



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m19/2013/07.10.14.32-TDI

## **MÁQUINA DE VETORES DE SUPORTE ADAPTATIVA AO CONTEXTO: FORMALIZAÇÃO E APLICAÇÕES EM SENSORIAMENTO REMOTO**

Rogério Galante Negri

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Luciano Vieira Dutra, e Sidnei João Siqueira Sant'Anna, aprovada em 01 de agosto de 2013.

URL do documento original:

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

INPE  
São José dos Campos  
2013

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

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

### **Presidente:**

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

### **Membros:**

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

Dr<sup>a</sup> Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

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

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

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

Dr<sup>a</sup> Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

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

### **BIBLIOTECA DIGITAL:**

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

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

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

### **EDITORAÇÃO ELETRÔNICA:**

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

Luciana Manacero - Serviço de Informação e Documentação (SID)



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m19/2013/07.10.14.32-TDI

## **MÁQUINA DE VETORES DE SUPORTE ADAPTATIVA AO CONTEXTO: FORMALIZAÇÃO E APLICAÇÕES EM SENSORIAMENTO REMOTO**

Rogério Galante Negri

Tese de Doutorado do Curso de Pós-Graduação em Computação Aplicada, orientada pelos Drs. Luciano Vieira Dutra, e Sidnei João Siqueira Sant'Anna, aprovada em 01 de agosto de 2013.

URL do documento original:

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

INPE  
São José dos Campos  
2013

Dados Internacionais de Catalogação na Publicação (CIP)

---

Negri, Rogério Galante.

N312m Máquina de Vetores de Suporte Adaptativa ao Contexto: Formalização e Aplicações em Sensoriamento Remoto / Rogério Galante Negri. – São José dos Campos : INPE, 2013.

xxvi + 140 p. ; (sid.inpe.br/mtc-m19/2013/07.10.14.32-TDI)

Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

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

1. SVM. 2. classificação de imagens. 3. contexto. I.Título.

CDU 528.854

---

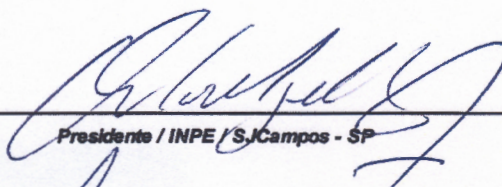


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

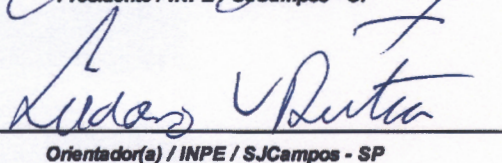
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Doutor(a)** em  
**Computação Aplicada**

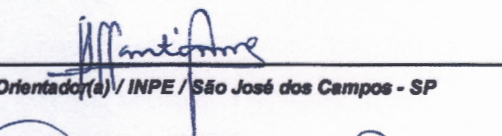
Dr. Antônio Miguel Vieira Monteiro

  
Presidente / INPE / SJC Campos - SP

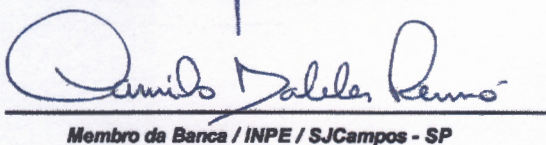
Dr. Luciano Vieira Dutra

  
Orientador(a) / INPE / SJC Campos - SP

Dr. Sidnei João Siqueira Sant'Anna

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

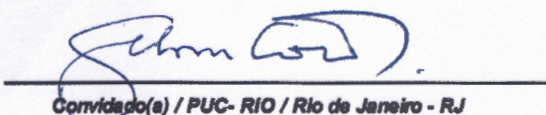
Dr. Camilo Daleles Rennó

  
Membro da Banca / INPE / SJC Campos - SP

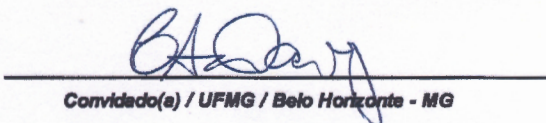
Dra. Ana Carolina Lorena

  
Convidado(a) / UNIFESP / São Paulo - SP

Dr. Gilson Alexandre Ostwald Pedro da Costa

  
Convidado(a) / PUC- RIO / Rio de Janeiro - RJ

Dr. Clodoveu Augusto Davis Junior

  
Convidado(a) / UFMG / Belo Horizonte - MG

Este trabalho foi aprovado por:

( ) maioria simples

unanimidade

Aluno (a): **Rogério Galante Negri**



*“Simplicity does not precede complexity, but follows it”.*

ALAN J. PERLIS





*Dedico este trabalho a meus vetores suporte... meus pais,*

*Décio e Maria Ivete.*



## AGRADECIMENTOS

Agradeço aos professores Luciano Vieira Dutra e Sidnei João Siqueira Sant'Anna pela orientação, amizade e confiança.

Ao Instituto Nacional de Pesquisas Espaciais pela oportunidade e por todo suporte concedido.

À CAPES pelo auxílio financeiro.

À Eliana Pantaleão e ao Professor Guaraci José Erthal, por toda contribuição e atenção.

Aos amigos que fiz durante estes anos de pós-graduação, em especial, aos Amigos da Senzala.

A meus pais, pelo apoio e incentivo singular.



## RESUMO

Em diversos estudos em Sensoriamento Remoto, o método Máquina de Vetores Suporte (*Support Vector Machine* - SVM) tem sido empregado para classificação de imagens. Embora a formulação original deste método não incorpore a informação contextual, existem diferentes propostas para a incorporação desse tipo de informação pelo método SVM. Geralmente, tais propostas consistem na modificação da etapa de treinamento do método SVM ou na integração de seus resultados de classificação através de modelos estocásticos. Este estudo traz uma nova perspectiva com relação ao desenvolvimento de SVM contextuais. O conceito principal desta nova proposta consiste em deslocar o hiperplano de separação, determinado inicialmente pelo SVM tradicional, para cada pixel da imagem, em função de sua informação contextual e de acordo com um submodelo de contextualização adotado. Neste trabalho foram propostos dois submodelos, denominados Repulsivo e Translativo. O submodelo Repulsivo permite a realização de movimentos de translação e rotação para adaptação do hiperplano, enquanto o submodelo Translativo permite apenas deslocamentos na direção ortogonal ao hiperplano. Três estudos de caso foram realizados, em que os resultados obtidos pelo método proposto são comparados com resultados obtidos pelos métodos SVM tradicional, SVM adaptado ao algoritmo ICM (*Iterated Conditional Modes*) e pela aplicação do Filtro da Moda sobre imagens classificadas pelo método SVM. Enquanto o primeiro estudo aborda problemas de classificação binária utilizando imagens simuladas, o segundo e terceiro estudos de caso consideram a classificação multiclasse de imagens de Sensoriamento Remoto obtidas pelos sensores ALOS PALSAR e IKONOS-II MS, respectivamente. Os resultados mostram que o método proposto é capaz de produzir resultados de classificação com exatidão semelhante aos métodos contextuais considerados neste estudo. No entanto, verifica-se que o método proposto apresenta maior capacidade de preservação de alvos pontuais e das bordas entre regiões de diferentes classes, em comparação aos métodos contextuais considerados.



# CONTEXT ADAPTIVE SUPPORT VECTOR MACHINE: FORMALIZATION AND REMOTE SENSING APPLICATIONS

## ABSTRACT

Several Remote Sensing studies have adopted the Support Vector Machine (SVM) method for image classification. Although the original formulation of this method does not incorporate contextual information, there are different proposals to incorporate this information on SVM classification. Usually, these proposals modify the SVM training phase or integrating SVM classifications using stochastic models. This study presents a new perspective on the development of contextual SVMs. The main concept of this new proposal is to displace the separation hyperplane, initially determined by the traditional SVM, for each pixel in the image. The hyperplane displacement is produced on basis of contextual information of each pixel and according to a contextualization submodel adopted. This work presents two contextualization submodels, called Repulsive and Translative. The Repulsive Submodel allows translational and rotational movements in order to adapt the separation hyperplane, while in the Translative submodel only movements in the hyperplane orthogonal direction are performed. Three case studies were conducted, where a comparison with SVM, SVM integrated to Iterated Concitional Modes(ICM) algorithm and to Mode Filter are made. While the first study deals with binary classification problems using simulated images, the second and third case studies consider the multiclass classification of Remote Sensing images from ALOS PALSAR and IKONOS MS-II sensors, respectively. The results show that the proposed method is able to produce classification results with similar accuracy to the others contextual methods considered in this study. However, the proposed method has an improved ability to preserve pointwise targets and edges between regions of different classes, when compared to the other contextual methods.





## LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Exemplos de hiperplanos capazes de separar adequadamente os padrões <span style="color: red;">▲</span> e <span style="color: green;">■</span> . O hiperplano $f_1$ proporciona maior <i>margem de separação</i> . . . . .	7
2.2 Representação dos parâmetros do hiperplano de separação, da margem e dos vetores suporte. . . . .	8
2.3 Representação do hiperplano de separação no caso de padrões não linearmente separáveis. . . . .	11
2.4 Confiabilidade da classificação de padrões representada pela sua distância ao hiperplano. . . . .	13
2.5 Exemplo de mapeamento dos padrões para um espaço de maior dimensão que proporciona separação linear. Fonte: Adaptado de Kavzoglu e Colkesen (2009). . . . .	14
2.6 Exemplo de aplicação das estratégias multiclasse OAA e OAO em um problema de separação envolvendo 3 classes. . . . .	17
3.1 Etapas do método de classificação contextual proposto. . . . .	24
3.2 Reprojeção dos padrões com diferentes níveis de confiança. . . . .	26
3.3 Etapas de ajuste do hiperplano local $f_{Local}(\mathbf{x}) = 0$ , segundo o submodelo Repulsivo, com relação ao padrão <span style="color: blue;">★</span> . . . . .	30
3.4 Etapas de ajuste do hiperplano local $f_{Local}(\mathbf{x}) = 0$ , segundo o submodelo Translativo, com relação ao padrão <span style="color: blue;">★</span> . . . . .	33
3.5 Etapas da classificação contextual de um problema binário, segundo o método CaSVM e os submodelos Repulsivo e Translativo. . . . .	35
3.6 Tendência característica observada em experimentos empíricos que relaciona os valores associados a $\lambda$ e o respectivo percentual de acurácia proporcionado. . . . .	36
4.1 Interface principal do sistema desenvolvido. . . . .	44
4.2 Imagem ALOS PALSAR em amplitude, na composição colorida (HH)R(HV)G(VV)B, entorno da região da Floresta Nacional do Tapajós - PA. Diferentes tipos de cobertura da terra são identificados. . . . .	46
4.3 <i>Phantom</i> adotado para simulação de imagens e amostras utilizadas para treinamento dos métodos. . . . .	47
4.4 Exemplos de imagens simuladas compostas por classes de diferentes contrastes. . . . .	47

