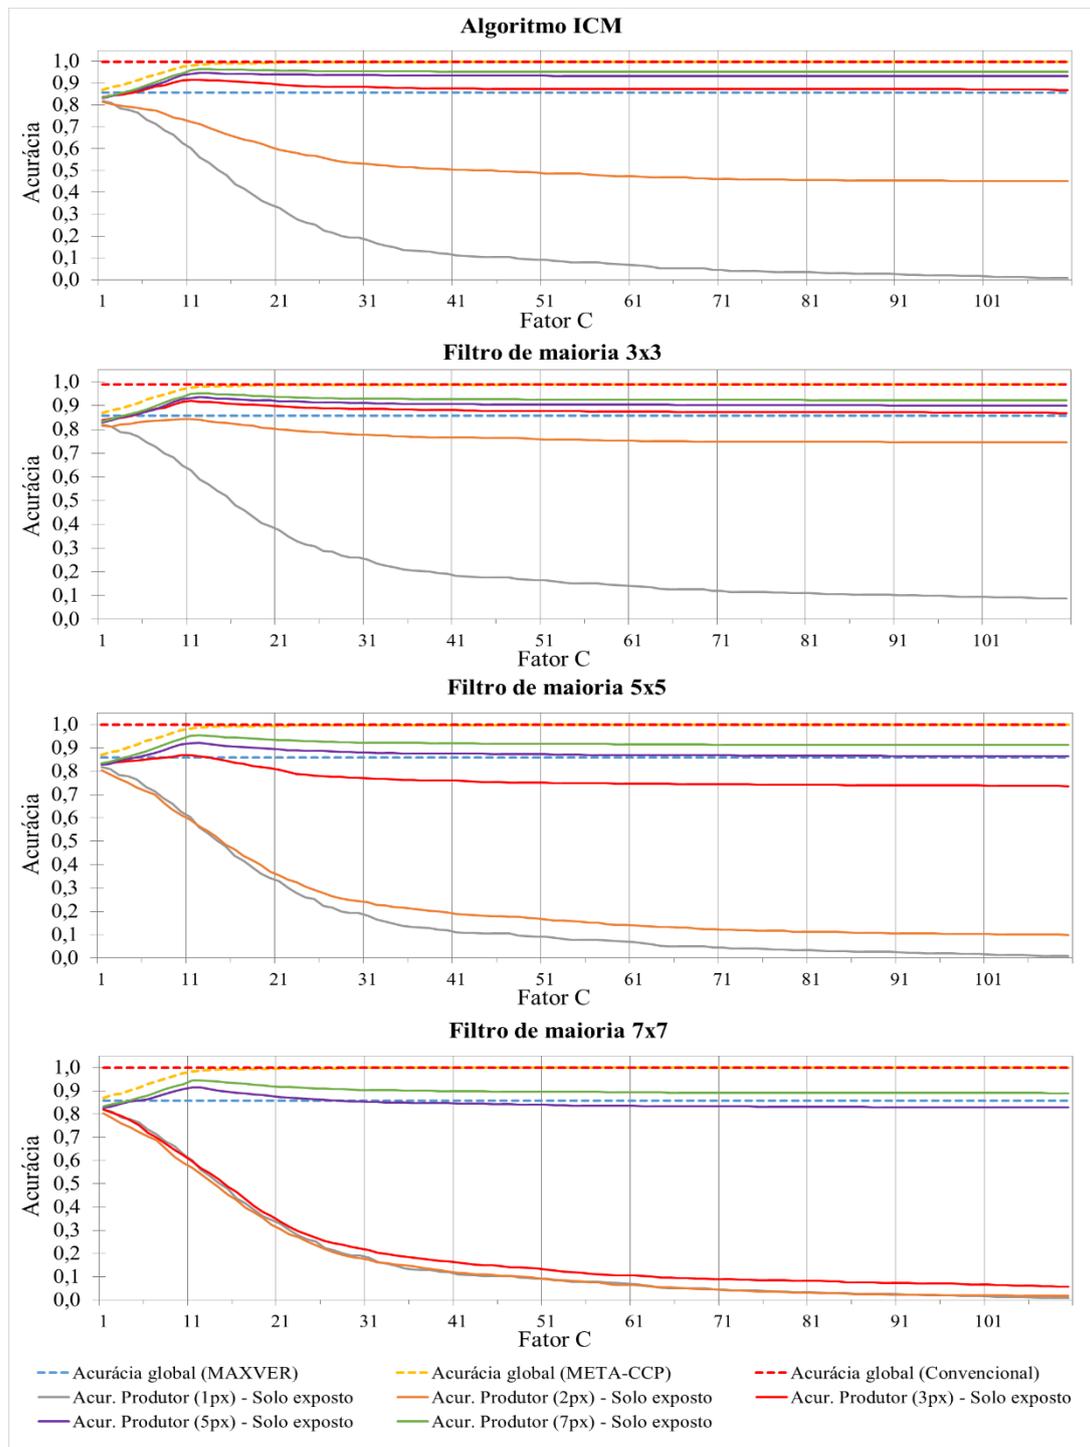
A análise das acurácias apresentadas pelos produtos gerados, tanto para feições estreitas quanto para áreas centrais, permite um melhor entendimento do efeito da variação do fator C na META-CCP. As principais estatísticas analisadas foram: acurácia global (AG), utilizada para avaliar a qualidade de classificação em regiões centrais; e, acurácia do produtor (AP), utilizada como alternativa para se analisar o dano sofrido por feições estreitas durante o procedimento de classificação. Estas estatísticas são obtidas a partir da matriz de confusão. A acurácia global representa a relação entre a quantidade de pixels classificados corretamente e o total de pixels da matriz de confusão. Já a acurácia do produtor, obtida separadamente para cada classe, indica o quanto de uma classe foi corretamente classificado pelo classificador.

A Figura 4.13 apresenta as acurácias obtidas para os mapas de classificação (considerando fatores C de 1 até 110) gerados para a imagem sintética com baixo contraste, composta por amostras de solo exposto e de pasto limpo. Nesta figura, são apresentadas as estatísticas obtidas para os métodos contextuais avaliados: algoritmo ICM, para vizinhança 8; e, filtro de maioria, com janelas móveis de 3x3, 5x5 e 7x7 pixels. As estatísticas apresentadas referem-se tanto às regiões centrais (acurácia global), quanto às feições estreitas (acurácia do produtor). Note que não são apresentadas estatísticas para feições com 4 e 6 pixels de largura, uma vez que estas apresentam acurácias similares àquelas observadas em feições com largura de 5 e 7 pixels.

Da mesma forma, na Figura 4.14 são apresentadas as estatísticas obtidas para os mapas gerados para a imagem sintética com médio contraste, composta por amostras de solo exposto e de pasto sujo. Nota-se para ambas as imagens que, quanto maior o fator C, maior o número de pixels reclassificados pela abordagem contextual. Além disso, em relação ao filtro de maioria, observa-se que o aumento da dimensão da janela móvel resulta na deterioração de feições de maior dimensão. Já o algoritmo ICM, no processamento da imagem com médio contraste, apresentou estatísticas semelhantes àquelas obtidas pelo filtro de maioria 3x3, afetando principalmente feições com 1 pixel de largura.

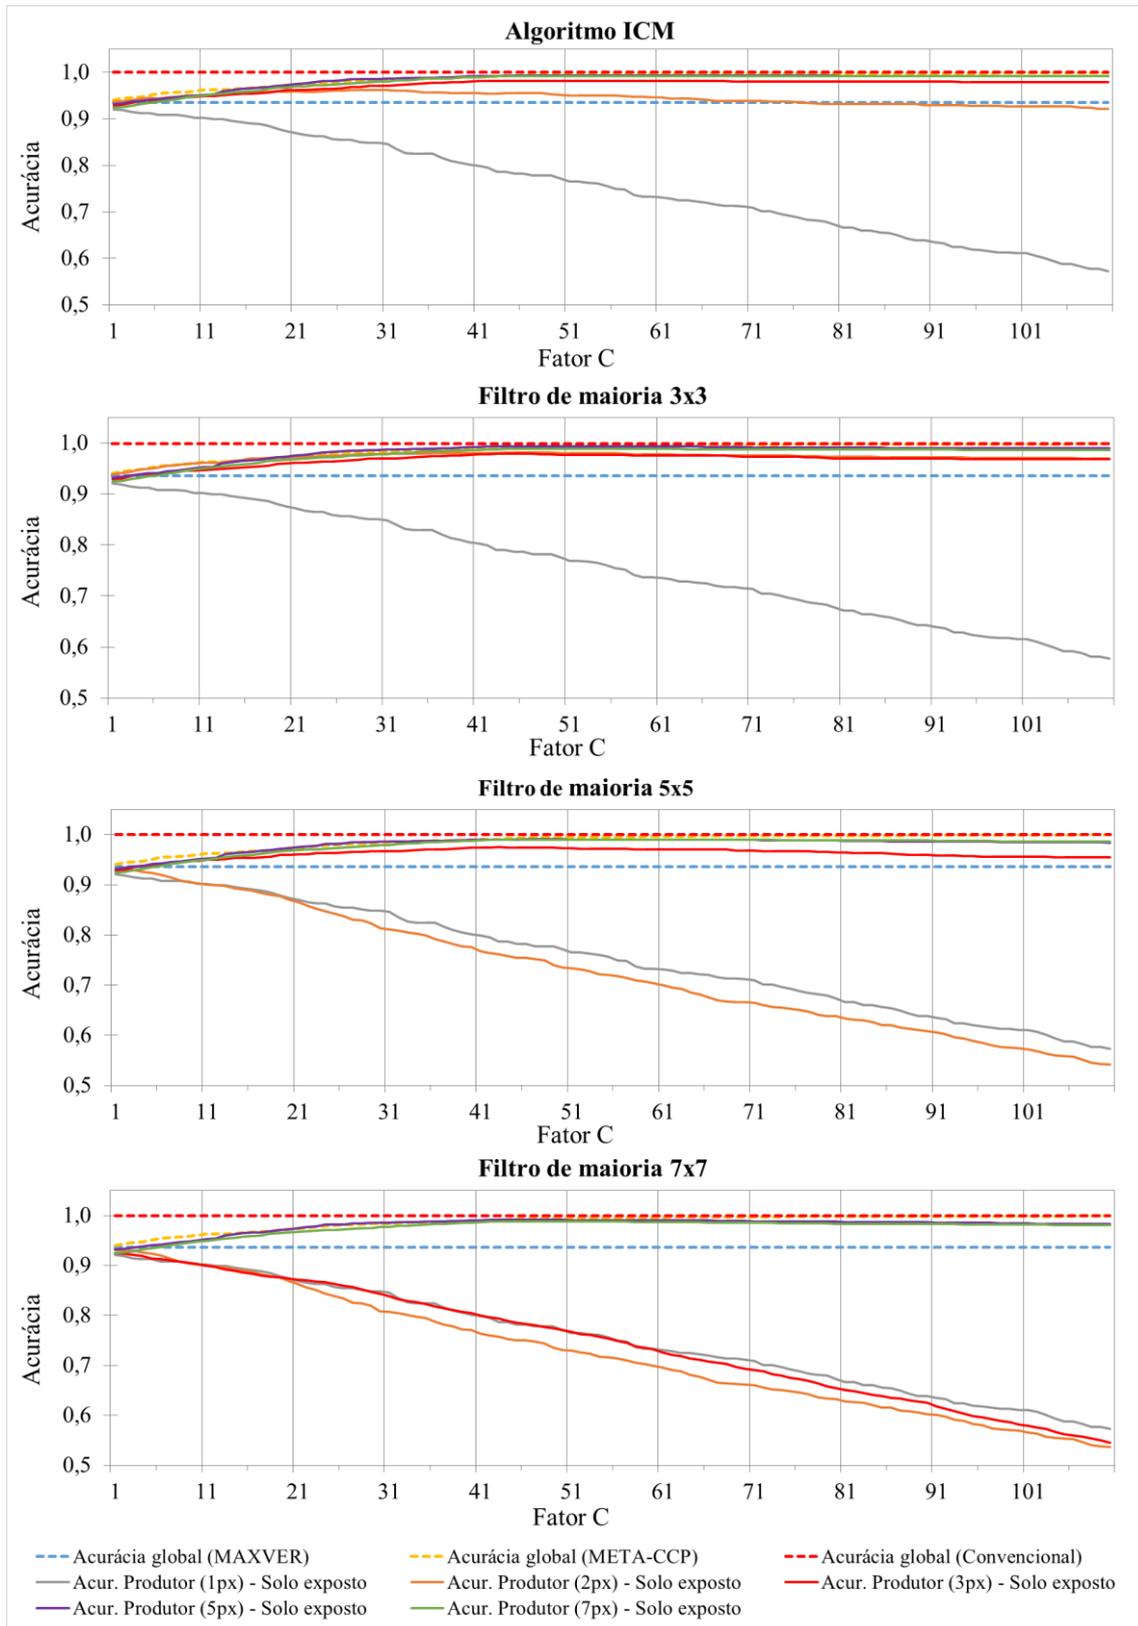
Por outro lado, no processamento da imagem com baixo contraste, a qual apresenta um maior nível de ruído, o algoritmo ICM deteriorou mais feições do que o filtro de maioria 3x3, afetando feições de até 2 pixels de largura.

Figura 4.13 – Estatísticas obtidas para os mapas de classificação referentes à imagem sintética com baixo contraste, ao se adotarem diferentes classificadores contextuais.



Fonte: Produção do autor.

Figura 4.14 – Estatísticas obtidas para os mapas de classificação referentes à imagem sintética com médio contraste, ao se adotarem diferentes classificadores contextuais.