4.5	Distinção entre os pixels que compõem os diferentes tipos de regiões ou estão na borda entre duas regiões. . . . .	49
4.6	Percentuais de acurácia obtidos na classificação de imagens com pares de classes de diferentes contrastes utilizando variadas configurações de parâmetros. . . . .	51
4.7	Tempo computacional despendido no treinamento do método SVM, considerando classes com diferentes contrastes entre si. . . . .	54
4.8	Amostras utilizadas no cálculo da acurácia das classificações produzidas por diferentes métodos de estimação de $\lambda$ . . . . .	56
4.9	Acurácia média obtida pelo valor estimado de $\lambda$ pelos métodos analisados, considerando os submodelos Repulsivo e Translativo. . . . .	58
4.10	Tempo computacional médio exigido na estimação do parâmetro $\lambda$ pelos métodos analisados, considerando os submodelos Repulsivo e Translativo. . . . .	59
4.11	Resultado da aplicação do procedimento <i>Grid Search</i> para seleção dos parâmetros adequados do algoritmo ICM, para uso posterior no método SVM+ICM. . . . .	62
4.12	Acurácia segundo a classificação no interior regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	64
4.13	Acurácia média de classificação no interior regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	65
4.14	Coefficiente <i>Upsilon</i> dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	66
4.15	Coefficiente <i>Upsilon</i> dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	67
4.16	Acurácia média da classificação nas regiões pontuais, com relação às imagens com diferentes contrastes entre classes. . . . .	68
4.17	Tempo computacional despendido na classificação de imagens com diferentes contrastes entre classes. . . . .	69
4.18	Resultados de classificação obtidos sobre uma das imagens simulada com baixo contraste entre classes. . . . .	70
4.19	Resultados de classificação obtidos sobre uma das imagens simulada com médio contraste entre classes. . . . .	71
4.20	Resultados de classificação obtidos sobre uma das imagens simulada com alto contraste entre classes. . . . .	72
4.21	Imagem ALOS PALSAR contendo as amostras de treinamento (círculos cheios) e de validação (polígonos vazios), e os pixels selecionados para avaliação das classificações nas bordas entre regiões de diferentes classes. . . . .	75

4.22	Representação dos resultados do procedimento <i>Grid Search</i> , aplicado para auxílio na seleção dos parâmetros dos métodos SVM (estratégia multiclasse OAA e OAO) e do método SVM+ICM. . . . .	77
4.23	Acurácias globais obtidas pelos métodos analisados. . . . .	78
4.24	Coeficientes <i>Upsilon</i> computados a partir da classificação dos pixels localizados na borda entre regiões das classes Floresta Primária e Solo Exposto, segundo os métodos de classificação analisados. . . . .	82
4.25	Coeficientes <i>Upsilon</i> computados a partir da classificação dos pixels localizados na borda entre regiões das classes Pastagem e Floresta Primária, segundo os métodos de classificação analisados. . . . .	83
4.26	Coeficientes <i>Upsilon</i> computados a partir da classificação dos pixels localizados na borda entre regiões das classes Agricultura de tipo 1 e Floresta Primária, segundo os métodos de classificação analisados. . . . .	83
4.27	Tempo computacional exigido pelos métodos de classificação analisados. . . . .	84
4.28	Alguns resultados de classificação relevantes obtidos pelos diferentes métodos analisados. Legenda: ■ Floresta Primária ■ Solo Exposto ■ Pastagem ■ Agricultura tipo 1 . . . . .	86
4.29	Imagem utilizada no estudo, amostras utilizadas para treinamento e validação dos experimentos e legenda referente as amostras selecionadas. . . . .	89
4.30	Identificação de veículos na imagem para avaliação dos métodos quanto à capacidade de classificação de alvos pontuais. A colorização destes alvos foi editada manualmente. . . . .	90
4.31	Representação dos resultados do procedimento <i>Grid Search</i> , aplicado para auxílio na seleção dos parâmetros dos métodos SVM (estratégia multiclasse OAA e OAO) e do método SVM+ICM. . . . .	91
4.32	Acurácias globais obtidas pelos métodos analisados. . . . .	92
4.33	Coeficientes <i>Upsilon</i> obtidos pelos métodos analisados na classificação dos pixels localizados na borda entre regiões da classe Telhado de Cerâmica e as demais classes. . . . .	94
4.34	Coeficientes <i>Upsilon</i> obtidos pelos métodos analisados na classificação dos pixels localizados na borda entre regiões da classe Asfalto e as demais classes. . . . .	95
4.35	Acurácia na classificação de alvos pontuais. . . . .	96
4.36	Tempo computacional exigido pelos métodos de classificação analisados. . . . .	96
4.37	Alguns resultados de classificação relevantes obtidos pelos diferentes métodos analisados. Legenda: ■ V.Alta ■ V.Baixa ■ Telha.(Cer.) ■ Telha.(Con.) ■ Solo.Exp. ■ Asfalto ■ Veículos . . . . .	99

A.1	Gráfico do coeficiente <i>Upsilon</i> , considerando dois conjuntos com 1000 pixels em cada classe. . . . .	114
B.1	Organização das funções da biblioteca desenvolvida, segundo suas finalidades. . . . .	116
B.2	Aba principal: informações sobre a imagem e amostras utilizadas no processo de classificação. . . . .	119
B.3	Interface de seleção do método de classificação e ajuste dos respectivos parâmetros. . . . .	120
B.4	Definição dos parâmetros para execução do procedimento <i>Grid Search</i> . . . . .	121
B.5	Opções gerais de processamento: seleção dos métodos de otimização, responsáveis pela resolução do problema (2.12), e estimação de $\lambda$ . . . . .	122

## LISTA DE TABELAS

	<u>Pág.</u>	
4.1	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia obtidos. . . . .	60
4.2	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os tempos computacionais exigidos. . . . .	60
4.3	Amostras de treinamento e validação. . . . .	76
4.4	Quantidade de pixels selecionados para verificar a acurácia nas bordas entre regiões de diferentes classes. . . . .	76
4.5	Frequências relativas as comparações entre a acurácia das classificações obtidas pelos métodos no processo de avaliação realizado. O método SVM+ICM é denotado por [U]. . . . .	81
4.6	Amostras de treinamento e validação. . . . .	90
4.7	Quantidade de pixels selecionados para quantificar a acurácia nas bordas das regiões. . . . .	90
4.8	Frequências relativas as comparações entre a acurácia das classificações obtidas pelos métodos no processo de avaliação realizado. O método SVM+ICM é denotado por [U]. . . . .	93
C.1	Médias e respectivos valores mínimos e máximos, entre parênteses, a respeito do tempo computacional despendido pelos métodos analisados. .	123
C.2	Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia de classificação no interior das regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	124
C.3	Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia de classificação no interior das regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	124
C.4	Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito do coeficiente <i>Upsilon</i> dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	124

C.5	Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito do coeficiente <i>Upsilon</i> dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	125
C.6	Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia da classificação nas regiões pontuais, com relação às imagens com diferentes contrastes entre classes. . . . .	125
C.7	Médias e respectivos desvios padrão, entre parênteses, a respeito do tempo computacional despendido na classificação de imagens com diferentes contrastes entre classes. . . . .	125
C.8	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia de classificação no interior das regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	126
C.9	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia de classificação no interior das regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	126
C.10	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os coeficientes <i>Upsilon</i> dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes. . . . .	127
C.11	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os coeficientes <i>Upsilon</i> dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes. . . . .	127
C.12	Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo a acurácia de classificação das regiões pontuais, com relação às imagens com diferentes contrastes entre classes. . . . .	128
D.1	Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAO. . . . .	129
D.2	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $3 \times 3$ . . .	129
D.3	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $5 \times 5$ . . .	129

D.4	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $7 \times 7$ .	130
D.5	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $3 \times 3$ .	130
D.6	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $5 \times 5$ .	130
D.7	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $7 \times 7$ .	130
D.8	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $3 \times 3$ .	130
D.9	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $5 \times 5$ .	131
D.10	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $7 \times 7$ .	131
D.11	Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAA.	132
D.12	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $3 \times 3$ .	132
D.13	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $5 \times 5$ .	132
D.14	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $7 \times 7$ .	133
D.15	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $3 \times 3$ .	133
D.16	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $5 \times 5$ .	133
D.17	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $7 \times 7$ .	133
D.18	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $3 \times 3$ .	133
D.19	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $5 \times 5$ .	134
D.20	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $7 \times 7$ .	134
D.21	Matriz de confusão referente à classificação obtida pelo método SVM+ICM.	134
E.1	Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAO.	135

E.2	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $3 \times 3$ .	135
E.3	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $5 \times 5$ .	135
E.4	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto $7 \times 7$ .	136
E.5	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $3 \times 3$ .	136
E.6	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $5 \times 5$ .	136
E.7	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto $7 \times 7$ .	136
E.8	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $3 \times 3$ .	136
E.9	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $5 \times 5$ .	137
E.10	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto $7 \times 7$ .	137
E.11	Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAA.	138
E.12	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $3 \times 3$ .	138
E.13	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $5 \times 5$ .	138
E.14	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto $7 \times 7$ .	139
E.15	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $3 \times 3$ .	139
E.16	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $5 \times 5$ .	139
E.17	Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto $7 \times 7$ .	139
E.18	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $3 \times 3$ .	139
E.19	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $5 \times 5$ .	140
E.20	Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto $7 \times 7$ .	140