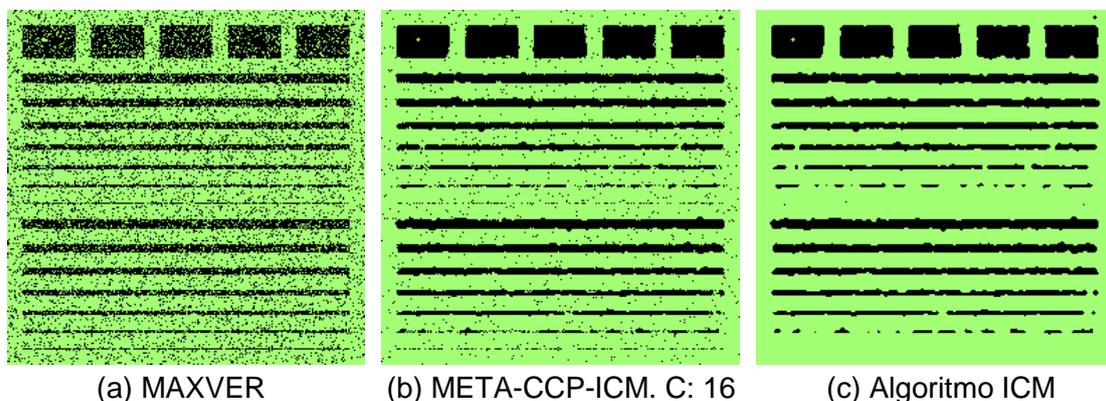


Fonte: Produção do autor.

Para se estabelecer o mapa final de classificação para cada uma das imagens sintéticas, deve-se definir também qual operação deseja-se priorizar: remoção de ruídos ou preservação de feições. A partir da escolha do fator é possível ponderar ambas as operações. Nesse processo, deve-se considerar também o contraste entre as classes analisadas na classificação. No caso da imagem sintética com baixo contraste, a qual resultou em um mapa de classificação pontual com alto nível de confusão, a classificação contextual considerando um fator C de 12 e janela móvel de 3x3 pixels apresentou ser uma eficiente alternativa para se remover alguns ruídos de classificação, sem degradar desnecessariamente feições com 1 pixel de largura. De forma similar, a classificação pelo algoritmo ICM, com fator C entre 12 e 16 também pode ser adotada. Estas configurações, utilizando o algoritmo ICM e o filtro de maioria, são ilustradas nas Figura 4.15(b) e Figura 4.15(d), respectivamente.

Por outro lado, a classificação utilizando uma janela móvel de 5x5 pixels e um fator C entre 12 e 15 pode ser utilizada com o objetivo de aumentar a eficiência na remoção de ruídos. Porém, nesta última configuração ocorre também uma maior deterioração de feições com largura de 2 pixels. O filtro de maioria com janela móvel de 7x7 pixels também é eficiente na remoção de ruídos; porém, devido à maior dimensão da janela móvel, feições maiores também são degradadas. Por exemplo, ao se aplicar o filtro de maioria 7x7, com fator C de 13, feições com largura de 3 e 4 pixels são também afetadas. Estas configurações de classificação são apresentadas na Figura 4.15.

Figura 4.15 – Comparação entre mapas gerados por abordagens convencionais e mapas resultantes da META-CCP, para a imagem com baixo contraste.



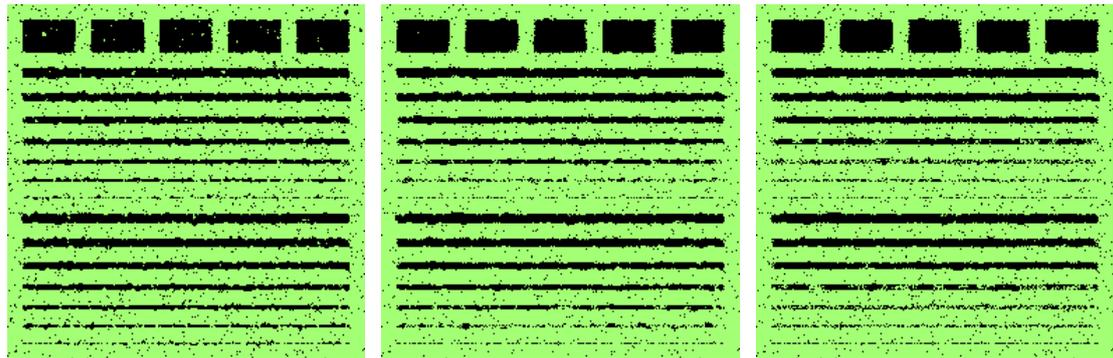
(a) MAXVER

(b) META-CCP-ICM. C: 16

(c) Algoritmo ICM

(continua)

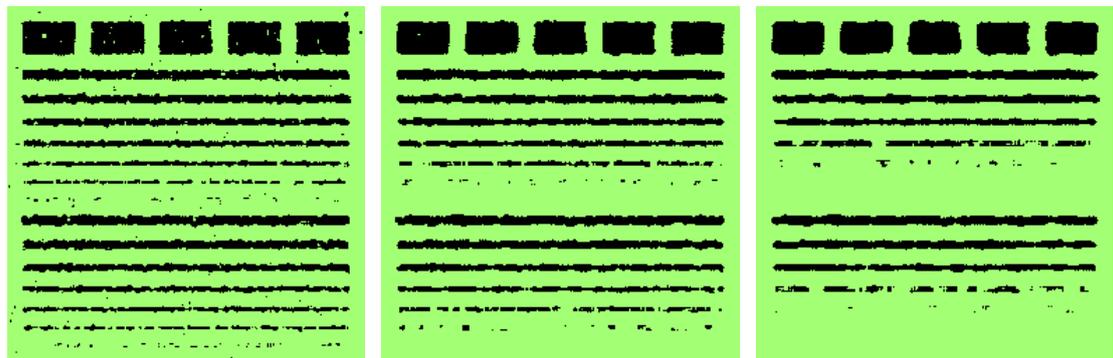
Figura 4.15 – Conclusão.



(d) META-CCP-FM3. C: 12

(e) META-CCP-FM5. C: 15

(f) META-CCP-FM7. C: 13



(g) Filtro de maioria 3x3

(h) Filtro de maioria 5x5

(i) Filtro de maioria 7x7

Classes: ■ Solo exposto ■ Pasto limpo

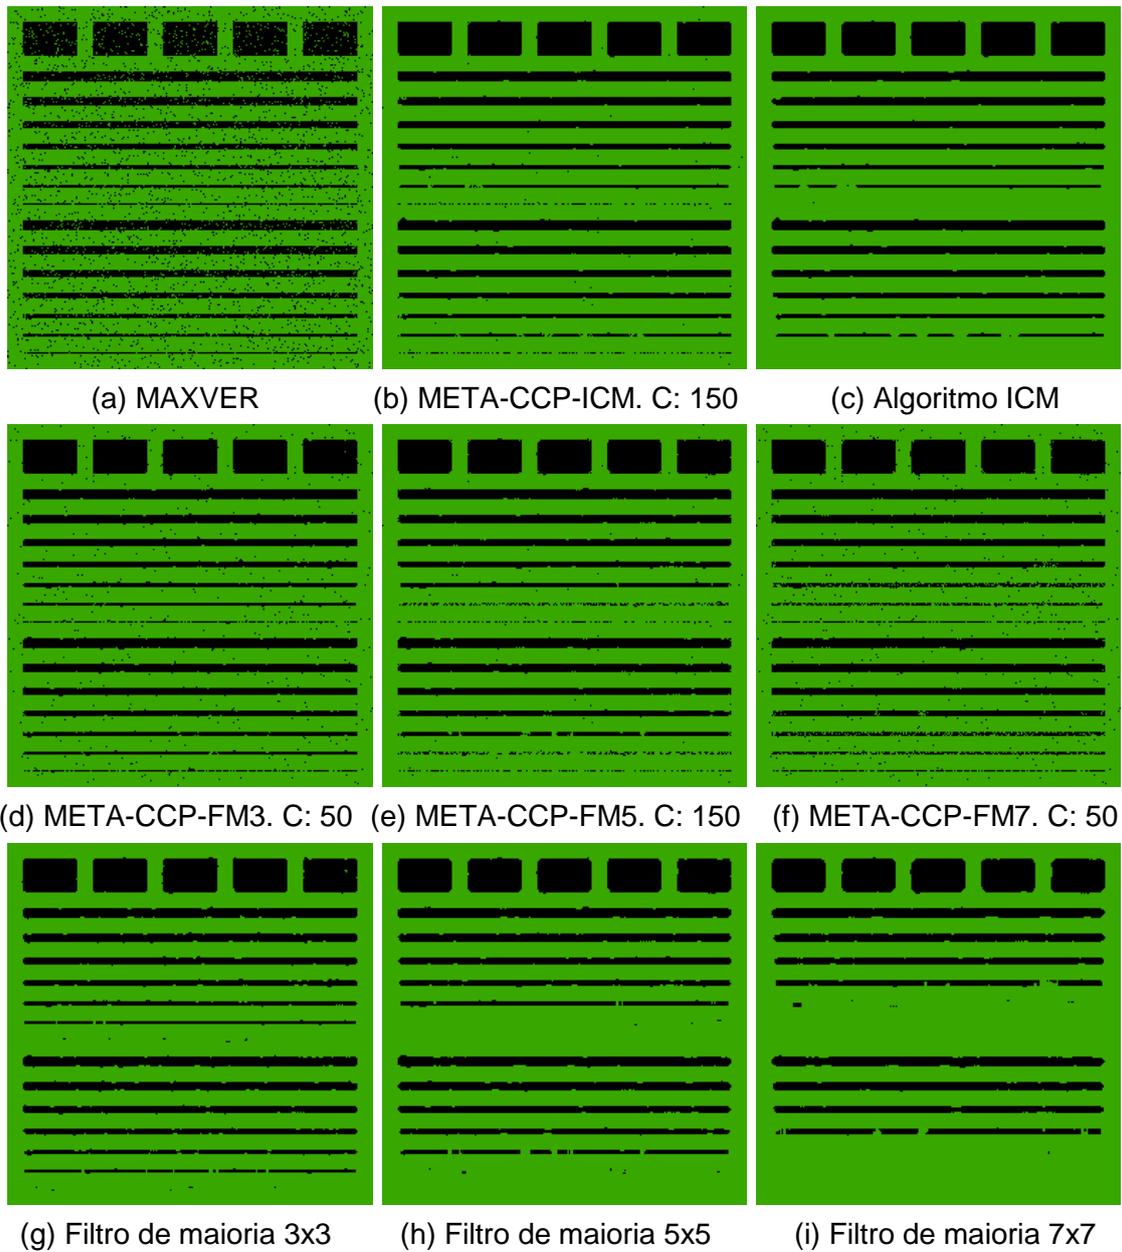
Fonte: Produção do autor.

No caso da imagem com médio contraste, devido a menor similaridade entre os alvos e o menor nível de ruído, observa-se que maiores valores podem ser adotadas para o fator C sem resultar na deterioração significativa de feições estreitas. Este efeito pode ser observado nas estatísticas apresentadas na Figura 4.14. A classificação gerada considerando o filtro de maioria 3x3 e fator C de 50, por exemplo, permite remover grande parte dos ruídos presentes no mapa de classificação pontual, sem danificar até mesmo feições estreitas com largura de 1 pixel. Esta configuração é apresentada na Figura 4.16(d). Este mesmo efeito é observado ao se aplicar o algoritmo ICM. Ao se aplicarem ambos os métodos, feições lineares com largura de 1px não são completamente eliminadas nem mesmo ao se adotar um fator C de 150. Este resultado, considerando o algoritmo ICM, é apresentado na Figura 4.16(b).

No caso de imagens com menor nível de ruído, a utilização do filtro de maioria com janelas móveis maiores, tais como janelas de ordem 5 ou 7, pode não

apresentar ganhos significativos na remoção dos ruídos. Para esta imagem, por exemplo, a utilização de janela móvel de 5x5 pixels e fator C equivalente a 50 não resulta em uma maior eliminação de ruídos. Neste caso, observa-se uma maior deterioração de feições com largura de até 2 pixels. Este mesmo efeito é observado ao se adotar uma janela móvel de 7x7 pixels. A Figura 4.16 apresenta os resultados obtidos com estas configurações.

Figura 4.16 – Comparação entre mapas gerados por abordagens convencionais e mapas resultantes da META-CCP, para a imagem com médio contraste.



Classes: ■ Solo exposto ■ Pasto sujo

Fonte: Produção do autor.

4.2 Estudo de caso II: classificação de imagem de SR

Nesta seção, a META-CCP é aplicada para classificação de uma imagem real de sensoriamento remoto. Neste experimento, considera-se a classificação de um recorte de imagem proveniente do sensor Landsat-8/OLI. Nesta imagem, diversas classes de cobertura da terra podem ser identificadas, além de apresentar feições estreitas, referentes a diferentes classes, que são normalmente eliminadas por abordagens convencionais de classificação contextual. Detalhes sobre o processamento realizado e os resultados obtidos são apresentados na Seção 4.2.1.

4.2.1 Classificação de imagem Landsat-8/OLI

A imagem utilizada nesse experimento corresponde a um pequeno recorte da imagem proveniente do sensor Landsat-8/OLI, adotada na Seção 4.1 para a coleta de amostras para a composição das imagens sintéticas com baixo e médio contraste. Neste experimento, a imagem classificada representa um extrato de dimensão 450 x 303 pixels, composta por 7 das 11 bandas espectrais que compõem a cena Landsat-8/OLI original. As bandas espectrais consideradas são: coastal/aerosol (banda 1), azul (banda 2), verde (banda 3), vermelho (banda 4), infravermelho próximo (banda 5), infravermelho de ondas curtas 1 (banda 6) e infravermelho de ondas curtas 2 (banda 7). Esta imagem é apresentada na Figura 4.17, sendo algumas de suas principais características descritas na Tabela 4.1.