E.21 Matriz de confusão referente à classificação obtida pelo método SVM+ICM.140



# SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
<b>2 CLASSIFICAÇÃO DE IMAGENS E SVM</b> . . . . .	<b>5</b>
2.1 Conceitos Gerais . . . . .	5
2.2 SVM . . . . .	5
2.2.1 Hiperplano de máxima margem de separação . . . . .	6
2.2.2 Margem de separação suave . . . . .	10
2.2.3 Confiabilidade da classificação . . . . .	12
2.2.4 Funções <i>kernel</i> . . . . .	13
2.2.5 Estratégias multiclasse . . . . .	15
2.3 Propostas contextuais de SVM . . . . .	17
2.3.1 Descrição geral sobre versões contextuais de SVM na literatura . . . . .	17
2.3.2 Considerações sobre MRF, o algoritmo ICM e a integração com SVM . . . . .	19
2.3.3 Técnicas de suavização e classificação contextual baseada em SVM . . . . .	22
<b>3 SVM ADAPTATIVA AO CONTEXTO</b> . . . . .	<b>23</b>
3.1 O submodelo Repulsivo . . . . .	27
3.2 O submodelo Translativo . . . . .	31
3.3 Etapas da classificação binária . . . . .	34
3.4 Problemas multiclasse . . . . .	35
3.5 Estimação do parâmetro $\lambda$ . . . . .	35
3.5.1 Busca binária . . . . .	38
3.5.2 Busca exaustiva . . . . .	39
3.5.3 Ajuste da curva de tendência . . . . .	40
3.6 Restrições no uso de funções <i>kernel</i> . . . . .	41
<b>4 EXPERIMENTOS E RESULTADOS</b> . . . . .	<b>43</b>
4.1 Estudo de caso I: classificação binária de imagens simuladas . . . . .	44
4.1.1 Simulação de imagens . . . . .	45
4.1.2 Seleção dos parâmetros do método SVM . . . . .	49
4.1.3 Seleção do algoritmo de otimização . . . . .	51
4.1.4 Seleção do algoritmo de estimação do $\lambda$ . . . . .	55
4.1.5 Classificação binária de imagens simuladas . . . . .	61

4.2	Estudo de caso II: classificação multiclasse de uma imagem do sensor ALOS PALSAR . . . . .	74
4.3	Estudo de caso III: classificação multiclasse de uma imagem do sensor IKONOS-II MS . . . . .	87
<b>5</b>	<b>CONCLUSÕES E PERSPECTIVAS FUTURAS . . . . .</b>	<b>101</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>105</b>
	<b>APÊNDICE A - MEDIDA PARA AVALIAÇÃO DE CLASSIFICAÇÃO EM BORDAS . . . . .</b>	<b>113</b>
	<b>APÊNDICE B - IMPLEMENTAÇÕES. . . . .</b>	<b>115</b>
B.1	Biblioteca de funções para classificação de imagens . . . . .	115
B.2	Descrição do sistema desenvolvido . . . . .	117
	<b>APÊNDICE C - ESTATÍSTICAS DO ESTUDO DE CASO I. . . . .</b>	<b>123</b>
	<b>APÊNDICE D - MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS NO ESTUDO DE CASO II . . . . .</b>	<b>129</b>
	<b>APÊNDICE E - MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS NO ESTUDO DE CASO III. . . . .</b>	<b>135</b>

# 1 INTRODUÇÃO

A *classificação de imagens* de Sensoriamento Remoto é uma das mais importantes aplicações de Reconhecimento de Padrões em estudos ambientais. Dentre diferentes estudos que fazem uso de técnicas de classificação de imagens, podem ser citados: o monitoramento de florestas (FREITAS et al., 2008; SHIMABUKURO et al., 2007), de rios (NIEDERMEIER et al., 2001), de geleiras (WHITEHEAD et al., 2009), o estudo de áreas afetadas por desastres naturais (CHESNEL et al., 2007) e o planejamento urbano (KASANKO et al., 2007).

Os diferentes métodos de classificação de imagem propostos na literatura podem ser entendidos como maneiras distintas de modelar regras de decisão para identificação automática dos alvos, dentre um número definido de classes temáticas (KHEDAM et al., 2002). O *paradigma de aprendizado* é uma característica que determina como é conduzida a modelagem da regra de decisão. Os aprendizados supervisionado e não supervisionado são dois paradigmas comumente utilizados nos métodos de classificação de imagens.

Para os métodos cujo aprendizado é supervisionado, são fornecidos conjuntos de treinamento que contém o conhecimento prévio a respeito das classes que compreendem o problema de classificação. A partir desse conhecimento são extraídos parâmetros necessários para modelagem da regra de decisão do classificador, e então é definido um mapeamento capaz de relacionar padrões ainda não conhecidos a uma determinada classe.

Em oposição aos supervisionados, os métodos de aprendizado não supervisionado não usufruem de informações a respeito das classes que envolvem o problema de classificação, logo, não são capazes de definir um mapeamento entre um conjunto de padrões e um conjunto de classes. Nesse caso, o processo de aprendizado é baseado em analogias construídas ao observar a organização e as relações entre os padrões correspondentes aos pixels da imagem a ser classificada. Como resultado são gerados subconjuntos compostos por padrões similares, sem uma classe associada a estes (KIYASU et al., 2009).

Além do paradigma de aprendizado, a comunidade científica de Sensoriamento Remoto usualmente distingue os métodos de classificação de imagens dentre os baseados em regiões e os baseados em pixels. Os métodos baseados em pixels são mais tradicionais em comparação aos baseados em regiões.

Na classificação por métodos baseados em regiões, a imagem é inicialmente segmentada para que os alvos presentes nesta sejam delimitados. Em seguida, para cada alvo delimitado são extraídas, por exemplo, informações estatísticas, de textura e forma. As informações extraídas de cada alvo são utilizadas na sua classificação.

Por outro lado, os métodos baseados em pixel, ou “pontuais”, efetuam a classificação da imagem a partir da classificação individual de cada um de seus pixels. As informações utilizadas no processo de classificação referem-se aos atributos dos pixels, sem necessariamente considerar a informação de sua vizinhança espacial. Em especial, os métodos baseados em pixels capazes de incorporar a informação da vizinhança espacial no processo de classificação são denominados “contextuais”.

Os métodos pontuais tendem a produzir resultados de classificação com menores níveis de exatidão, quando comparados aos contextuais. As informações dos atributos dos pixels, quando observada isoladamente, podem ser insuficientes para identificar padrões complexos. Neste caso, é comum os pixels serem rotulados com classes distintas de seus vizinhos.

De acordo com [Binaghi et al. \(2003\)](#), a utilização de métodos contextuais nas aplicações em Sensoriamento Remoto é justificada por dois princípios: a estrutura dos fenômenos geográficos e a fotointerpretação humana. Os fenômenos geográficos estão estruturados de modo que os tipos de cobertura da terra tendem a ser encontrados na presença de determinados outros tipos. Na cognição humana, a assinatura espectral dos pixels está integrada com a informação contextual para lidar com a complexidade existente nos padrões de cobertura da terra.

Segundo [Cortijo e Blanca \(1998\)](#), duas formas comuns de produzir classificações contextuais consiste na aplicação de técnicas de suavização ou na suposição da existência de um Campo Aleatório Markoviano (*Markov Random Fields* - MRF) sobre a classificação. As técnicas de suavização incluem a aplicação de filtros sobre os rótulos da imagem classificada e a incorporação de canais adicionais, tais como medidas de textura, antes do processo de classificação pontual. Já o MRF consiste em uma modelagem estatística capaz de incluir a informação contextual em um processo de classificação. Esta forma de classificação contextual se tornou popular após o trabalho de [Besag \(1986\)](#), onde é apresentado o algoritmo Modas Condicionais Iterativas (*Iterated Conditional Modes* - ICM).

Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) é um método de Reconhecimento de Padrões que tem se tornado popular desde sua introdução,

por Boser et al. (1992). Este método tem recebido grande atenção por parte da comunidade científica devido a características como: algoritmo de arquitetura simples, complexidade computacional moderada, boa capacidade de generalização e robustez perante o fenômeno de Hughes (ZORTEA et al., 2007; BRUZZONE; PERSELLO, 2009). O conceito central deste método visa a distinção entre padrões através de hiperplanos cuja margem de separação é máxima.

De acordo com o estudo apresentado em Mountrakis et al. (2011), a grande maioria das pesquisas científicas que utilizam SVM na classificação de imagens de Sensoriamento Remoto adotam a abordagem pontual. No entanto, diferentes propostas de incorporação da informação contextual no método SVM são apresentadas na literatura. Geralmente, tais propostas consistem na integração dos resultados de classificação produzidos pelo SVM em modelos estocásticos (BOVOLO; BRUZZONE, 2005; LI et al., 2011; KHODADADZADEH; GHASSEMIAN, 2011), ou na modificação do algoritmo que contempla o treinamento do método (BOVOLO et al., 2006; BRUZZONE; PERSELLO, 2009; LI et al., 2012; GURRAM; KWON, 2013).

Além da integração com MRFs ou modificações no treinamento do método, verifica-se ainda a possibilidade de efetuar classificações contextuais derivadas do método SVM a partir da adaptação (deslocamento) do hiperplano de separação, para cada pixel da imagem, em função da informação do contexto.

O **objetivo deste trabalho** é o desenvolvimento de um novo método contextual baseado na concepção original do SVM. Diferente das propostas mencionadas, não são adotadas técnicas estocásticas ou modificações no algoritmo que abrange o treinamento do SVM. A versão contextual proposta é baseada no conceito da adaptação do hiperplano de separação, inicialmente determinado pelo método SVM, em função da informação contextual. A transformação da informação contextual em alterações no hiperplano de separação é determinada através de submodelos de contextualização. Neste trabalho são propostos dois submodelos, denominados Repulsivo e Translativo.

Após o desenvolvimento e implementação, o método proposto foi aplicado em três estudos de caso, sendo comparado a outros métodos contextuais também baseados em SVM. No primeiro estudo são realizadas classificações binárias utilizando imagens simuladas. Já no segundo e terceiro estudos, são realizadas classificações multiclasse de imagens de Sensoriamento Remoto. Os resultados obtidos mostram que o método proposto, assim como os demais métodos contextuais, é capaz de produzir classificações homogêneas, ou seja, evita a classificação de pixels com classe distinta

de seus vizinhos. Além dessa característica, foi verificado também que o método proposto possui maior capacidade em classificar adequadamente alvos pontuais (regiões pequenas) e bordas entre regiões, em comparação aos demais métodos considerados neste estudo.

Para apresentar a pesquisa realizada, o texto desta tese está estruturado da seguinte forma: no Capítulo 2 são introduzidos conceitos e notações gerais sobre classificação de imagem, assim como a formulação do método SVM. Neste capítulo também são discutidas propostas contextuais de SVM apresentadas na literatura. No Capítulo 3 é descrita detalhadamente a formulação teórica do método contextual proposto. Estudos de caso, discutidos no Capítulo 4, são utilizados para comparar os desempenhos de classificação obtidos com o novo método SVM contextual com aqueles obtidos com o SVM original e também com outras versões contextuais do SVM. Por fim, no Capítulo 5 são tecidas as conclusões e perspectivas futuras sobre o trabalho desenvolvido.



## 2 CLASSIFICAÇÃO DE IMAGENS E SVM

### 2.1 Conceitos Gerais

Um classificador é representado por uma função  $F: \mathcal{X} \rightarrow \mathcal{Y}$ , que associa elementos do espaço de atributos  $\mathcal{X}$  a uma das classes de  $\Omega = \{\omega_1, \omega_2, \dots, \omega_c\}$ , com  $c \in \mathbb{N}^*$ , a partir de um dado rótulo (indicador) de classe em  $\mathcal{Y} = \{1, 2, \dots, c\}$ . Nestas condições, para  $\mathbf{x} \in \mathcal{X}$  e  $y \in \mathcal{Y}$ ,  $y = F(\mathbf{x})$  indica que  $\mathbf{x}$  pertence à classe  $\omega_y$ .

A classificação de imagens baseada em pixels consiste na aplicação de  $F$  sobre os vetores de atributos dos pixels (padrões) que compõem uma imagem  $\mathcal{I}$ , definida sobre um reticulado (suporte)  $\mathcal{S} \subset \mathbb{N}^2$ , cujo resultado de classificação pode ser denotado por  $F(\mathcal{I})$ . Com relação à imagem em que é conduzido o processo de classificação,  $\mathcal{I}(s) = \mathbf{x}$  denota que o pixel  $s \in \mathcal{S}$  de  $\mathcal{I}$  possui atributos representados pelo vetor  $\mathbf{x} \in \mathcal{X}$ . Ainda, as posições ocupadas pelos vizinhos de  $s$  pertencem ao conjunto  $\mathcal{V}_\rho(s) = \{t \in \mathcal{S} : 0 \leq md(s, t) \leq \rho\}$ , sendo  $\rho$  denominado *raio de influência da vizinhança* e  $md(\cdot, \cdot)$  é uma distância adotada. Nestas condições, define-se por contexto de  $s$  o conjunto de pares ordenados  $(\mathbf{x}, y)$ , compostos pelo vetor de atributos  $\mathbf{x}$  e o indicador de classe  $y$ , tal que  $\mathcal{I}(t) = \mathbf{x}$  e  $t \in \mathcal{V}_\rho(s)$ .

Os diferentes métodos de classificação de imagem propostos na literatura podem ser entendidos como maneiras distintas de modelar a função  $F: \mathcal{X} \rightarrow \mathcal{Y}$  e aplicá-la na classificação de  $\mathcal{I}$ . Para os métodos cujo aprendizado é supervisionado, são utilizadas informações disponíveis em um *conjunto de treinamento*  $\mathcal{D} = \{(\mathbf{x}_i, y_i) \in \mathcal{X} \times \mathcal{Y} : i = 1, \dots, m\}$  composto por  $m \in \mathbb{N}^*$  vetores de treinamento. O mapeamento entre  $\mathcal{X}$  e  $\mathcal{Y}$  definido por  $F$  representa o conhecimento adquirido das informações observadas em  $\mathcal{D}$ .

### 2.2 SVM

Como já mencionado, SVM é um método de Reconhecimento de Padrões que tem recebido grande atenção da comunidade científica devido as várias características atrativas, sejam elas teóricas ou práticas. Em especial, diversas aplicações que abordam classificação de imagens de Sensoriamento Remoto da Terra têm sido conduzidas com êxito com uso do método SVM.

A formalização inicial deste método é apresentada na Subseção 2.2.1, onde é introduzido o conceito de *hiperplano de separação de máxima margem* para classificação de padrões linearmente separáveis em duas classes. A partir do conceito de *margem de separação suave*, é tratada na Subseção 2.2.2 a classificação binária

de padrões não linearmente separáveis. Baseado nas fundamentações apresentadas, uma interpretação sobre a confiabilidade da classificação realizada pelo método SVM é expressa na Subseção 2.2.3<sup>(1)</sup>. Na Subseção 2.2.4 é apresentado um artifício que permite melhorar a classificação de padrões não linearmente separáveis, através do uso de funções *kernel*. Por fim, uma vez que as formulações apresentadas estão vinculadas à classificação entre apenas duas classes, na Subseção 2.2.5 são discutidas técnicas que permitem expandir a aplicação do SVM aos casos que envolvem mais classes.

### 2.2.1 Hiperplano de máxima margem de separação

A formalização do método SVM parte da concepção que hiperplanos podem ser empregados para realizar a separação, no espaço de atributos, entre dois conjuntos de padrões linearmente separáveis. Um hiperplano equivale ao lugar geométrico onde a função  $f : \mathcal{X} \rightarrow \mathbb{R}$ , definida por:

$$f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b, \quad (2.1)$$

torna-se nula, sendo  $\mathbf{w}$  o vetor ortogonal ao hiperplano de separação  $f(\mathbf{x}) = 0$  e  $b$  um escalar tal que  $|b|/\|\mathbf{w}\|$  representa a distância do hiperplano à origem do espaço de atributos. As notações  $|\cdot|$ ,  $\|\cdot\|$  e  $\langle \cdot, \cdot \rangle$  representam o módulo escalar, a norma vetorial e o produto interno vetorial, respectivamente.

A determinação deste hiperplano é baseada na informação disponível em um conjunto de treinamento  $\mathcal{D} = \{(\mathbf{x}_i, y_i) \in \mathcal{X} \times \mathcal{Y} : i = 1, \dots, m\}$  com  $m \in \mathbb{N}^*$  e  $\mathcal{Y} = \{-1, +1\}$ . Neste caso, o padrão  $\mathbf{x}_i$  está associado à classe  $\omega_1$  quando  $y_i = +1$ , ou associado a  $\omega_2$  quando  $y_i = -1$ <sup>(2)</sup>.

Na Figura 2.1 são representas, em um espaço de atributos bidimensional, dois exemplos de hiperplanos,  $f_1$  e  $f_2$ . Embora ambos os hiperplanos sejam capazes de separar adequadamente os conjuntos de padrões  $\blacktriangle$  e  $\blacksquare$ , o hiperplano  $f_1$  apresenta maior *margem de separação* com relação aos aglomerados de padrões. Sendo assim, este hiperplano possui maiores condições de manter a separabilidade entre as classes quando novos padrões forem adicionados, ou seja, ele possui maior capacidade de generalização que  $f_2$ .

<sup>(1)</sup>Embora o conteúdo desta subseção não faça parte da fundamentação teórica do método SVM, mas sim do método proposto no Capítulo 3, ele será mantido, por conveniência, nesta seção.

<sup>(2)</sup>Apesar de  $\mathcal{Y}$ , e a indicação de pertinência às classes por  $y_i$ , diferir da definição estabelecida na Seção 2.1, não existe perda de generalidade.

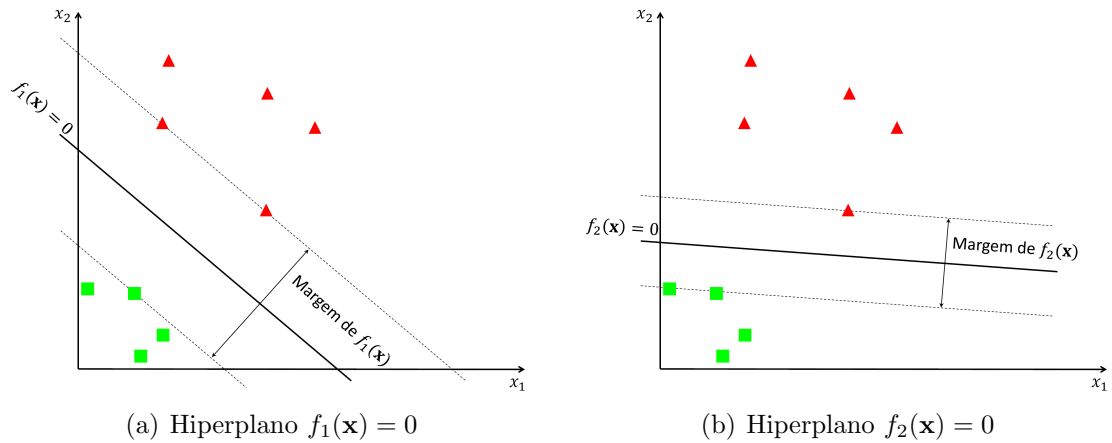


Figura 2.1 - Exemplos de hiperplanos capazes de separar adequadamente os padrões  $\blacktriangle$  e  $\blacksquare$ . O hiperplano  $f_1$  proporciona maior *margem de separação*.

Para obter o hiperplano que proporciona a maior margem de separação entre dois conjuntos de padrões, é considerada a simples relação de distância entre “ponto e reta”. A distância entre um padrão (ponto)  $\mathbf{x}_i$  qualquer e o hiperplano de separação (reta)  $f(\mathbf{x}) = 0$  é calculada por  $\frac{|f(\mathbf{x}_i)|}{\|\mathbf{w}\|}$ .

Reescalando  $\mathbf{w}$  de forma que  $f(\mathbf{x}_i) = +1$  e  $f(\mathbf{x}_j) = -1$ , para  $\mathbf{x}_i \in \omega_1$  e  $\mathbf{x}_j \in \omega_2$ , os padrões mais próximos do hiperplano  $f(\mathbf{x}) = 0$ , são obtidas as seguintes relações:

- (i) a margem de separação tem largura  $\frac{2}{\|\mathbf{w}\|}$ ;
- (ii) dado que  $\mathbf{x}_i \in \omega_1$ , então  $f(\mathbf{x}_i) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq +1$ ;
- (iii) dado que  $\mathbf{x}_j \in \omega_2$ , então  $f(\mathbf{x}_j) = \langle \mathbf{w}, \mathbf{x}_j \rangle + b \leq -1$ .