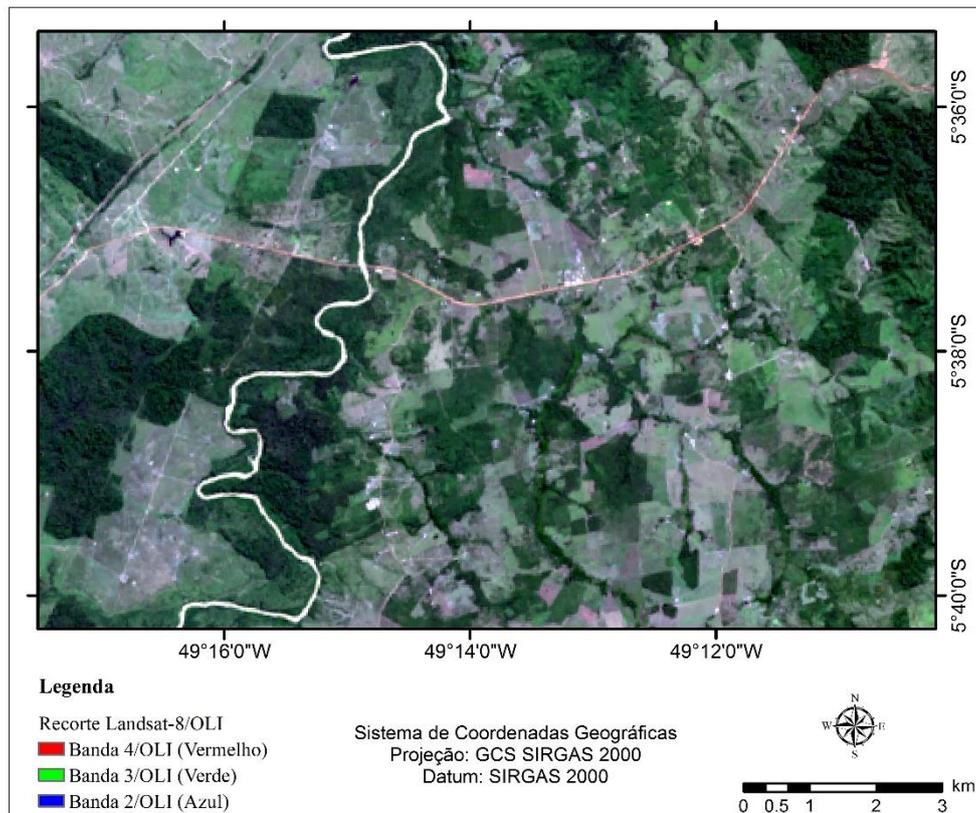
Tabela 4.1 – Estudo de caso II: principais características da imagem classificada.

Características	Extrato de imagem LANDSAT-8/OLI
Data de aquisição	12 de junho de 2014
Órbita/ponto	223/064
Resolução espacial	30 m
Resolução espectral	7 bandas*: 0,435 a 0,451 μm ; 0,452 a 0,512 μm ; 0,533 a 0,590 μm ; 0,636 a 0,673 μm ; 0,851 a 0,879 μm ; 1,566 a 1,651 μm ; 2,107 a 2,294 μm .
Dimensão	303 x 450 pixels

* Foram utilizadas as bandas de 1-7, dentre as 11 bandas adquiridas pelo sensor OLI.

Fonte: Barsi et al. (2014).

Figura 4.17 – Recorte de imagem Landsat-8/OLI.



Fonte: Produção do autor.

A partir desta imagem podem ser identificados os seguintes tipos de cobertura da terra: água, floresta, pasto limpo, pasto sujo, solo exposto e vegetação secundária. Além disso, pode-se observar feições estreitas ao longo da imagem, referentes a um rio e a estradas de terra. Para classificação desta imagem utilizando a META-CCP, foram coletadas as amostras de treinamento e de teste apresentadas na Figura 4.18(a), além dos pixels rotulados ilustrados na Figura 4.18(b). Destaca-se que foram coletadas amostras de teste para todas as classes, inclusive para classes referentes a feições estreitas.

Durante o estágio de classificação por pixel, 100 modelos de classificação foram gerados para cada classe. Para se gerar cada modelo, foram utilizadas 200 amostras aleatoriamente obtidas a partir do conjunto total coletado, minimizando o problema de auto correlação espacial. Este menor número de amostras foi definido considerando-se o conjunto da classe com menor quantidade de amostras de treinamento. Assim como no experimento anterior, 150 máscaras foram geradas, considerando fatores C de 1 a 150.

Figura 4.18 – Dados iniciais de classificação: (a) Amostras de treinamento/teste e (b) pixels rotulados.



(a)



(b)

Amostras de Treinamento:						
	Água	Floresta	Pasto limpo	Pasto sujo	Solo exposto	Veg. secundária
Amostras de Teste:						
	Água	Floresta	Pasto limpo	Pasto sujo	Solo exposto	Veg. secundária
Pixels rotulados:						
	Água	Floresta	Pasto limpo	Pasto sujo	Solo exposto	Veg. secundária

Fonte: Produção do autor.

A variação dos valores adotados para o fator C automaticamente estabelece diferentes medidas de divergência observadas entre classes comumente encontradas na natureza. Dessa forma, as amostras de treinamento usadas na classificação por máxima verossimilhança foram também utilizadas a fim de se definir fatores C representativos das divergências observadas entre as classes analisadas neste experimento. A partir das amostras de treinamento coletadas, calcula-se a média e a variância dos valores amostrados para cada classe. A partir desses valores, é possível se obter a FDR, conforme descrito na equação 3.1, referente a diferentes combinações de pares de classes. Sabendo-se que o fator C é definido pela raiz quadrada da FDR, obtém-se os fatores C representativos para todos os pares de classes analisados neste experimento.

Neste caso, considerou-se pares de classes comumente associados tanto a uma feição estreita quanto a uma feição mais abrangente. Estes valores foram utilizados a fim de auxiliar na análise dos resultados gerados pela META-CCP. Considerando as classes de cobertura da terra observadas na imagem, foram definidas 8 combinações de classes, conforme apresentado na Tabela 4.2.

Tabela 4.2 – Combinações de pares de classes considerados para obtenção de fatores C representativos.

Combinação	Classe normalmente associada a feições estreitas	Classe normalmente associada a feições mais abrangentes
1	Solo exposto	Floresta
2	Solo exposto	Vegetação secundária
3	Solo exposto	Pasto limpo
4	Solo exposto	Pasto sujo
5	Água	Floresta
6	Água	Vegetação secundária
7	Água	Pasto limpo
8	Água	Pasto sujo

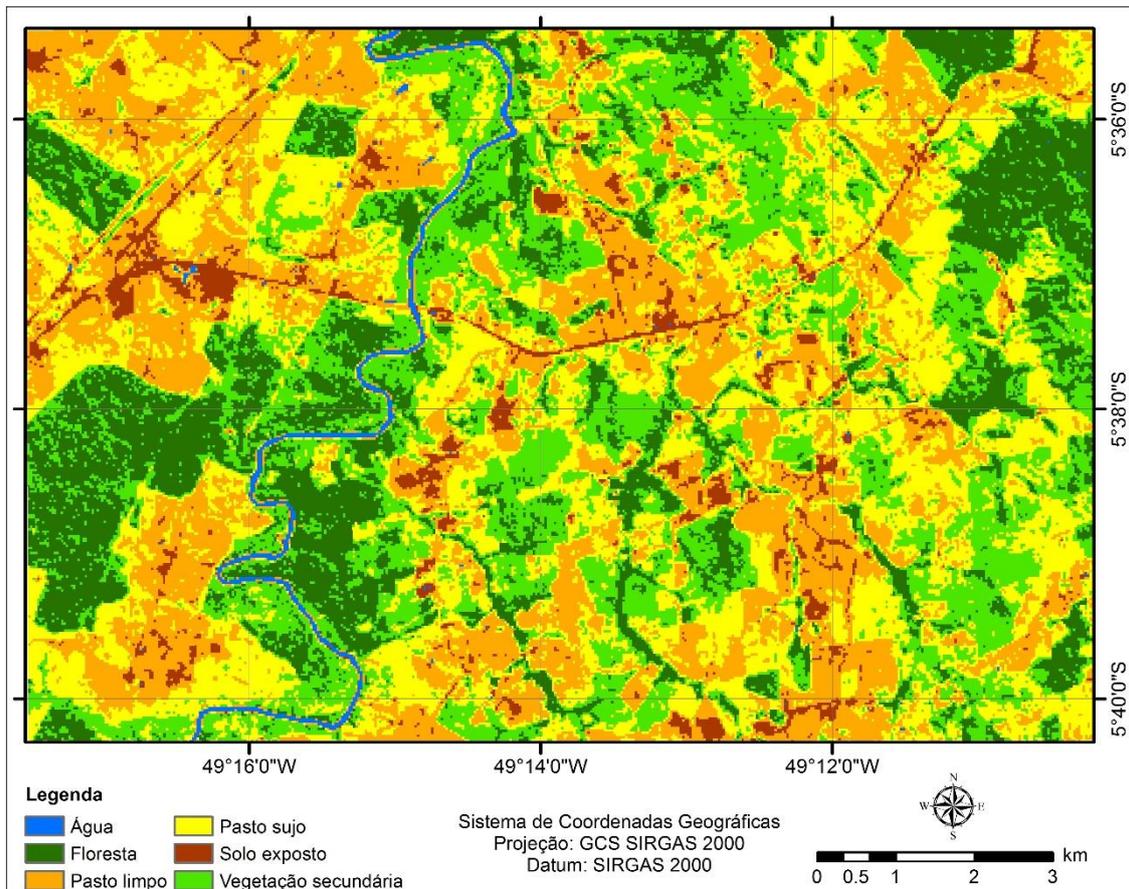
Fonte: Produção do autor.

4.2.1.1 Descrição e análise dos produtos de classificação

A Figura 4.19 apresenta o produto de classificação pixel a pixel obtido para esta imagem Landsat-8/OLI. O mapa temático apresenta alta confusão entre as

classes: floresta e vegetação secundária; e, pasto limpo e pasto sujo. Algumas áreas de pasto limpo foram também classificadas como solo exposto, o que pode ser justificado pela presença de vegetação esparsa e até mesmo de solo nu em áreas de pastagem. Estes ruídos de classificação ocorrem devido ao comportamento espectral semelhante entre algumas feições.

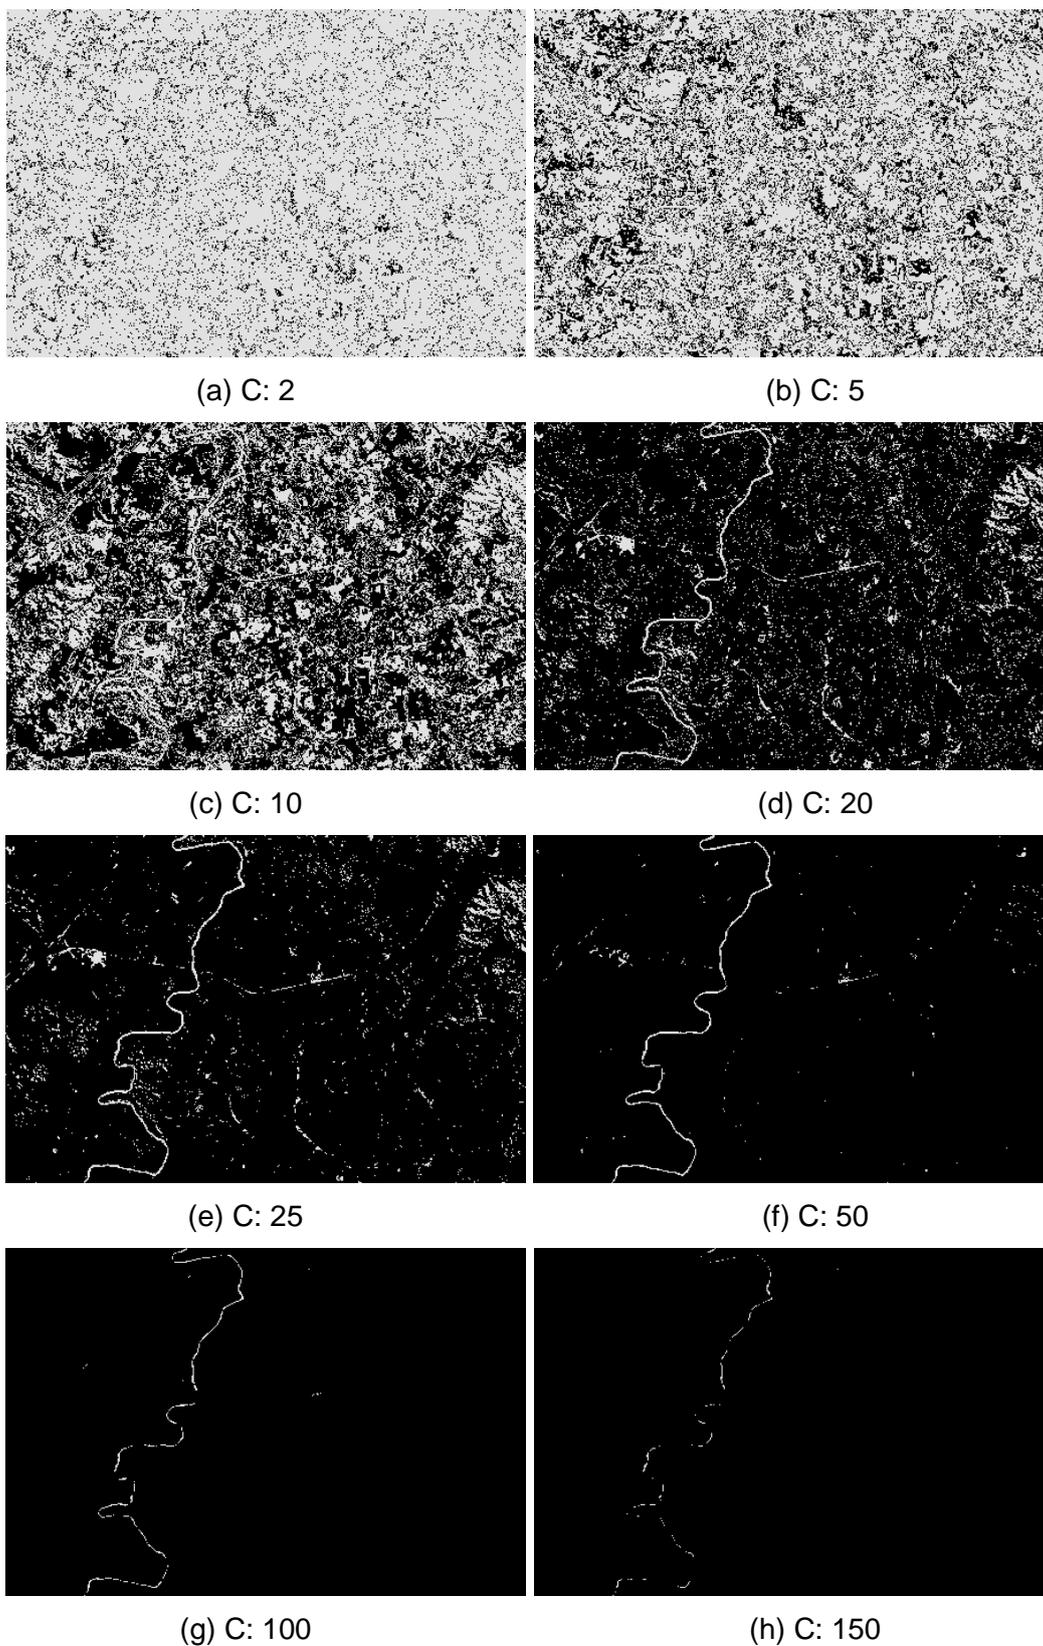
Figura 4.19 – Mapa de classificação pontual gerado pelo classificador MAXVER.