Com base nestas relações, a maximização da margem de separação é obtida com a determinação de  $\mathbf{w}$  e  $b$  que minimiza  $\|\mathbf{w}\|$  e mantém válidas as relações (ii) e (iii). A determinação de  $\mathbf{w}$  e  $b$  é modelada pelo seguinte problema de otimização (THEODORIDIS; KOUTROUMBAS, 2008):

$$\begin{aligned} \min_{\mathbf{w}, b} \left( \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle \right) \\ \text{sujeito a: } y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1, \quad i = 1, \dots, m. \end{aligned} \quad (2.2)$$

Na Figura 2.2 são ilustradas as relações geométricas que o hiperplano de margem máxima deve respeitar. Cabe ressaltar que os padrões localizados nos limites da margem de separação (i.e.,  $f(\mathbf{x}) = \pm 1$ ) são responsáveis por determinar o hiperplano

ótimo. A estes padrões é dado o nome de *vetores suporte*. É identificado ainda nesta figura a relação (i), que especifica que a margem possui largura  $\frac{2}{\|\mathbf{w}\|}$ , a distância entre a origem do espaço de atributos e o hiperplano  $f(\mathbf{x}) = 0$ , dada por  $\frac{|b|}{\|\mathbf{w}\|}$ , e o vetor  $\mathbf{w}$ , ortogonal a  $f(\mathbf{x}) = 0$ , cujo sentido aponta para a classe composta por padrões com indicador de classe  $y_i = +1$ .

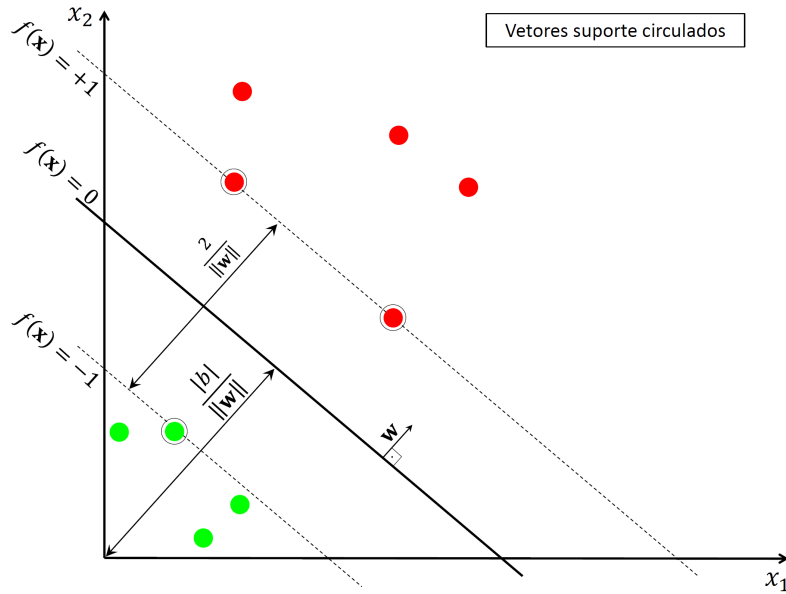


Figura 2.2 - Representação dos parâmetros do hiperplano de separação, da margem e dos vetores suporte.

O problema de otimização que determina o hiperplano de margem máxima possui função objetivo convexa com restrições lineares, logo, torna-se conveniente resolvê-lo com uso da Teoria Lagrangeana. Para isso, inicialmente deve ser construída a função lagrangeana, que consiste na soma da função objetivo de (2.2) com a combinação linear formada pelas restrições deste problema multiplicadas por escalares não negativos  $\gamma_i$ , denominados *multiplicadores de Lagrange*. A seguinte expressão corresponde à forma *primal* da função lagrangeana do problema (2.2):

$$L_P(\mathbf{w}, b, \gamma) = \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle - \sum_{i=1}^m \gamma_i [y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1] \quad (2.3)$$

A solução do problema (2.2) é equivalente ao “ponto de sela” da função lagrangeana (2.3), a qual deve ser minimizada com relação a  $\mathbf{w}$  e  $b$  e maximizada com relação a  $\gamma_i$  (WEBB, 2002). O valor mínimo da função (2.3) com relação a  $\mathbf{w}$  e  $b$  equivale

ao ponto onde sua derivada com relação a estes parâmetros é nula. Por conseguinte, surgem as seguintes relações:

$$\frac{\partial L_P(\mathbf{w}, b, \gamma)}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^m \gamma_i y_i \mathbf{x}_i = 0, \quad (2.4)$$

$$\frac{\partial L_P(\mathbf{w}, b, \gamma)}{\partial b} = \sum_{i=1}^m \gamma_i y_i = 0. \quad (2.5)$$

Substituindo as relações (2.4) e (2.5) na função lagrangeana (2.3), obtém-se como resultado a forma *dual* da função lagrangeana:

$$L_D(\gamma) = \sum_{i=1}^m \gamma_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \gamma_i \gamma_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle. \quad (2.6)$$

Com a eliminação de  $\mathbf{w}$  e  $b$  nesta nova representação da função lagrangeana, a solução do problema (2.2) torna-se equivalente à resolução do seguinte problema de otimização:

$$\begin{aligned} & \max_{\gamma} \left( \sum_{i=1}^m \gamma_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \gamma_i \gamma_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \right) \\ & \text{sujeito a: } \begin{cases} \gamma_i \geq 0, i = 1, \dots, m \\ \sum_{i=1}^m \gamma_i y_i = 0. \end{cases} \end{aligned} \quad (2.7)$$

Os multiplicadores de Lagrange ótimos fornecidos pela resolução de (2.7) possibilitam calcular os parâmetros ótimos que definem o hiperplano de margem máxima. O vetor  $\mathbf{w}$  é definido através da relação (2.4). Já o escalar  $b$  pode ser calculado com a substituição de  $\mathbf{w}$  na função (2.1) e adotando qualquer vetor suporte que a torna igual a 1.

Além de proporcionar maior simplicidade no cálculo dos parâmetros ótimos, a representação dual da função lagrangeana possui como fator o produto interno entre padrões. Esta característica possibilita o uso de funções *kernel*, a ser discutido na Subseção 2.2.4.

Os parâmetros  $\mathbf{w}$  e  $b$  obtidos definem o hiperplano com a maior margem de separação possível, denotado por  $f_{SVM}(\mathbf{x})$ . A classificação pelo método SVM é definida pela regra de decisão  $F_{SVM} : \mathcal{X} \rightarrow \mathcal{Y}$  tal que:

$$F_{SVM}(\mathbf{x}) = \text{sgn}(f_{SVM}(\mathbf{x})), \quad (2.8)$$

onde  $\text{sgn}(\cdot)$  é a função sinal<sup>(3)</sup>. A partir de (2.8),  $\mathbf{x}_i$  é associado à classe  $\omega_1$  se  $F_{SVM}(\mathbf{x}_i) = +1$ , ou à classe  $\omega_2$  caso  $F_{SVM}(\mathbf{x}_i) = -1$ .

### 2.2.2 Margem de separação suave

O desenvolvimento apresentado na subseção anterior é fundamentado em casos onde duas classes de padrões são linearmente separáveis. No entanto, existem casos onde os padrões não são linearmente separáveis. Para contornar este tipo de problema são inseridas variáveis de folga não negativas  $\xi$ , tornando sempre verdadeiras as seguintes relações:

(i) dado que  $\mathbf{x}_i$  está associado a  $\omega_1$ , então  $f(\mathbf{x}_i) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq +1 - \xi_i$ ;

(ii) dado que  $\mathbf{x}_j$  está associado a  $\omega_2$ , então  $f(\mathbf{x}_j) = \langle \mathbf{w}, \mathbf{x}_j \rangle + b \leq -1 + \xi_j$ .

Geometricamente, as variáveis de folga representam o deslocamento que os padrões classificados erroneamente encontram-se do limite da margem de separação referente a sua classe. Na Figura 2.3 é ilustrada tal relação, onde é possível verificar que os padrões  $\mathbf{x}_1$ ,  $\mathbf{x}_2$ ,  $\mathbf{x}_3$  e  $\mathbf{x}_4$  exigem variáveis de folga não nulas. Além disso, observa-se que variáveis de folga superiores a 1 estão associadas aos padrões  $\mathbf{x}_1$  e  $\mathbf{x}_2$ , cujas classificações são incorretas. Variáveis de folga com valores inferiores a 1 estão relacionadas aos padrões  $\mathbf{x}_3$  e  $\mathbf{x}_4$ , localizados no interior da margem de separação. Por fim, padrões classificados corretamente ou sobre os limites da margem de separação possuem variáveis de folga nulas, como é o caso dos padrões  $\mathbf{x}_5$ ,  $\mathbf{x}_6$ ,  $\mathbf{x}_7$ ,  $\mathbf{x}_8$ ,  $\mathbf{x}_9$  e  $\mathbf{x}_{10}$ . Os *vetores suporte* responsáveis por determinar este hiperplano devem apresentar variável de folga não nula, ou ainda possuir folga nula e estar localizados nos limites da margem de separação. As demais relações sobre a largura da margem de separação, o vetor ortogonal ao hiperplano e distância à origem do espaço de atributos são idênticas às apresentadas na Figura 2.2.

Devido à não separabilidade linear dos padrões, é incorporado o custo adicional  $C \sum_{i=1}^m \xi_i$  na função objetivo de (2.2). Este termo é responsável por quantificar o número de padrões classificados erroneamente, incluindo ainda uma penalidade associada a estes erros a partir do parâmetro de regularização  $C$ . Esta consideração

---

<sup>(3)</sup>Seja  $x \in \mathbb{R}$ ,  $\text{sgn}(x) = \begin{cases} +1 & \text{se } x \geq 0 \\ -1 & \text{se } x < 0 \end{cases}$ .