Fonte: Produção do autor.

Após o estágio de classificação pontual, obtêm-se o conjunto de máscaras MPAD. Dentre as 150 máscaras geradas, alguns exemplos são apresentados na Figura 4.20. Conforme descrito anteriormente, o número de pixels que podem ser reclassificados pela abordagem contextual se torna maior à medida que se aumenta o fator C. Nestes exemplos, nota-se uma maior divergência entre a classe água e as demais classes, sendo sua feição definida como de alta discriminabilidade em diversas das máscaras geradas.

Figura 4.20 – Exemplos de máscaras MPAD obtidas para a imagem Landsat-8/OLI.



■ Pixels que podem ser reclassificados ■ Pixels de alta discriminabilidade

Fonte: Produção do autor.

A Tabela 4.3 apresenta os fatores C representativos, calculados considerando as amostras de treinamento adotadas para classificação pontual. O fator C médio obtido por meio de amostras de solo exposto e pasto limpo, por exemplo, é representativo da divergência média observada entre as amostras de ambas as classes. Portanto, neste caso, pixels nos quais os dois maiores valores de verossimilhança fazem referência a estas classes apresentam uma maior probabilidade de serem preservados ao se considerar um fator C menor do que o valor apresentado para esta medida representativa. Neste caso, a utilização de um fator C maior do que o valor representativo pode aumentar o número de pixels referentes a estas feições a serem reclassificados pelo método contextual, o que pode também aumentar o dano em feições estreitas.

Tabela 4.3 - Fatores C representativos computados para diferentes pares de classes de cobertura da terra, por meio de amostras adquiridas em imagem Landsat-8/OLI.

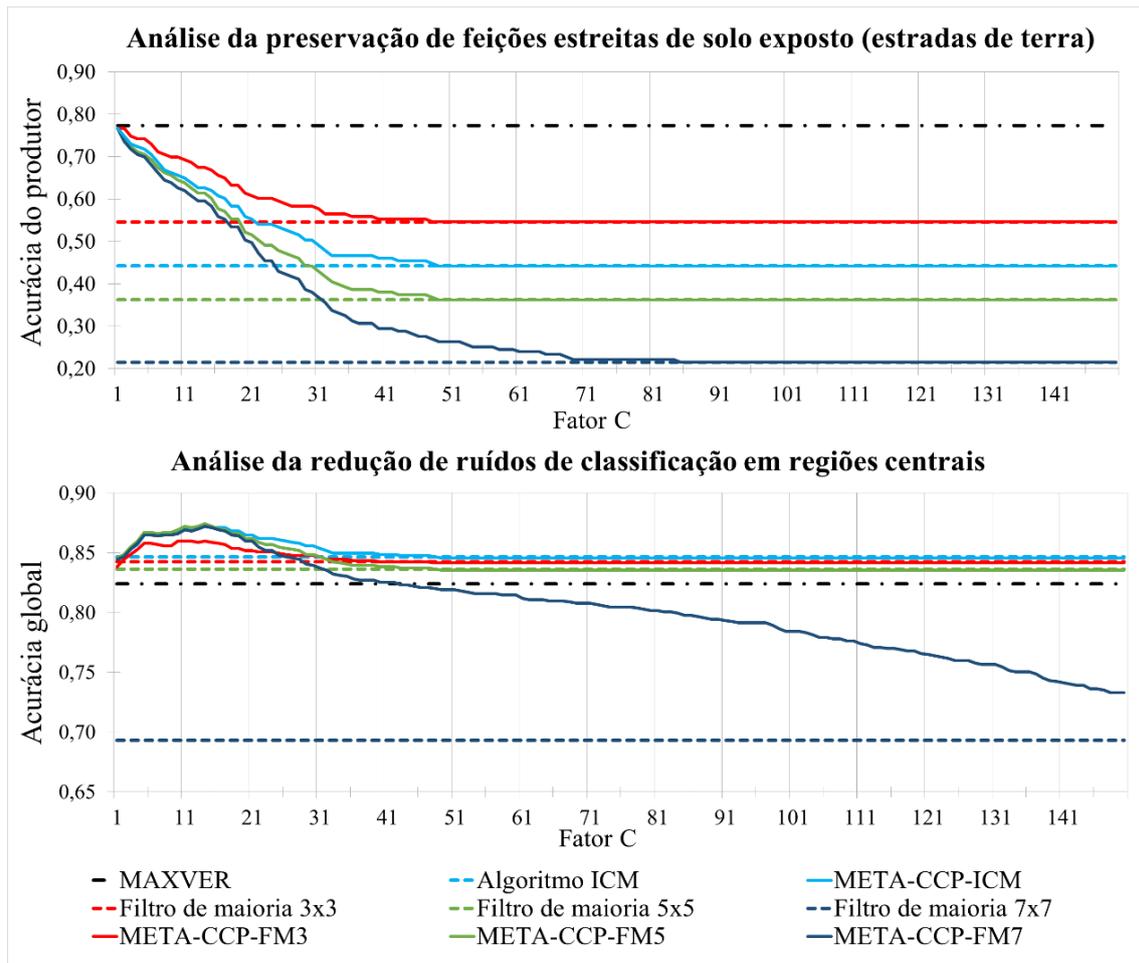
Pares de classes	Fator C representativo
Solo exposto e floresta	3,7
Solo exposto e vegetação secundária	3,5
Solo exposto e pasto limpo	1,6
Solo exposto e pasto sujo	2,3
Água e floresta	5,2
Água e vegetação secundária	5,2
Água e pasto limpo	3,8
Água e pasto sujo	4,4

Fonte: Produção do autor.

A Figura 4.21 apresenta as estatísticas obtidas a partir dos diversos produtos de classificação gerados, considerando tanto métodos convencionais quanto a META-CCP. Nesta figura, os termos FM3, FM5 e FM7 indicam a aplicação do filtro de maioria, com janelas de 3x3, 5x5 e 7x7 pixels, respectivamente. As estatísticas apresentadas permitem avaliar tanto o dano sofrido por feições estreitas, referentes a solo exposto, quanto a acurácia de classificação em regiões centrais. A META-CCP permite a obtenção de mapas de classificação com diferentes níveis de acurácia em feições estreitas. Estes níveis variam da acurácia obtida pelo classificador pontual até a acurácia resultante da aplicação

de métodos convencionais de classificação contextual sobre o mapa de classificação pontual. Nesse processo há também uma redução do número de pixels ruidosos em áreas centrais de feições largas, o que proporciona uma melhora na acurácia global do mapa final classificação.

Figura 4.21 – Estatísticas referentes a imagem Landsat-8/OLI, para áreas centrais (acurácia global) e feições estreitas de solo exposto (acurácia do produtor).



Fonte: Produção do autor.

Observe nas estatísticas apresentadas anteriormente que, os mapas resultantes da META-CCP apresentaram melhores acurácias globais ao se considerarem fatores C entre 1 e 25, para todos os métodos contextuais analisados. Note que, as maiores acurácias globais foram obtidas ao se utilizar o algoritmo ICM. No caso do filtro de maioria, os ganhos mais evidentes em termos de acurácia global foram observados em produtos gerados com janelas móveis de 5x5 e 7x7 pixels. Este intervalo para o fator C apresentou ainda uma

redução na deterioração de feições estreitas de solo exposto (estrada de terra), em comparação aos produtos obtidos pela abordagem convencional.

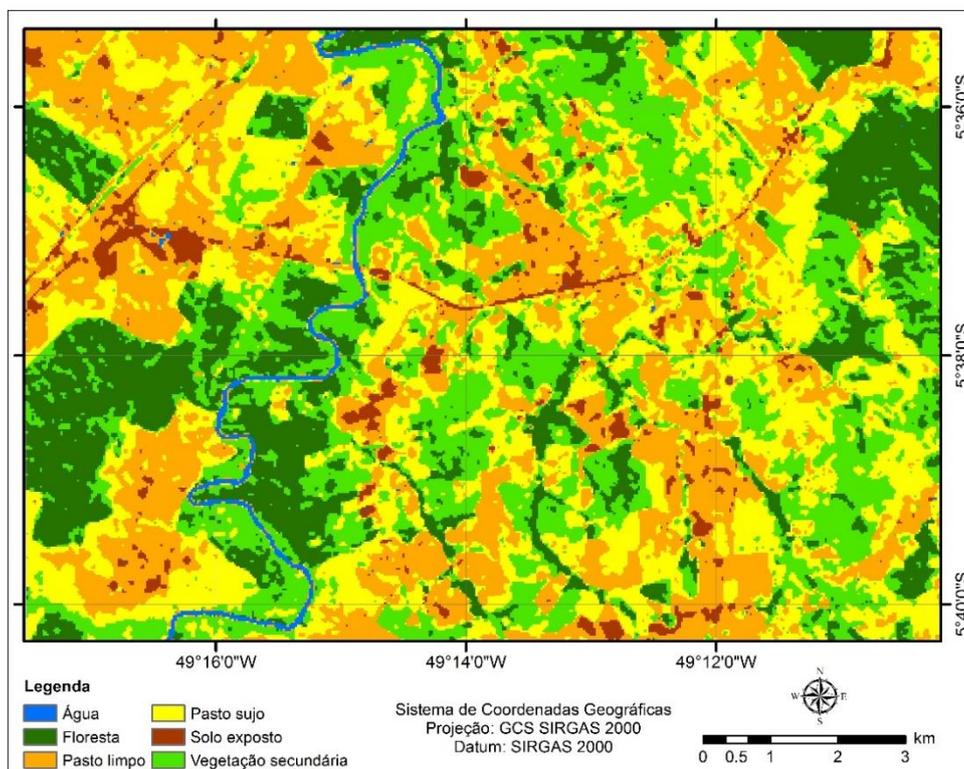
Destaca-se ainda que, após o fator C atingir um determinado valor, o qual varia conforme o método contextual utilizado e as características da imagem, a classificação resulta em acurácias idênticas às aquelas obtidas ao se adotar a abordagem convencional de classificação. A utilização de fatores C superiores a este determinado valor não resulta em alterações na classificação, uma vez que não há pixels a serem definidos como sendo de alta discriminabilidade.

A Figura 4.22 apresenta alguns produtos de classificação gerados ao se aplicar o filtro de maioria pelo método apresentado, adotando-se um fator C de 13 e janelas móveis de 3x3, 5x5 e 7x7 pixels. Além disso, para fins de comparação, são incluídos também nesta figura os mapas resultantes da aplicação do filtro de maioria convencional, com janelas móveis de mesma dimensão. Nestas imagens, nota-se a eficiência do método apresentado tanto na preservação de feições quanto na remoção de ruídos de classificação.