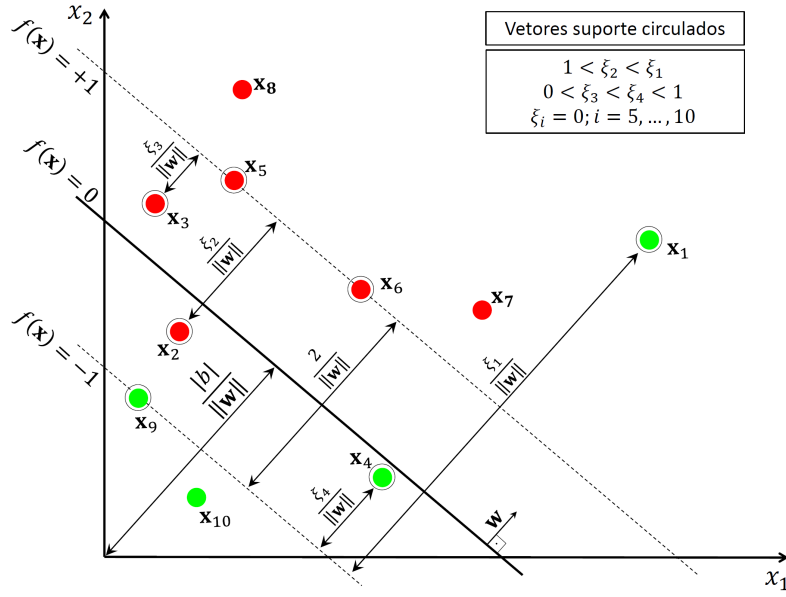


Figura 2.3 - Representação do hiperplano de separação no caso de padrões não linearmente separáveis.

proporciona a seguinte reformulação sobre o problema (2.2):

$$\begin{aligned} & \min_{\mathbf{w}, b} \left( \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle + C \sum_{i=1}^m \xi_i \right) \\ & \text{sujeito a: } \begin{cases} y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i; & i = 1, \dots, m \\ \xi_i > 0; & i = 1, \dots, m. \end{cases} \end{aligned} \quad (2.9)$$

Por sua vez, a função lagrangeana na forma primal obtida a partir do problema (2.9) é expressa por:

$$L'_P(\mathbf{w}, b, \gamma) = \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \gamma_i [y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 + \xi_i] - \sum_{i=1}^m \vartheta_i \xi_i, \quad (2.10)$$

onde  $\vartheta$  são multiplicadores de Lagrange inseridos para garantir a positividade das variáveis de folga  $\xi$ .

Seguindo os mesmos procedimentos apresentados na subseção anterior para obtenção da forma dual da função lagrangeana, as derivadas da função (2.10) com relação a  $\mathbf{w}$ ,  $b$  e  $\xi$  devem ser nulas. O resultado desta derivação com relação a  $\mathbf{w}$  e  $b$  produzem os mesmos resultados obtidos nas relações (2.4) e (2.5). Já a derivação com relação a  $\xi_i$  fornece:

$$\frac{\partial L'_P(\mathbf{w}, b, \gamma)}{\partial \xi_i} = C - \gamma_i - \vartheta_i = 0; \quad i = 1, \dots, m, \quad (2.11)$$

a partir da qual, sendo  $\gamma_i$  e  $\vartheta_i$  escalares reais estritamente positivos, é possível concluir que  $0 \leq \gamma_i \leq C$ .

Após as devidas substituições de (2.4), (2.5) e (2.11) em (2.10), a forma *dual* da função lagrangeana alcançada torna-se idêntica à função (2.6). Assim, o problema de otimização formulado para o tratamento de padrões não linearmente separáveis difere do problema (2.7) apenas com relação às restrições, como segue:

$$\begin{aligned} & \max_{\gamma} \left( \sum_{i=1}^m \gamma_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \gamma_i \gamma_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \right) \\ & \text{sujeito a: } \begin{cases} 0 \leq \gamma_i \leq C, i = 1, \dots, m \\ \sum_{i=1}^m \gamma_i y_i = 0. \end{cases} \end{aligned} \quad (2.12)$$

Com a otimização do problema (2.12), a obtenção do parâmetro  $\mathbf{w}$  decorre da mesma forma realizada para o caso linearmente separável. Por outro lado, o valor de  $b$  é determinado a partir da primeira restrição do problema (2.9), adotando qualquer vetor suporte cuja variável de folga seja nula.

As considerações apresentadas tornam possível a definição de hiperplanos de separação que, baseado nos padrões não linearmente separáveis de  $\mathcal{D}$  e no valor associado ao parâmetro  $C$ , garantem a maior margem de separação e a menor quantidade possível de erros de classificação. Esta característica os denomina por *hiperplanos de margem de separação suave*.

### 2.2.3 Confiabilidade da classificação

Pelas definições apresentadas nas Subseções 2.2.1 e 2.2.2, verifica-se que o hiperplano de separação é definido pelo conjunto de vetores suporte. De acordo com as formulações sobre margem de separação suave (Subseção 2.2.2), os vetores suporte ocupam posições do espaço de atributos localizadas nos limites ou sobre a margem de separação, ou ainda quando classificados erroneamente. Admitindo a margem de separação como uma zona de transição na regra de decisão, conclui-se que o hiperplano é determinado a partir de padrões de treinamento que possuem baixa confiabilidade na classificação.

Dessa forma, é razoável admitir que a *confiabilidade* da classificação de um padrão  $\mathbf{x}_i$  corresponde ao valor  $|f_{SVM}(\mathbf{x}_i)|$ , que equivale a uma distância entre  $\mathbf{x}_i$  e o hiperplano de separação  $f_{SVM}(\mathbf{x}) = 0$ . Assim, após a classificação, quanto maior for a distância entre o padrão e o hiperplano de separação, maior será a *confiabilidade* em sua classificação.



A confiabilidade da classificação de alguns padrões, expressa através da distância entre o padrão e o hiperplano, é ilustrada na Figura 2.4. É possível verificar que os padrões  $\mathbf{x}_2$ ,  $\mathbf{x}_3$  e  $\mathbf{x}_4$  estão sobre os limites da margem de separação, isto é, onde  $f_{SVM}(\mathbf{x}) = \pm 1$ , e por sua vez possuem a mesma confiabilidade de classificação. Verifica-se ainda que a confiabilidade na classificação de  $\mathbf{x}_7$  é superior à confiabilidade de  $\mathbf{x}_1$ , mesmo que  $\mathbf{x}_7$  tenha sido classificado erroneamente. Os padrões  $\mathbf{x}_5$  e  $\mathbf{x}_6$  apresentam as maiores confiabilidades, sendo ainda  $\mathbf{x}_6$  classificado com maior confiabilidade que  $\mathbf{x}_5$ .

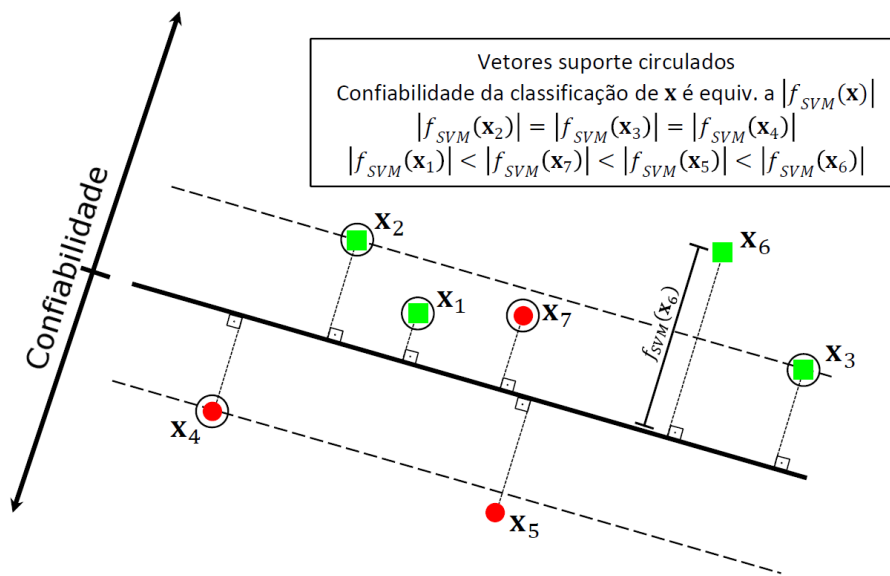



Figura 2.4 - Confiabilidade da classificação de padrões representada pela sua distância ao hiperplano.

#### 2.2.4 Funções *kernel*

Na Subseção 2.2.2 foi introduzido o conceito de hiperplano de margem de separação suave, o que permite o uso de hiperplanos na classificação de padrões não linearmente separáveis. No entanto, existem circunstâncias em que o uso de hiperplanos na classificação de padrões não linearmente separáveis é inadequado, como no exemplo ilustrado na Figura 2.5(a). Uma alternativa ao caso apresentado é realizar o mapeamento dos padrões, que não são linearmente separáveis no *espaço de atributos* original, para outro espaço, denominado *espaço característico*, onde a separabilidade é maior. Na Figura 2.5(b) é mostrado um exemplo de mapeamento dos padrões apresentados na Figura 2.5(a) que possibilita separação linear.

O processo de mapeamento exemplificado na Figura 2.5 pode ser conduzido



(a) Padrões distribuídos sobre o *espaço de atributos* de forma não linearmente separável. Mesmo o uso de hiperplanos de margem suave não proporcionam separação adequada

(b) Mapeamento dos padrões em um *espaço característico* de maior dimensão, onde é possível realizar a separação de forma linear

Figura 2.5 - Exemplo de mapeamento dos padrões para um espaço de maior dimensão que proporciona separação linear. Fonte: Adaptado de Kavzoglu e Colkesen (2009).

implicitamente nas formulações apresentadas nas Subseções 2.2.1 e 2.2.2. Para isto, basta substituir o produto interno  $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$  presente na função objetivo do problema (2.12) por uma função  $K(\cdot, \cdot)$  que respeite as condições do *Teorema de Mercer* (THEODORIDIS; KOUTROUMBAS, 2008):

**Teorema de Mercer:** Sejam  $\mathbf{x}, \mathbf{z} \in \mathbb{R}^d$  e  $\phi(\cdot)$  um mapeamento  $\mathbf{x} \mapsto \phi(\mathbf{x}) \in \mathcal{E}$ , sendo  $\mathcal{E}$  um espaço de Hilbert<sup>(4)</sup>. O produto interno  $\langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle$  é equivalente à função contínua e simétrica<sup>(5)</sup>  $K(\mathbf{x}, \mathbf{z})$  que satisfaz:

$$\int_{\mathcal{X}} \int_{\mathcal{X}} K(\mathbf{x}, \mathbf{z}) g(\mathbf{x}) g(\mathbf{z}) d\mathbf{x} d\mathbf{z} \geq 0, \quad (2.13)$$

para qualquer  $g(\mathbf{x})$ ,  $\mathbf{x} \in \mathcal{X} \subset \mathbb{R}^d$  tal que:

$$\int_{\mathcal{X}} g(\mathbf{x})^2 d\mathbf{x} < +\infty. \quad (2.14)$$

<sup>(4)</sup>Espaço de Hilbert é um espaço vetorial real munido do produto interno com dimensão não necessariamente finita.

<sup>(5)</sup>Simétrica com relação aos vetores de entrada.

Como consequência deste teorema, para qualquer função  $K(\mathbf{x}, \mathbf{z})$  que satisfaz as condições (2.13) e (2.14), é possível afirmar que existe um espaço vetorial onde tal função define um produto interno. Estas funções são denominadas *kernel*.