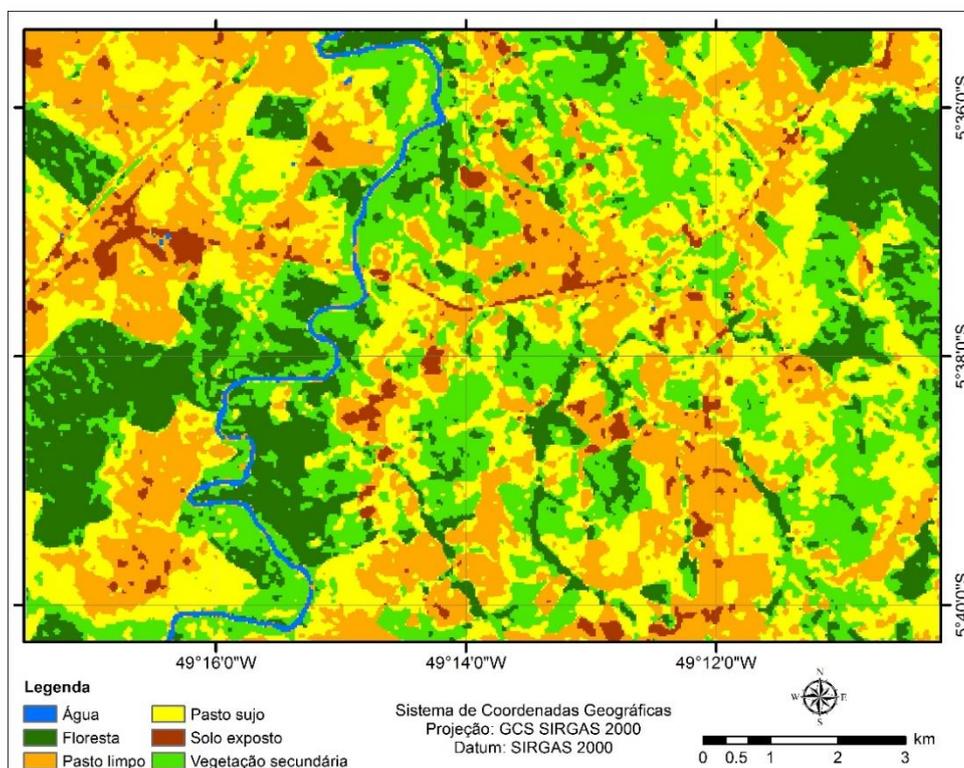
No caso do filtro de maioria 3x3, ganhos em termos de preservação de feições, podem não ser tão perceptíveis ao se adotar a META-CCP, devido à pequena dimensão da janela móvel e das feições apresentadas na imagem. Com esta configuração, mesmo a abordagem convencional não apresenta danos significativos em feições estreitas. Os danos ocasionados não são tão perceptíveis uma vez que esta configuração de classificação afeta principalmente feições com largura de apenas 1 pixel.

Porém, apesar de não serem tão perceptíveis, alguns detalhes são perdidos ao se aplicar o método convencional. Ao se adotar uma classificação com preservação de MPAD, gerada com fator C de 13, por exemplo, pequenos detalhes da estrada de terra, ilustrada na imagem na classe solo exposto, são preservados. A Figura 4.23(a) apresenta a diferença entre o produto gerado pela META-CCP, utilizando o filtro de maioria 3x3 e fator C de 13, e o produto obtido pela aplicação do filtro de maioria 3x3 convencional.

Figura 4.22 – Comparação entre produtos de classificação obtidos ao se aplicar o filtro de maioria considerando a META-CCP e pelo método convencional.



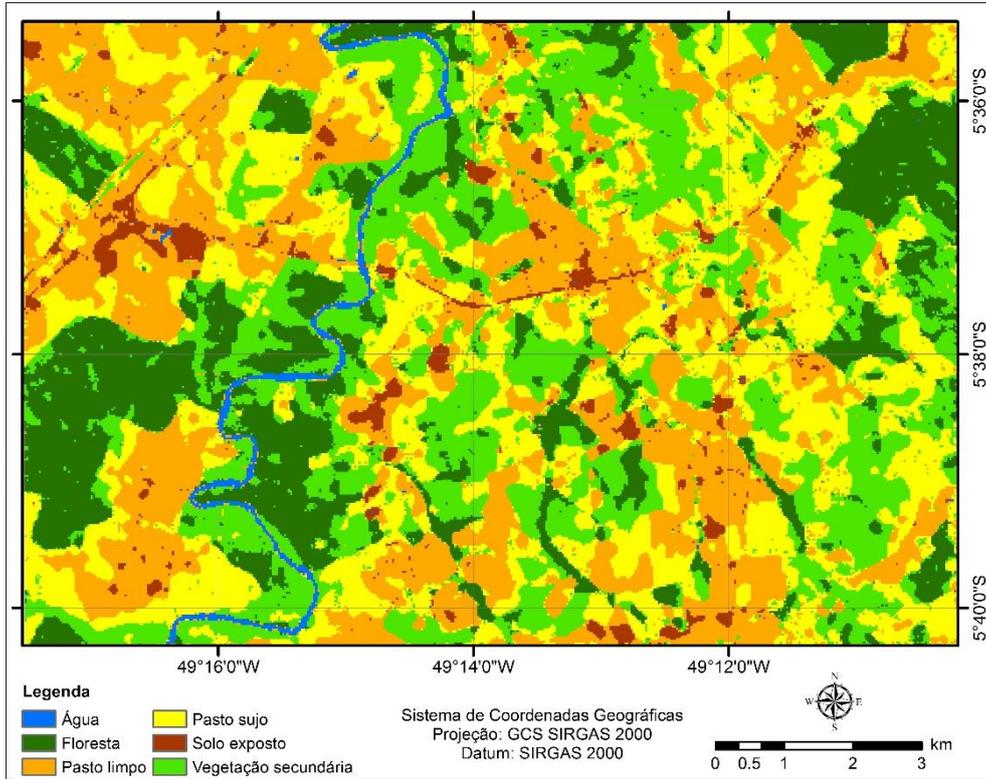
(a) META-CCP-FM3. C: 13



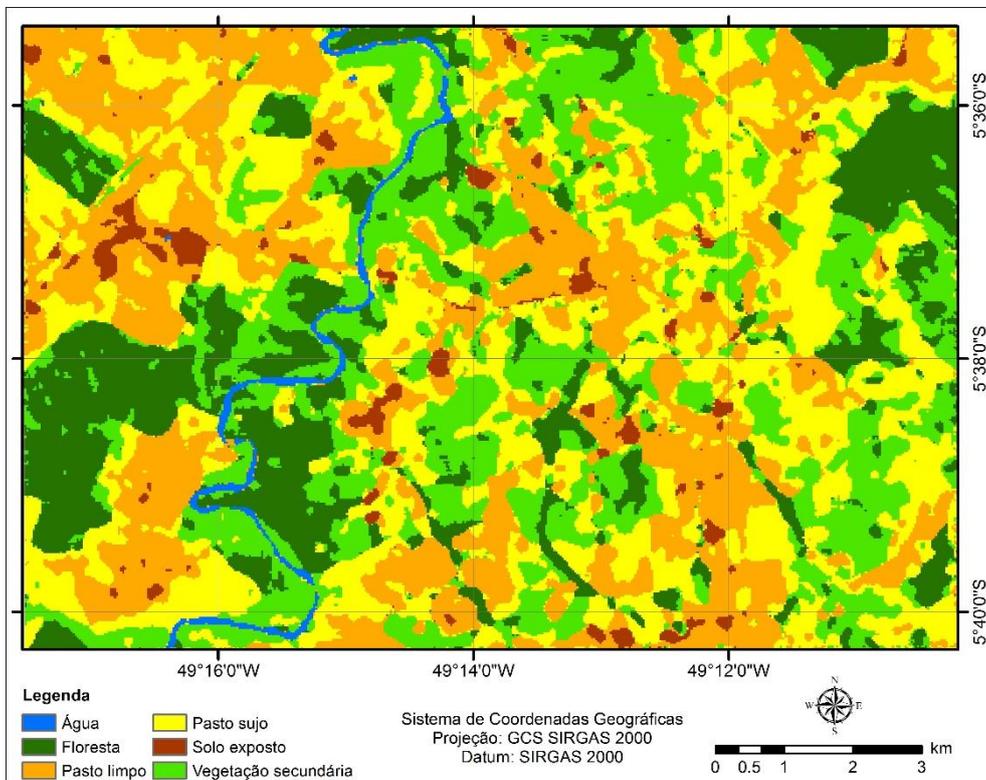
(b) Filtro de maioria 3x3 (convencional)

(continua)

Figura 4.22 – Continuação.



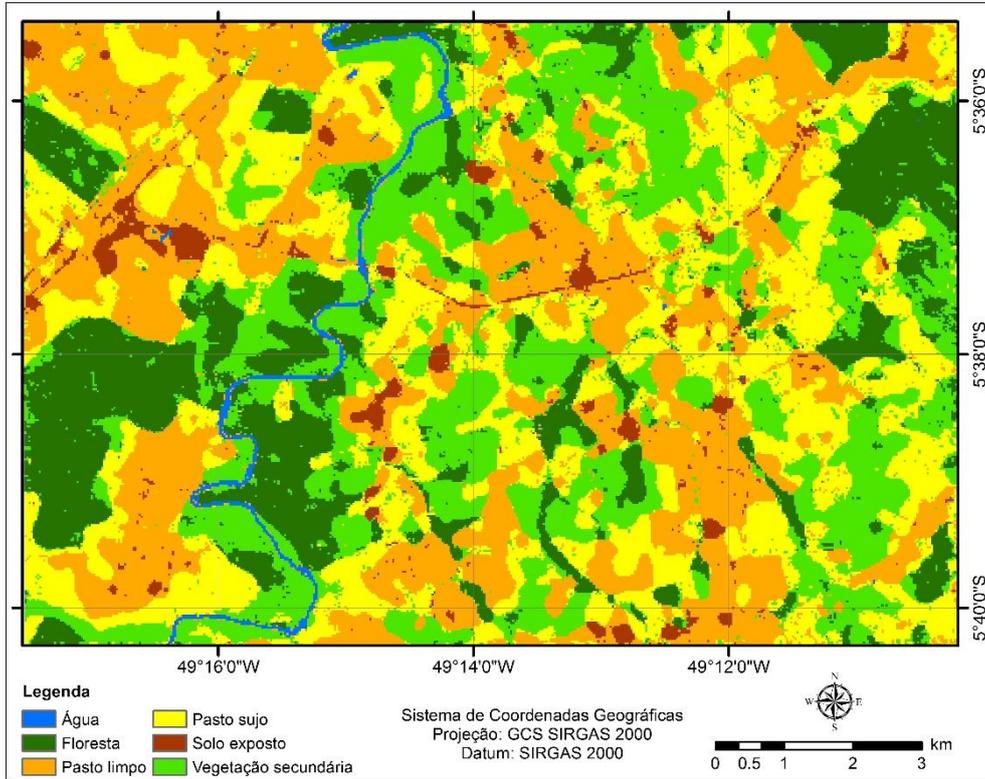
(c) META-CCP-FM5. C: 13



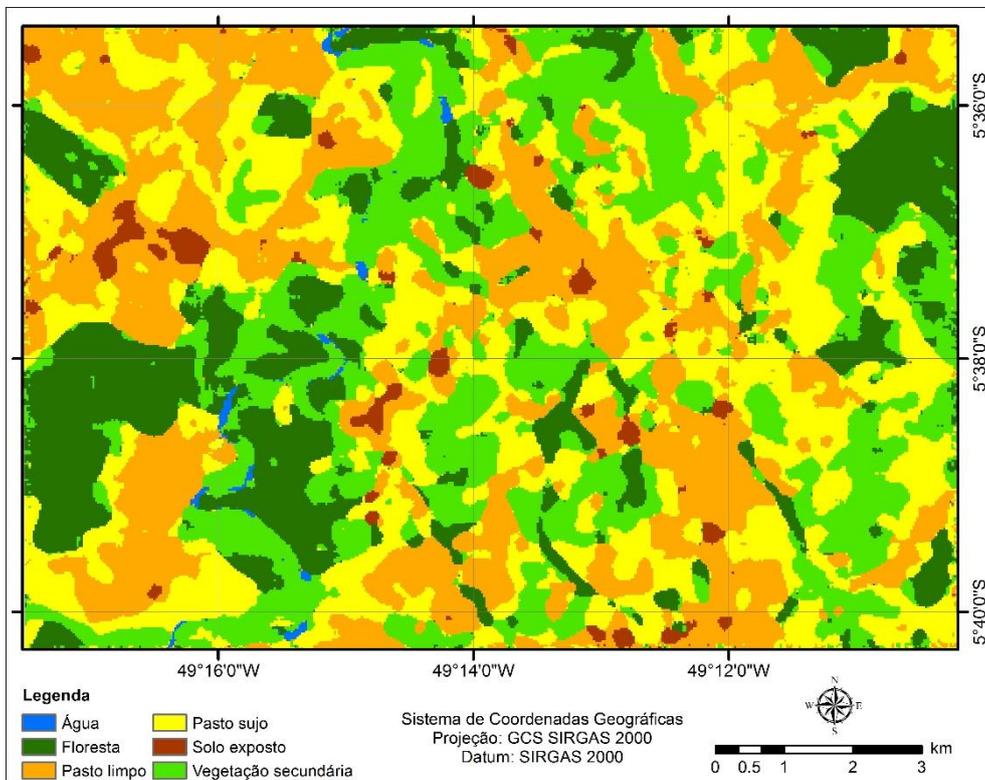
(d) Filtro de maioria 5x5 (convencional)

(continua)

Figura 4.22 – Conclusão.



(e) META-CCP-FM7. C: 13



(f) Filtro de maioria 7x7 (convencional)

Fonte: Produção do autor.

Figura 4.23 – Imagem diferença obtida entre os produtos gerados pela META-CCP, com Fator C de 13 e filtro de maioria 3x3, e pelo filtro de maioria 3x3 convencional.



■ Pixels classificados igualmente ■ Pixels com classificações distintas

Fonte: Produção do autor.