Embora o Teorema de Mercer forneça condições necessárias para construção de funções que definem o produto interno em algum espaço vetorial, não são fornecidos meios para definir qual é este espaço, ou seja, não é fornecido uma maneira direta de definir  $\phi(\cdot)$  a partir de  $K(\cdot, \cdot)$ . Alguns exemplos de funções *kernel* frequentemente adotadas na resolução de problemas gerais são as funções de Base Radial (*Radial Basis Function* - RBF) e Polinomiais, apresentadas respectivamente em (2.16) e (2.17). Vale ressaltar que o produto interno entre os vetores do espaço de atributos é denominado por função *kernel* Linear (2.15).

$$K_{\text{Linear}}(\mathbf{x}_i, \mathbf{x}_j) = \langle \mathbf{x}_i, \mathbf{x}_j \rangle, \quad (2.15)$$

$$K_{\text{Pol}}(\mathbf{x}_i, \mathbf{x}_j) = (\langle \mathbf{x}_i, \mathbf{x}_j \rangle + 1)^q, \quad (2.16)$$

$$K_{\text{RBF}}(\mathbf{x}_i, \mathbf{x}_j) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}}, \quad (2.17)$$

onde  $q \in \mathbb{N}^*$  e  $\sigma \in \mathbb{R}_+^*$  são parâmetros nos *kernels* RBF e Polinomial.

### 2.2.5 Estratégias multiclasse

De acordo com as formulações apresentadas nas Subseções 2.2.1 e 2.2.2, nota-se que o método SVM foi desenvolvido para problemas que envolvem a separação entre duas classes. A aplicação deste método em problemas que abrangem mais de duas classes está vinculada ao uso de estratégias multiclasse. Na literatura existem dois tipos gerais de estratégias multiclasse: as que reformulam o método e as que decompõem o problema original em subproblemas binários. Reformulações multiclasse exigem maior custo computacional em comparação com as estratégias de decomposição (HSU; LIN, 2002).

As estratégias baseadas em decomposições binárias envolvem basicamente dois passos. O primeiro é responsável pela decomposição do problema multiclasse em subproblemas binários, e o segundo pela reconstrução do problema multiclasse a partir da combinação dos resultados dos subproblemas binários. “Um-Contra-Todos” (One-Against-All - OAA) e “Um-Contra-Um” (One-Against-One - OAO) são exemplos de estratégias multiclasse baseadas em decomposições binárias (WEBB, 2002).

Para problemas que envolvam  $c$  classes e a estratégia OAA é empregada, são definidos  $c$  hiperplanos  $f_{SVM_j}(\mathbf{x}) = 0$ ,  $j = 1, \dots, c$ . Cada hiperplano  $f_{SVM_j}(\mathbf{x}) = 0$  é responsável especificamente pela separação da classe  $\omega_j$  com relação às demais  $\Omega \setminus \{\omega_j\}$ . Ainda, para determinação destes hiperplanos, os padrões da classe  $\omega_j$  recebem indicadores de classe ( $y$ ) iguais a  $+1$ , enquanto os demais recebem indicadores  $-1$ . Após obtidos tais hiperplanos, a classe de um padrão  $\mathbf{x}_i$  é determinada de acordo com a seguinte regra:

$$\mathbf{x}_i \text{ é associado a } \omega_j \Leftrightarrow j = \arg \max_{k=1, \dots, c} \{f_{SVM_k}(\mathbf{x}_i)\}. \quad (2.18)$$

Já na estratégia OAO, para o mesmo problema de classificação envolvendo  $c$  classes, o número de hiperplanos definidos é igual a combinação de  $c$  dois a dois. Neste caso, cada classificador é responsável pela separação dos padrões entre um determinado par de classes. Dessa maneira, um padrão pode ser classificado com relação a uma mesma classe diversas vezes. Neste caso, a classificação de um padrão baseia-se na quantidade de vezes que este padrão é associado a uma determinada classe.

Na Figura 2.6 é exemplificado o uso das estratégias OAA e OAO em um problema de classificação envolvendo 3 classes, cujos padrões são identificados por  $\blacklozenge$ ,  $\blacktriangle$  e  $\blacksquare$ . Padrões que pertencem à união entre classes são denotados por  $\star$  e o padrão a ser classificado por  $\square$ . A notação  $f_{\omega_i/\omega_j}$  define que o hiperplano  $f$  realiza a separação entre as classes  $\omega_i$  e  $\omega_j$ . Na estratégia OAA o padrão  $\square$  pertence à classe composta por elementos  $\blacklozenge$ , uma vez que a aplicação de  $f_{\blacklozenge/\{\blacktriangle, \blacksquare\}}$  sobre este padrão retorna o maior valor, comparado às demais funções. O valor retornado com a aplicação da função  $f_{\blacktriangle/\{\blacklozenge, \blacksquare\}}$  sobre  $\square$ , de acordo com  $\mathbf{w}$ , deve ser negativo. Na estratégia OAO o padrão  $\square$  é classificado novamente como sendo da classe  $\blacklozenge$ , pois, dentre os três casos binários analisados ( $f_{\blacklozenge/\blacktriangle}$ ,  $f_{\blacksquare/\blacktriangle}$  e  $f_{\blacklozenge/\blacksquare}$ ), ele é associado à classe  $\blacklozenge$  duas vezes, em  $f_{\blacklozenge/\blacktriangle}$  e  $f_{\blacklozenge/\blacksquare}$ .

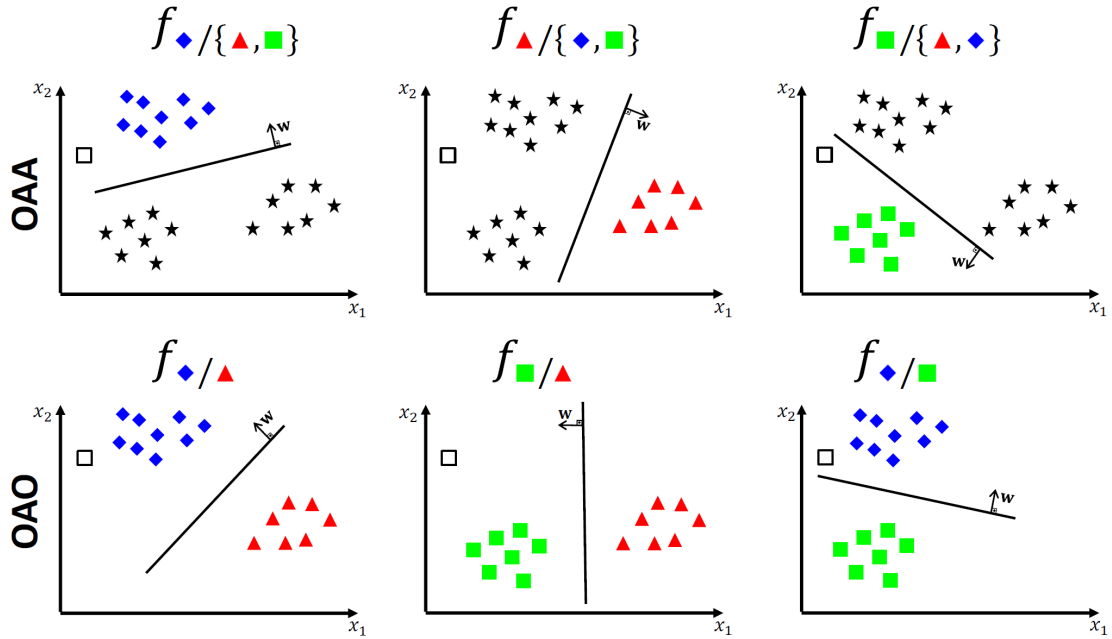


Figura 2.6 - Exemplo de aplicação das estratégias multiclasse OAA e OAO em um problema de separação envolvendo 3 classes.

## 2.3 Propostas contextuais de SVM

Nesta seção são abordados métodos de classificação contextual baseados em SVM. Uma revisão sobre as principais propostas apresentadas na literatura é realizada na Subseção 2.3.1. Na Subseção 2.3.2 discute-se os principais detalhes sobre a integração entre MRF e SVM, enquanto na Subseção 2.3.3 discute-se uma das mais simples formas de produzir classificações contextuais derivadas do método SVM, a partir do uso de técnicas de suavização.

### 2.3.1 Descrição geral sobre versões contextuais de SVM na literatura

A formulação original do SVM o caracteriza como um método de aprendizado supervisionado. Além disso, em grande parte dos estudos que empregam este método na classificação de imagens de Sensoriamento Remoto, a abordagem pontual é adotada (MOUNTRAKIS et al., 2011). No entanto, existem diferentes propostas que adaptam este método aos paradigmas de aprendizado não supervisionado e semissupervisionado (XU; SCHUURMANS, 2005; LI; TENG, 2006; HAMEL, 2006; BRUZZONE; PERSELLO, 2009; NEGRI et al., 2013), assim como à abordagem baseada em regiões (TZOTSOS, 2006; NEGRI et al., 2012).

A derivação do SVM em versões contextuais não é uma exceção. As propostas

encontradas na literatura a respeito de SVM contextuais geralmente tratam a integração em arquiteturas MRF ou através da alteração do processo de treinamento. Uma das propostas pioneiras, não só com relação à integração com MRF, mas também como versão contextual de SVM, é apresentada em Bovolo e Bruzzone (2005). Para isso, a regra de decisão do método SVM, originalmente baseada na relação de distância entre padrões ao hiperplano de separação, é transformada em distribuições de probabilidade, segundo o método proposto em Platt (2000). Posteriormente, as distribuições de probabilidade são inseridas nos algoritmos ICM (BESAG, 1986), *Simulated Annealing* (SA) (GEMAN; GEMAN, 1984) e *Maximization of the Posteriori Marginals* (MPM) (MARROQUIN et al., 1987).

Semelhante ao estudo apresentado em Bovolo e Bruzzone (2005), é verificado em Khodadadzadeh e Ghassemian (2011) que a aplicação de técnicas de relaxação probabilística sobre resultados do método SVM, após interpretados como distribuições de probabilidade segundo o método apresentado em Platt (2000), é uma outra forma de produzir classificações contextuais baseadas em SVM.

Em Li et al. (2011) é apresentado uma melhoria na integração com MRF dos resultados fornecidos pelo SVM. Tal melhoria está associada ao emprego do método apresentado em Lin et al. (2007), responsável pela interpretação de distribuições de probabilidade a partir dos resultados SVM, e pelo uso de um termo adicional que pondera tais distribuições de probabilidade em função da informação contextual dos pixels. O problema de classificação resultante da integração entre SVM e MRF é resolvido com uso do algoritmo SA.