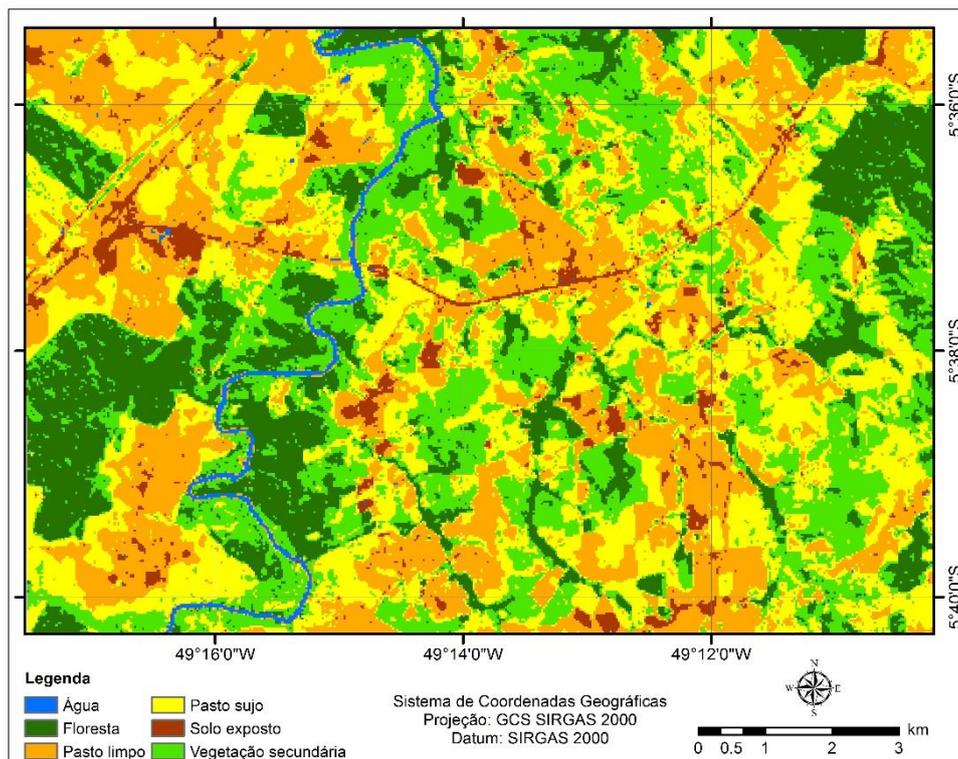
Por outro lado, a eficiência da preservação de MPAD durante o processo de classificação contextual se torna mais nítida à medida que se consideram janelas móveis de maior dimensão. No caso do filtro de maioria com janela móvel de 5x5 pixels, por exemplo, nota-se uma maior eficiência na eliminação de ruídos em regiões centrais, sem resultar em danos significativos a feições estreitas, conforme ilustrado na Figura 4.22(c). Note ainda que a representação de grande parte da estrada de terra presente na imagem, a qual é basicamente composta por feições com 1 pixel de largura, é preservada mesmo ao se adotar uma janela móvel de 7x7 pixels. Em geral, apesar do método convencional remover grande parte dos ruídos de classificação, quanto maior o tamanho da janela móvel, mais evidente se torna a perda de detalhes em feições estreitas. Este efeito pode ser observado na Figura 4.22(d) e Figura 4.22(f).

Em relação à utilização do algoritmo ICM, os produtos de classificação obtidos a partir desse método apresentaram resultados semelhantes àqueles gerados pelo filtro de maioria de ordem 5, quanto à eliminação de pixels ruidosos. Apesar de ser implementado para vizinhança 8, este método apresenta maior eficiência na remoção de ruídos do que o filtro de maioria de ordem 3. Na Figura 4.24, são apresentados produtos de classificação resultantes da utilização do algoritmo ICM, tanto pela abordagem apresentada neste trabalho quanto pela abordagem convencional. Os produtos gerados considerando-se a apresentação de MPAD foram obtidos adotando-se fatores C de 5 e 15.

De forma geral, todos os métodos contextuais apresentaram bons resultados ao adotarem a preservação de MPAD. A possibilidade de se estabelecer máscaras com diferentes níveis de preservação de feições permite adaptar a configuração do classificador de acordo com as características das principais feições de interesse. Dentre os métodos analisados, uma maior capacidade de conciliar eliminação de ruídos e preservação de feições foi observada ao se adotar o algoritmo ICM como abordagem contextual.

Além disso, observa-se nos exemplos apresentados que, o fato de se adotarem fatores C superiores aos valores representativos das divergências observadas entre diferentes pares de classes (Tabela 4.3), ainda permite a obtenção de bons resultados quanto à preservação de feições. O uso de um fator C igual ou inferior àqueles definidos como representativos permite maior preservação das feições. Porém, neste caso, muitos ruídos de classificação são mantidos.

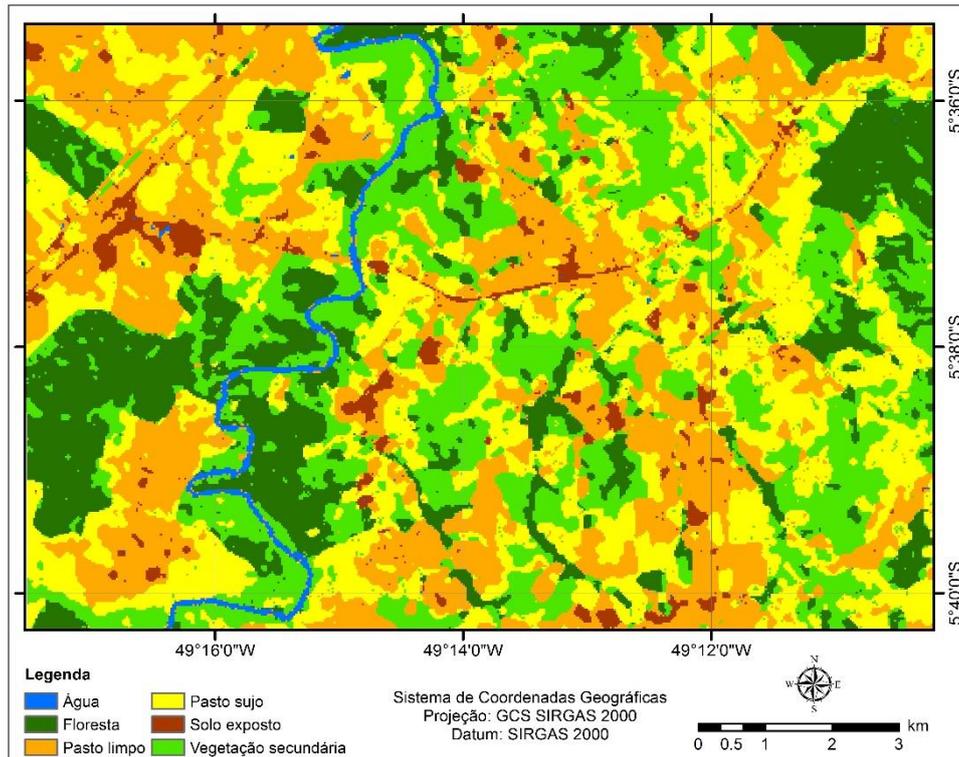
Figura 4.24 – Comparação entre produtos de classificação obtidos pelo algoritmo ICM considerando a META-CCP e pelo método convencional.



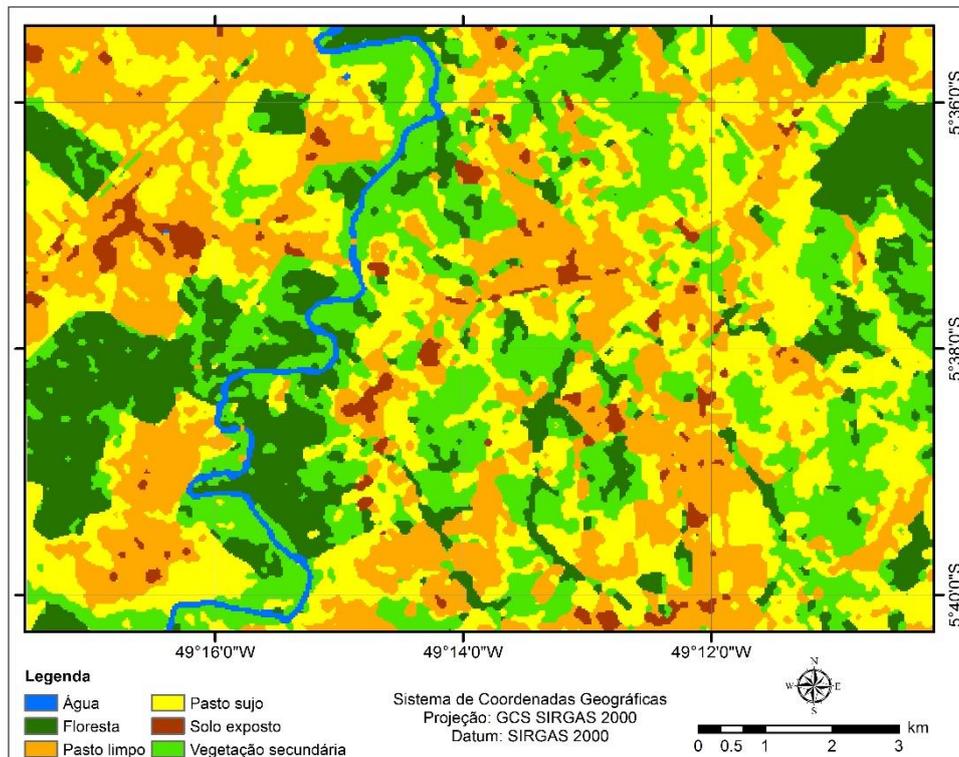
(a) Algoritmo META-CCP-ICM. C: 5

(continua)

Figura 4.24 – Conclusão.



(b) Algoritmo META-CCP-ICM. C: 15



(c) Algoritmo ICM (convencional)

Fonte: Produção do autor.

5 CONCLUSÕES E PERSPECTIVAS FUTURAS

Neste trabalho, foi apresentado uma nova meta-metodologia de classificação contextual, baseada na análise de discriminabilidade entre classes, denominada META-CCP. Este método permite reduzir ruídos de classificação, comumente encontrados em mapas gerados por classificadores baseados em abordagens por-pixel, sem deteriorar a representação de feições estreitas. A META-CCP faz uso de parâmetros obtidos pelo classificador MAXVER. No algoritmo, analisa-se a diferença entre os valores de verossimilhança obtidos para cada pixel, como uma alternativa para se identificar pixels menos susceptíveis a erros de classificação. Estes pixels são definidos como Pixels de Alta Discriminabilidade. Além disso, um parâmetro definido como fator C também é introduzido. A partir do fator C é possível adaptar o limite que define os pixels de alta discriminabilidade, de forma a adequar o classificador à necessidade principal da classificação a ser realizada: preservação de feições ou eliminação/redução de ruídos de classificação.

Com base nas formalizações realizadas, a META-CCP foi implementada considerando-se dois diferentes métodos de classificação contextual: filtro de maioria, com janelas móveis de diferentes dimensões; e, algoritmo ICM, implementado para vizinhança 8. A partir das implementações realizadas, dois estudos de caso foram desenvolvidos. Primeiramente, avaliou-se a eficiência do método proposto na classificação de imagens sintéticas. Por outro lado, no segundo experimento, realizou-se a classificação de uma imagem real de sensoriamento remoto, proveniente do sensor Landsat-8/OLI.

Nos estudos de caso realizados, objetivou-se avaliar a capacidade da META-CCP de conciliar a redução de ruídos e a preservação de feições estreitas. Os produtos de classificação gerados pelo algoritmo implementado foram comparados aos resultados obtidos considerando-se a aplicação das abordagens convencionais de classificação contextual, tanto para o filtro de maioria, quanto para o algoritmo ICM. A fim de comparar a eficiência de classificação tanto em áreas centrais quanto em feições estreitas, duas estatísticas principais foram analisadas: acurácia global, adotada para se avaliar a classificação em áreas centrais; e, acurácia do produtor, utilizada para se avaliar o dano gerado pela classificação em feições estreitas.

A acurácia do produtor foi definida como estatística para se analisar feições estreitas uma vez que medidas globais, tal como a acurácia global, tendem a sempre melhorar com a aplicação de filtros contextuais. Assim, estas medidas não refletem o que ocorre em feições finas durante a classificação, apenas em regiões centrais, sendo o dano apresentado em regiões estreitas mascarado na medida obtida. Neste caso, quanto maior o número de classes, mais mascarado se torna a medida do dano em estruturas finas.

Com base nos resultados obtidos, verifica-se que a META-CCP permite conciliar as operações de redução de ruídos e preservação de feições de acordo com os interesses de classificação e as características apresentadas pela imagem analisada. Todos os classificadores contextuais considerados neste trabalho apresentaram resultados satisfatórios ao se adotar o método proposto. No caso do filtro de maioria, a vantagem de utilização da META-CCP se torna mais evidente à medida que se aumenta o tamanho da janela móvel a ser considerada. Ao se adotar janelas de maior dimensão, observa-se uma maior eficiência na eliminação de ruídos de classificação, sem resultar em danos significativos a feições estreitas. Nos experimentos realizados observa-se que, até mesmo feições estreitas com largura de 1 pixel podem ser preservadas ao se utilizar a abordagem proposta.

De forma geral, pode-se concluir que a abordagem de classificação contextual introduzida neste trabalho apresenta grandes contribuições em termos de eliminação de ruídos, para trabalhos que apresentem preocupação quanto a preservação de feições finas. Poucos estudos são encontrados na literatura relacionados ao problema de preservação de feições estreitas na classificação de imagens de sensoriamento remoto.

Com base nas descobertas apresentadas neste estudo, trabalhos futuros podem ser desenvolvidos buscando-se conciliar a abordagem apresentada com outros métodos de classificação, tanto para a identificação de pixels de alta discriminabilidade quanto para a classificação contextual. Além disso, para trabalhos futuros, pode-se também analisar diferentes classes de cobertura da terra a fim de se estabelecer valores mais adequados a serem utilizados como fator C, para a classificação de imagens de sensoriamento remoto.

REFERÊNCIAS BIBLIOGRÁFICAS

AFFONSO, A.; ESCADA, M. I. S. Monitoramento ambiental por satélites no bioma amazônia - MSA In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos, SP. **Anais...** São José dos Campos: INPE, 2017. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3PBSCRE>>.

ALMEIDA, C. M. Aplicação dos sistemas de sensoriamento remoto por imagens e o planejamento urbano e regional. **Revistas Eletrônica de Arquitetura e Urbanismo (USJT)**, v. 3, p. 98-123, 2010. Disponível em: <http://www.usjt.br/arq.urb/numero_03/8arqurb3-claudia.pdf>. Acesso em: 30 jan. 18.

BARSI, J. A.; LEE, K.; KVARAN, G.; MARKHAM, B. L.; PEDELTY, J. A. The spectral response of the landsat-8 operational land imager. **Remote Sensing**, v. 6, p. 10232-10251, 2014. DOI:10.3390/rs61010232.

BESAG, J. On the statistical analysis of dirty pictures. **Journal of the Royal Statistical Society, Series B: Methodological**, v. 48, n. 3, p. 259-302, 1986.

BINAGHI, E.; GALLO, I.; PEPE, M. A cognitive pyramid for contextual classification of remote sensing images. **IEEE Transaction on Geoscience and Remote Sensing**, v. 41, n. 12, p. 2906–2922, 2003.

CAMPS-VALL, G.; BRUZZONE, L. (Eds.) **Kernel methods for remote sensing data analysis**. Chichester, UK: Wiley, 2009. 403 p. ISBN 978-0-470-72211-4.

CANTY, M. J. **Image analysis, classification, and change detection in remote sensing with algorithms for ENVI/IDL**. 2. ed. Boca Raton, FL: CRC, 2010. 441 p. ISBN 978-1-420-08713-0.

CHEN, S.; ZHANG, H.; SUN, T.; ZHAO, J.; GUO, X. Remote sensing image classification using the spectral-spatial distance based on information content. **Sensors**, v. 18, n. 10, p. 3428, 2018. DOI: <10.3390/s18103428>.

CARAS, T.; HEDLEY, J.; KARNIELI, A. Implications of sensor design for coral reef detection: upscaling ground hyperspectral imagery in spatial and spectral scales. **International Journal of Applied Earth Observation and Geoinformation**, v. 63, p. 68-77, 2017.

CORREIA, A. H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 1998. 273 p. IBI: <6qtX3pFwXQZ4PKzA/isJ7N>. (INPE-7178-TDI/679). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. Disponível em: <<http://urlib.net/6qtX3pFwXQZ4PKzA/isJ7N>>.

CORTIJO, F. J.; BLANCA, N. P. Improving classical contextual classifications. **International Journal of Remote Sensing**, v. 19, n. 8, p. 1591–1613, 1998.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2.ed. [S.l.]: Wiley-Interscience, 2000. 654p. ISBN: 978-0471056690.

EASTMAN, J. R.; JIN, W.; KYEM, P. A. K.; TOLEDANO, J. Raster procedures for multi-criteria/multi-objective decisions. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 5, p. 539-547, 1995.

ERTHAL, G. J.; FRERY, A. C. O. Segmentação de imagens multiespectrais pelo algoritmo ICM: emigração ao ambiente SPRING. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, 6., 1993, Recife, BR. **Anais...** 1993. p. 33-36. (INPE-5516-PRE/1791).

FRERY, A. C. O. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética**. 1993. 252 p. IBI: <6qtX3pFwXQZ3r59YCT/GUfji>. (INPE-5548-TDI/534). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1993. Disponível em: <<http://urlib.net/6qtX3pFwXQZ3r59YCT/GUfji>>.

GONG, P. XU, B. Contextual image analysis methods for urban applications. In: JONG, S. M.; VAN DER MEER, F. D. **Remote sensing image analysis: including the spatial domain**. Netherlands: Dordrecht, 2006. Cap. 8, p. 137-152.

KHEDAM, R.; BELHADJ-AISSA, A. Contextual classification of remotely sensed data using map approach and MRF. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 35, n. 7, p. 11-16, 2004.

KHEDAM, R.; BELHADJ-AISSA, A.; RANCHIN, T. Study of ICM parameters influence on images satellite contextual classification. In: GEOINFORMATION FOR EUROPEAN-WIDE INTEGRATION, 12., 2002, Prague. **Proceedings...** Prague: EARSEL, 2002. p.79-85.

KIM, K. E. Adaptive majority filtering for contextual classification of remote sensing data. **International Journal of Remote Sensing**, v. 17, n. 5, p. 1083-1087, 1996.

LEGENDRE, P. Spatial autocorrelation: trouble or new paradigm? **Ecology**, v.74, n. 6, p. 1659-1673, 1993.

LIN, J.; WANG, Q.; YUAN, Y. In defense of iterated conditional mode for hyperspectral image classification. In: IEEE INTERNATIONAL CONFERENCE ON MULTIMEDIA AND EXPO (ICME), 2014, Chengdu. **Proceedings...** 2014. p.1-6.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, p. 823–870, 2007. Disponível em: <https://doi.org/10.1080/01431160600746456>.

MARTINS, A. L. D. **Uso do algoritmo ICM adaptativo a descontinuidades para o aumento da resolução de imagens digitais por técnicas de reconstrução por super resolução**. 2007. Dissertação (Mestrado em Ciências Exatas e da Terra) - Universidade Federal de São Carlos, São Carlos, 2007.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784-2817, 2018.

MILLER, H. J. Tobler's first law and spatial analysis. **Annals of the Association of American Geographers**, v. 98, n.2, p. 284-289, 2004. Disponível em: <<https://doi.org/10.1111/j.1467-8306.2004.09402005.x>>.

MYEONG, S.; NOWAK, D. J.; HOPKINS, P. F.; BROCK, R. H. Urban cover mapping using digital, high-spatial resolution aerial imagery. **Urban Ecosystems**, v. 5, n. 4, p. 243–256, 2001.

NEGRI, R. G. **Máquina de vetores de suporte adaptativa ao contexto: formalização e aplicações em sensoriamento remoto**. 2013. 166 p. IBI: <8JMKD3MGP7W/3EEEGJP>. (sid.inpe.br/mtc-m19/2013/07.10.14.32-TDI). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3EEEGJP>>.

NEGRI, R. G.; DUTRA, L. V.; SANT'ANNA, S. J. S. Comparing support vector machine contextual approaches for urban area classification. **Remote Sensing Letters**, v. 7, n. 5, p. 485-494, May 2016. DOI: <10.1080/2150704X.2016.1154218>.

QIAN, Y.; ZHANG, K.; QIU, F. Spatial contextual noise removal for post classification smoothing of remotely sensed images. In: ACM SYMPOSIUM ON APPLIED COMPUTING, 2005. **Proceedings...** 2005. p. 524-528.

R CORE TEAM. **R: Software development life cycle**: a description of R's development, testing, release and maintenance processes. Vienna, Austria: R Foundation for Statistical Computing, 2014. Disponível em: <<https://www.r-project.org/doc/R-SDLC.pdf>>.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4.ed. Berlin, Germany: Springer, 2006. 439 p.

RODRIGUEZ-CUENCA, B. R.; MALPICA, J. A.; ALONSO, C. A spatial contextual postclassification method for preserving linear objects in

multispectral imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 1, p. 174–183, 2013.

SANT'ANNA, S. J. S.; YANASSE, C. C. F.; FRERY, A. C. Estudo comparativo de alguns classificadores utilizando-se imagens Radarsat da região de Tapajos. In: JORNADAS LATINO-AMERICANAS DE PERCEPÇÃO REMOTA POR RADAR, 1., 1996, Buenos Aires, AR. **Anais...** 1996. p. 187-194. ISSN 03796566. (INPE-7140-PRE/3070).

SHIMABUKURO, Y. E.; ARAI, E.; ANDERSON, L. O.; ARAGÃO, L. E. O. C.; DUARTE, V. Mapping degraded forest areas caused by fires during the year 2010 in Mato Grosso State, Brazilian Legal Amazon using Landsat-5 TM fraction images. **Revista Brasileira de Cartografia**, v. 69, n. 1, p. 23-32, jan./fev. 2017.

SOUZA, I. M. **Sensoriamento remoto orbital aplicado a estudos urbanos**. São José dos Campos: INPE, 2012. 32 p. IBI: <8JMKD3MGP7W/3BEFCJH>. (sid.inpe.br/mtc-m19/2012/02.28.13.46-PUD). Disponível em: <<http://urlib.net/8JMKD3MGP7W/3BEFCJH>>.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 2.ed. Amsterdam, The Netherlands: Academic Press, 2003. 689 p.

THEODORIDIS, S.; PIKRAKIS, A.; KOUTROUMBAS, K.; CAVOURAS, D. **Introduction to pattern recognition: a matlab approach**. The Netherlands: Elsevier, 2010. 219 p. ISBN 978-0-12-374486-9.

TOBLER, W. R. A computer movie simulating urban growth in the Detroit region. **Economic Geography**, v. 46, p. 234-240, 1970. DOI: <10.2307/143141>.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. 2.ed. Boca Raton, FL: CRC, 2009. 356 p. ISBN 978-1-4200-9072-7.

VIEIRA, P. R. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. 1996. 251 p. IBI: <6qtX3pFwXQZ3r59YD6/GPcyt>. (INPE-6124-TDI/585). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1996. Disponível em: <<http://urlib.net/6qtX3pFwXQZ3r59YD6/GPcyt>>.

YU, L., LIANG, L.; WANG, J.; ZHAO, Y.; CHENG, Q.; HU, L.; LIU, S.; YU, L.; WANG, X.; ZHU, P.; LI, X.; XU, Y.; LI, C.; FU, W.; LI, X.; LI, W.; LIU, C.; CONG, N.; ZHANG, H.; SUN, F.; BI, X.; XIN, Q.; LI, D.; YAN, D.; ZHU, Z.; GOODCHILD, M. F.; GONG, P. Meta-discoveries from a synthesis of satellite-based land-cover mapping research. **International Journal of Remote Sensing**, v. 35, n. 13, p. 4573–4588, 2014. DOI: <10.1080/01431161.2014.930206>.

GLOSSÁRIO

discriminabilidade – relativo a capacidade de se distinguir determinados atributos.

função de densidade de probabilidade – função que descreve a probabilidade relativa de uma variável aleatória tornar um valor dado.

instância – uma realização em particular de um processo aleatório.

meta-metodologia – sistema concebido para desenvolver e testar uma metodologia para um propósito específico; e, como tal, providenciar o desenvolvimento e a pesquisa de metodologias. Neste trabalho, apresenta-se uma metodologia que permite a aplicação de diferentes métodos contextuais de classificação já existentes.

treinamento – operação que faz uso das amostras rotuladas para obtenção de parâmetros do modelo de classificação utilizado (e.g., MAXVER)

APÊNDICE A – PSEUDOCÓDIGOS PARA CLASSIFICAÇÃO UTILIZANDO A META-CCP

A abordagem de classificação proposta neste trabalho, denominada META-CCP, baseada na utilização de máscara de pixels de alta discriminabilidade (MPAD), pode ser implementada conforme apresentado nos pseudocódigos abaixo.

A.1 – Fase 1: Construção de instâncias de modelos de classificação

Algoritmo: Construção de instâncias de modelos de classificação

Entrada: Conjunto de amostras rotuladas para treinamento (*Samples*)
Número total de modelos a serem gerados (*J*)
Número de classes (*K*)
Número de amostras por classe a ser utilizado para gerar cada modelo (*N*)

Saída: Coleção de modelos de classificação ($\{g_{j,k}\}$)

- 1 g = Variável, sem valores atribuídos, para armazenar as ($J * K$) funções discriminantes a serem geradas
 - 2 **Para** $j = 1, \dots, J$ **faça**
 - 3 $Random_samples$ = Vetor contendo um conjunto de *N* amostras por classe, obtidas aleatoriamente do conjunto *Samples*. Processo iterativo feito com reposição de amostras.
 - 4 **Para** $k = 1, \dots, K$ **faça**
 - 5 $Média_classe[k]$ = Vetor contendo a média, para todas as bandas, dos valores contidos em *Random_samples*, amostrados para a classe *k*.
 - 6 $Cov_classe[k]$ = Matriz de covariância obtida para a classe *k*, utilizando as amostras contidas em *Random_samples*.
 - 7 $Função_g$ = Função discriminante gerada para a classe *k*, considerando os parâmetros obtidos para este modelo de classificação
 - 8 $g[j, k] = Função_g$
 - 9 **Fim-Para**
 - 10 **Fim-Para**
 - 11 **Retorna** $\{g\}$ #Retorna o conjunto de funções discriminantes geradas
-

A.2 – Fase 2: Cálculo da variabilidade por classe

Algoritmo: Cálculo da variabilidade por classe

Entrada: Conjunto de pixels rotulados, para todas as classes analisadas (*PixelSet*)
Conjunto de funções discriminantes, geradas para todas as classes (*g*)
Número de pixels rotulados (*I*)
Número total de modelos gerados (*J*)
Número de classes (*K*)

Saída: Coleção de desvios padrões, referentes a cada uma das classes ($\{\sigma_k\}$)

```
1  $\sigma$  = Variável, sem valores atribuídos, para armazenar os K desvios padrões a  
   serem obtidos  
2 Para  $i = 1, \dots, I$  faça  
3    $x_{i,k} = PixelSet[i]$  # Pixel com classe conhecida (classe k)  
4   Para  $j = 1, \dots, J$  faça  
5      $g_{j,k}(x_{i,k}) =$  Cálculo da função discriminante  $j$  para o pixel  $x_{i,k}$   
6   Fim-Para  
7 Fim-Para  
8    $\sigma^2(g(x_{i,k})) =$  Cálculo da variância dos J valores contidos no conjunto  $\{g\}$ , para  
   cada um dos pixels rotulados  
9    $\sigma_k =$  Cálculo da raiz quadrada da média das variâncias obtidas, por classe  
10 Retorna  $\{\sigma_k\}$  #Retorna o conjunto de desvios padrões obtidos
```

A.3 – Fase 3: Escolha dos modelos de classificação representante

Algoritmo: Escolha dos modelos representantes

Entrada: Conjunto de valores de verossimilhança, calculados na fase anterior (*g*)
Número de pixels rotulados (*I*)
Número total de modelos gerados (*J*)
Número de classes (*K*)

Saída: Conjunto de modelos representantes ($\{g_k^*\}$)

```
1  $\sigma$  = Variável, sem valores atribuídos, para armazenar os K modelos  
   representantes  
2  $\bar{g}_{j,k} =$  Média, por classe (k) e modelo (j), dos valores contidos no conjunto  $\{g\}$ ,  
   obtido considerando-se o conjunto de pixels rotulados  
3  $\bar{g}_k =$  Média, por classe (k), dos valores contidos no conjunto  $\{\bar{g}_{j,k}\}$   
4 Para  $k = 1, \dots, K$  faça  
5    $g_k^* =$  Modelo de classificação ( $j$ ) que gerou o valor  $\bar{g}_{j,k}$  mais próximo da  
   média  $\bar{g}_k$ , para a classe  $k$   
6 Fim-Para  
7 Retorna  $\{g_k^*\}$  #Retorna o conjunto de modelos escolhidos
```

A.4 – Fase 4: Classificação por pixel e geração da máscara (MPAD)

Algoritmo: Classificação pontual e obtenção da máscara MPAD

Entrada: Imagem a ser classificada (R)

Conjunto de modelos representantes ($\{g_k^*\}$)

Coleção de desvios padrões, para cada uma das classes ($\{\sigma_k\}$)

Número de classes (K)

Fator C (C)

Saída: Mapa de classificação pontual (y)

Máscara ($MPAD$)

1 y = Matriz de mesma dimensão da imagem R , sem valores atribuídos

2 $MPAD$ = Matriz de zeros, de mesma dimensão da imagem R

3 **Para** $lin = 1, \dots, Nr_linhas(R)$ **faça**

4 **Para** $col = 1, \dots, Nr_colunas(R)$ **faça**

5 **Para** $k = 1, \dots, K$ **faça**

6 $g_k^*(R[lin, col])$ = Cálculo da função discriminante gerada pelo
7 modelo representante, escolhido para a classe k ,
8 para o pixel $R[lin, col]$

7 **Fim-Para**

8 k_1 = Classe que obteve o maior valor de verossimilhança

9 k_2 = Classe que obteve o segundo maior valor de verossimilhança

10 $y[lin, col] = k_1$ # Atribuindo classe ao mapa de classificação pontual

11 **Se** $\left(g_{k_1}^*(R[lin, col]) \geq g_{k_2}^*(R[lin, col]) + C * \sqrt{\sigma_{k_1}^2 + \sigma_{k_2}^2} \right)$ **então**

12 $MPAD[lin, col] = 1$ # Pixel de alta discriminabilidade

13 **Fim-Se**

14 **Fim-Para**

15 **Fim-Para**

16 **Retorna** $y, MPAD$ # Mapa de classificação pontual e máscara MPAD

A.5 – Fase 5: Classificação contextual

Algoritmo: Classificação contextual considerando máscara MPAD

Entrada: Mapa de classificação pontual (y)
Máscara MPAD ($MPAD$)

Saída: Mapa de classificação contextual ($y_{context}$)

```
1  $y_{contextual}$  = Matriz de mesma dimensão do mapa  $y$ , sem valores atribuídos
2 Para  $lin = 1, \dots, Nr\_linhas(y)$  faça
3   Para  $col = 1, \dots, Nr\_colunas(y)$  faça
4     Se ( $MPAD[lin, col] = 1$ ) então
5        $y_{context}[lin, col] =$  Classificação contextual para o pixel  $y[lin, col]$ 
6     Fim-Se
7     Senão
8        $y_{context}[lin, col] = y[lin, col]$  # Preserva-se a classificação pontual
9     Fim-Se
10   Fim-Para
11 Fim-Para
12 Retorna  $y, MPAD$  # Mapa de classificação no formato matricial
```

ANEXO A – EQUAÇÃO PARA ESTIMAÇÃO DE β PARA VIZINHANÇA 8

Conforme descrito por Vieira (1996), o parâmetro β para vizinhança 8 pode ser estimado a partir da solução da equação descrita abaixo. Nesta equação, K representa o número de classes e Viz_Q representa a quantidade de ocorrências de uma determinada configuração Q .

$$\begin{aligned}
 & 8Viz_8 * \frac{(K-1)}{e^{8\beta} + K - 1} + Viz_{71} * \frac{6e^\beta + 7K - 14}{e^{7\beta} + e^\beta + K - 2} + 2Viz_{62} * \frac{2e^{2\beta} + 3K - 6}{e^{6\beta} + e^{2\beta} + K - 2} \\
 & + 2Viz_{611} * \frac{5e^\beta + 3K - 9}{e^{6\beta} + 2e^\beta + K - 3} + Viz_{53} * \frac{2e^{3\beta} + 5K - 10}{e^{5\beta} + e^{3\beta} + K - 2} \\
 & + Viz_{521} * \frac{3e^{2\beta} + 4e^\beta + 5K - 15}{e^{5\beta} + e^{2\beta} + e^\beta + K - 3} + Viz_{5111} * \frac{12e^\beta + 5K - 20}{e^{5\beta} + 3e^\beta + K - 4} \\
 & + Viz_{44} * \frac{4(K-2)}{2e^{4\beta} + K - 2} + Viz_{431} * \frac{e^{3\beta} + 3e^\beta + 4K - 12}{e^{4\beta} + e^{3\beta} + e^\beta + K - 3} \\
 & + 4Viz_{422} * \frac{e^{2\beta} + K - 3}{e^{4\beta} + 2e^{2\beta} + K - 3} + 2Viz_{4211} * \frac{e^{2\beta} + 3e^\beta + 2K - 8}{e^{4\beta} + e^{2\beta} + 2e^\beta + K - 4} \\
 & + 4Viz_{41111} * \frac{3e^\beta + K - 5}{e^{4\beta} + 4e^\beta + K - 5} + Viz_{35} * \frac{-2e^{5\beta} + 3K - 6}{e^{5\beta} + e^{3\beta} + K - 2} \\
 & + Viz_{341} * \frac{-e^{4\beta} + 2e^\beta + 3K - 9}{e^{4\beta} + e^{3\beta} + e^\beta + K - 3} + Viz_{332} * \frac{e^{2\beta} + 3K - 9}{2e^{3\beta} + e^{2\beta} + K - 3} \\
 & + Viz_{3311} * \frac{4e^\beta + 3K - 12}{2e^{3\beta} + 2e^\beta + K - 4} + Viz_{3221} * \frac{2e^{2\beta} + 2e^\beta + 3K - 12}{e^{3\beta} + 2e^{2\beta} + e^\beta + K - 4}
 \end{aligned}$$

$$\begin{aligned}
& + Viz_{32111} * \frac{e^{2\beta} + 6e^\beta + 3K - 15}{e^{3\beta} + e^{2\beta} + 3e^\beta + K - 5} + Viz_{311111} * \frac{10e^\beta + 3K - 18}{e^{3\beta} + 5e^\beta + K - 6} \\
& + 2Viz_{26} * \frac{-2e^{6\beta} + K - 2}{e^{6\beta} + e^{2\beta} + K - 2} + Viz_{251} * \frac{-3e^{5\beta} + e^\beta + 2K - 6}{e^{5\beta} + e^{2\beta} + e^\beta + K - 3} \\
& + 2Viz_{242} * \frac{-e^{4\beta} + K - 3}{e^{4\beta} + 2e^{2\beta} + K - 3} + 2Viz_{2411} * \frac{-e^{4\beta} + e^\beta + K - 4}{e^{4\beta} + e^{2\beta} + 2e^\beta + K - 4} \\
& + 2Viz_{233} * \frac{-e^{3\beta} + K - 3}{2e^{3\beta} + e^{2\beta} + K - 3} + Viz_{2321} * \frac{-e^{3\beta} + e^\beta + 2K - 8}{e^{3\beta} + 2e^{2\beta} + e^\beta + K - 4} \\
& + Viz_{23111} * \frac{-e^{3\beta} + 3e^\beta + 2K - 10}{e^{3\beta} + e^{2\beta} + 3e^\beta + K - 5} + Viz_{2222} * \frac{2(K - 4)}{4e^{2\beta} + K - 4} \\
& + 2Viz_{22211} * \frac{e^\beta + K - 5}{3e^{2\beta} + 2e^\beta + K - 5} + 2Viz_{221111} * \frac{2e^\beta + K - 6}{2e^{2\beta} + 4e^\beta + K - 6} \\
& + 2Viz_{2111111} * \frac{3e^\beta + K - 7}{e^{2\beta} + 6e^\beta + K - 7} + Viz_{17} * \frac{-6e^{7\beta} + K - 2}{e^{7\beta} + e^\beta + K - 2} \\
& + Viz_{161} * \frac{-5e^{6\beta} + K - 3}{e^{6\beta} + 2e^\beta + K - 3} + Viz_{152} * \frac{-4e^{5\beta} - e^{2\beta} + K - 3}{e^{5\beta} + e^{2\beta} + e^\beta + K - 3} \\
& + Viz_{1511} * \frac{-4e^{5\beta} + K - 4}{e^{5\beta} + 3e^\beta + K - 4} + Viz_{143} * \frac{-3e^{4\beta} - 2e^{3\beta} + K - 3}{e^{4\beta} + e^{3\beta} + e^\beta + K - 3} \\
& + Viz_{1421} * \frac{-3e^{4\beta} - e^{2\beta} + K - 4}{e^{4\beta} + e^{2\beta} + 2e^\beta + K - 4} + Viz_{14111} * \frac{-3e^{4\beta} + K - 5}{e^{4\beta} + 4e^\beta + K - 5}
\end{aligned}$$

$$\begin{aligned}
& + Viz_{1331} * \frac{-4e^{3\beta} + K - 4}{2e^{3\beta} + 2e^\beta + K - 4} + Viz_{1322} * \frac{-2e^{3\beta} - 2e^{2\beta} + K - 4}{e^{3\beta} + 2e^{2\beta} + e^\beta + K - 4} \\
& + Viz_{13211} * \frac{-2e^{3\beta} - e^{2\beta} + K - 5}{e^{3\beta} + e^{2\beta} + 3e^\beta + K - 5} + Viz_{131111} * \frac{-2e^{3\beta} + K - 6}{e^{3\beta} + 5e^\beta + K - 6} \\
& + Viz_{12221} * \frac{-3e^{2\beta} + K - 5}{3e^{2\beta} + 2e^\beta + K - 5} + Viz_{122111} * \frac{-2e^{2\beta} + K - 6}{2e^{2\beta} + 4e^\beta + K - 6} \\
& + Viz_{1211111} * \frac{-e^{2\beta} + K - 7}{e^{2\beta} + 6e^\beta + K - 7} + Viz_{11111111} * \frac{K - 8}{8e^\beta + K - 8} \\
& - Viz_{08} * \frac{8}{e^{8\beta} + K - 1} - Viz_{071} * \frac{7e^{7\beta} + e^\beta}{e^{7\beta} + e^\beta + K - 2} \\
& - 2Viz_{062} * \frac{3e^{6\beta} + e^{2\beta}}{e^{6\beta} + e^{2\beta} + K - 2} - 2Viz_{0611} * \frac{3e^{6\beta} + e^\beta}{e^{6\beta} + 2e^\beta + K - 3} \\
& - Viz_{053} * \frac{5e^{5\beta} + 3e^{3\beta}}{e^{5\beta} + e^{3\beta} + K - 2} - Viz_{0521} * \frac{5e^{5\beta} + 2e^{2\beta} + e^\beta}{e^{5\beta} + e^{2\beta} + e^\beta + K - 3} \\
& - Viz_{05111} * \frac{5e^{5\beta} + 3e^\beta}{e^{5\beta} + 3e^\beta + K - 4} - Viz_{044} * \frac{8e^{4\beta}}{2e^{4\beta} + K - 2} \\
& - Viz_{0431} * \frac{4e^{4\beta} + 3e^{3\beta} + e^\beta}{e^{4\beta} + e^{3\beta} + e^\beta + K - 3} - 4Viz_{0422} * \frac{e^{4\beta} + e^{2\beta}}{e^{4\beta} + 2e^{2\beta} + K - 3} \\
& - 2Viz_{04211} * \frac{2e^{4\beta} + e^{2\beta} + e^\beta}{e^{4\beta} + e^{2\beta} + 2e^\beta + K - 4} - 4Viz_{041111} * \frac{e^{4\beta} + e^\beta}{e^{4\beta} + 4e^\beta + K - 5}
\end{aligned}$$

$$\begin{aligned}
& - 2Viz_{0332} * \frac{3e^{3\beta} + e^{2\beta}}{2e^{3\beta} + e^{2\beta} + K - 3} - 2Viz_{03311} * \frac{3e^{3\beta} + e^\beta}{2e^{3\beta} + 2e^\beta + K - 4} \\
& - Viz_{03221} * \frac{3e^{3\beta} + 4e^{2\beta} + e^\beta}{e^{3\beta} + 2e^{2\beta} + e^\beta + K - 4} - Viz_{032111} * \frac{3e^{3\beta} + 2e^{2\beta} + 3e^\beta}{e^{3\beta} + e^{2\beta} + 3e^\beta + K - 5} \\
& - Viz_{0311111} * \frac{3e^{3\beta} + 5e^\beta}{e^{3\beta} + 5e^\beta + K - 6} - 8Viz_{02222} * \frac{e^{2\beta}}{4e^{2\beta} + K - 4} \\
& - 2Viz_{022211} * \frac{3e^{2\beta} + e^\beta}{3e^{2\beta} + 2e^\beta + K - 5} - 4Viz_{0221111} * \frac{e^{2\beta} + e^\beta}{2e^{2\beta} + 4e^\beta + K - 6} \\
& - 2Viz_{02111111} * \frac{e^{2\beta} + 3e^\beta}{e^{2\beta} + 6e^\beta + K - 7} - 8Viz_{011111111} * \frac{e^\beta}{8e^\beta + K - 8} = 0
\end{aligned}$$