A primeira versão contextual derivada de alterações na formulação original do método SVM, denominada *Context-Sensitive Support Vector Machine* (CS-SVM), é apresentada em Bovolo et al. (2006). Nesta proposta, a dependência do contexto é inserida a partir da adição de novos termos na função objetivo e na regra de decisão, definidas nas equações (2.2) e (2.8), respectivamente. Com isso, as informações dos atributos dos pixels contidos na vizinhança dos dados de treinamento são consideradas durante as fases de treinamento e de classificação.

Uma extensão de Bovolo et al. (2006), denominada *Context-Sensitive Semi-Supervised Support Vector Machine* é apresentada em Bruzzone e Persello (2009). Novamente, a partir de modificações sobre as equações (2.2) e (2.8), as informações a respeito da vizinhança são consideradas durante as fases de treinamento e de classificação. Além disso, tais modificações induzem a realização de um aprendizado semissupervisionado. Cabe mencionar que está proposta esta vinculada à estratégia

multiclasse OAA.

De maneira distinta das propostas supracitadas, em Li et al. (2012) são propostas duas versões contextuais baseadas em SVM. A primeira proposta, denominada Máquina de Vetores de Suporte Espaço-Contextual (*Spatial-Contextual Support Vector Machine* - SCSVM), insere uma modificação na função objetivo de (2.2) e utiliza as informações espectrais da vizinhança geográfica dos pixels de treinamento, como também os rótulos provenientes de uma classificação inicial pelo método SVM original. A partir das informações sobre a vizinhança dos pixels de treinamento é realizado um procedimento iterativo, até que o resultado de classificação alcance convergência. A segunda proposta, intitulada Máquina de Vetores de Suporte Espaço-Contextual no Espaço Característico (*Spatial-Contextual Support Vector Machine on Feature Space* - SCSVMF), é similar ao SCSVM, porém, é considerada a vizinhança dos pixels de treinamento no espaço de atributos.

Por fim, em Gurram e Kwon (2013), são induzidas classificações contextuais pelo método SVM a partir da composição de funções *kernel*. A função resultante da composição é capaz de incorporar a informação espacial e espectral dos pixels durante as fases de treinamento e classificação.

### 2.3.2 Considerações sobre MRF, o algoritmo ICM e a integração com SVM

*Maximum a posteriori* (MAP) é tido como um modelo geral de classificação estatística. Neste modelo, a classificação dos padrões é realizada a partir da probabilidade *a posteriori*  $P(\omega_j|\mathbf{x}_i)$ , designando o padrão  $\mathbf{x}_i$  à classe  $\omega_j$  que maximiza  $P(\omega_j|\mathbf{x}_i)$ , isto é:

$$\mathbf{x}_i \text{ é associado a } \omega_j \Leftrightarrow j = \arg \max_{k=1,\dots,c} \{P(\omega_k|\mathbf{x}_i)\}; \forall s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i. \quad (2.19)$$

No entanto, pelo Teorema de Bayes, a expressão (2.19) é reescrita por:

$$\mathbf{x}_i \text{ é associado a } \omega_j \Leftrightarrow j = \arg \max_{k=1,\dots,c} \left\{ \frac{P(\mathbf{x}_i|\omega_k)P(\omega_k)}{P(\mathbf{x}_i)} \right\}; \forall s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i, \quad (2.20)$$

onde,  $P(\mathbf{x}_i|\omega_k)$ , denominada *probabilidade classe-condicional*, representa a probabilidade do padrão  $\mathbf{x}_i$  estar associado à classe  $\omega_k$ , enquanto a *probabilidade a priori*  $P(\omega_k)$  especifica geralmente a proporção de padrões associados à classe  $\omega_k$ , e  $P(\mathbf{x}_i)$  representa a distribuição do padrão  $\mathbf{x}_i$ , independente da classe associada

a estes, tal que  $P(\mathbf{x}_i) = \sum_{k=1}^c P(\mathbf{x}_i|\omega_k)P(\omega_k)$ . Usualmente, admite-se que  $P(\mathbf{x}_i)$  é idêntica para qualquer  $\mathbf{x} \in \mathcal{X}$ .

Por definição, MRF consiste em um grafo  $\mathcal{G} = (\mathcal{A}, \mathcal{B})$ , onde  $\mathcal{A} = \{1, \dots, S\}$ , com  $S \in \mathbb{N}^*$ , representa o conjunto de vértices, tal que  $y_i$  é uma variável aleatória<sup>(6)</sup> associada ao vértice  $i$ , para  $i = 1, \dots, S$ , e  $\mathcal{B}$  é o conjunto de arestas deste grafo. Denotando a vizinhança do vértice  $i$  por  $\mathcal{V}(i)$ , o conjunto dos vértices adjacentes a  $i$ , tal que  $j \in \mathcal{V}(i)$  se e somente se  $(i, j)$  é uma aresta pertencente a  $\mathcal{B}$ , uma MRF satisfaz a seguinte propriedade:

$$P(y_i | \{y_j : j \in \mathcal{A} \setminus \{i\}\}) = P(y_i | \{y_j : j \in \mathcal{V}(i)\}). \quad (2.21)$$

A propriedade apresentada em (2.21) expressa que a probabilidade de  $y_i$ , condicionada pelas demais variáveis aleatórias associadas aos vértices de  $\mathcal{G}$ , equivale a probabilidade de  $y_i$ , condicionada apenas às variáveis aleatórias associadas aos vértices vizinhos. Cabe observar que nas aplicações em classificação de imagens, os vértices de  $\mathcal{G}$  representam pixels. A relação entre as definições de vizinhança, representadas aqui por  $\mathcal{V}$  e  $\mathcal{V}_\rho$ , na Seção 2.1, são similares, exceto que, o aumento do valor de  $\rho$  implica no aumento do número de vizinhos, o que por sua vez, exige o aumento das arestas em  $\mathcal{G}$  para garantir a definição de vizinhança. Analogamente, as arestas de  $\mathcal{G}$  devem ser redefinidas quando  $\rho$  diminui.

Admitindo que as classes dos padrões associados aos pixels de uma imagem sejam modeladas por uma MRF, as probabilidades  $P(\omega_k)$  podem ser expressas como uma distribuição de Gibbs cuja modelagem da função energia é dada pelo modelo de Potts (KHEDAM et al., 2002). Nestas condições, a expressão (2.20) é reescrita como:

$$\mathbf{x}_i \text{ é associado a } \omega_j \Leftrightarrow j = \arg \max_{k=1, \dots, c} \{U(\mathbf{x}_i|\omega_k)\}, \quad (2.22)$$

tal que:

$$U(\mathbf{x}_i|\omega_k) = P(\mathbf{x}_i|\omega_k) + \sum_{\eta \in W} \left( \beta \sum_{t \in \mathcal{V}(i)} (1 - \delta(y_i, y_t)) \right), \forall s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i, \quad (2.23)$$

onde,  $\beta$  é um parâmetro do modelo que pondera a influência da vizinhança e  $\eta$  é um clique<sup>(7)</sup> que contém  $i$ , pertencente ao conjunto de cliques  $W$  e  $\delta(\cdot, \cdot)$  representa

<sup>(6)</sup>Embora tenha sido definido inicialmente como um indicador de classe de  $\mathbf{x}_i$ ,  $y_i$  será considerado como uma variável aleatória a respeito das classes de  $\mathbf{x}_i$ .

<sup>(7)</sup>Uma clique em um grafo não-orientado  $\mathcal{G} = (\mathcal{A}, \mathcal{B})$  é um conjunto de vértices  $\bar{\mathcal{A}} \subseteq \mathcal{A}$  tal que



a função Delta de Kronecker<sup>(8)</sup>.

Uma vez que (2.22) consiste em um problema de maximização, o mesmo pode ser resolvido por um algoritmo de otimização. O ICM é um exemplo de método para solução deste problema, que consiste em encontrar o máximo local, ao invés do global. Com isso, a expressão (2.23), reestruturada para o caso do ICM, em:

$$U_{ICM}(\mathbf{x}_i|\omega_k) = P(\mathbf{x}_i|\omega_k) + \beta \sum_{t \in \mathcal{V}(i)} (1 - \delta(y_i, y_t)), \quad \forall s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i. \quad (2.24)$$

O processo de otimização é conduzido iterativamente enquanto o algoritmo não alcança sua convergência. Um *número máximo de iterações* ou um *porcentual mínimo de mudança* na classificação entre iterações consecutivas são algumas sugestões de critério de convergência.

Observa-se que o primeiro termo da função de otimização (2.24) corresponde a uma classificação inicial, sobre a qual será conduzido o processo de classificação contextual. O segundo termo corresponde às interações locais na vizinhança espacial dos pixels.

Existem diferentes propostas para definição do valor de  $\beta$ . O *estimador de máxima pseudoverossimilhança para o modelo de Potts-Strauss* é uma forma de realizar a estimação deste parâmetro. Detalhes sobre este estimador podem ser encontrados em [Vieira \(1996\)](#).

Para que classificações fornecidas pelo método SVM sejam contextualizadas em uma arquitetura MRF pelo algoritmo ICM, a função (2.1) deve ser reinterpretada como uma distribuição classe-condicional. Dentre diferentes métodos existentes na literatura, são citados [Platt \(2000\)](#) e [Lin et al. \(2007\)](#). Em particular, o método proposto em [Lin et al. \(2007\)](#) consiste em uma melhoria de [Platt \(2000\)](#).

De acordo com [Lin et al. \(2007\)](#), a transformação da função (2.1) na distribuição classe-condicional de  $\omega_j$  é dada por:

$$P(\mathbf{x}_i|\omega_k) = \frac{1}{1 + e^{\Theta_1 f_{SVM_k}(\mathbf{x}_i) + \Theta_2}}, \quad (2.25)$$

onde  $\Theta_1$  e  $\Theta_2$  são parâmetros e  $f_{SVM_k}(\mathbf{x}) = 0$  representa um hiperplano que separa

---

para todo  $i, j \in \bar{\mathcal{A}}$ , existe uma aresta entre  $i$  e  $j$ .

<sup>(8)</sup> $\delta(i, j) = \begin{cases} 1, & \text{se } i = j \\ 0, & \text{se } i \neq j \end{cases}$ .

padrões da classe  $\omega_k$  de padrões de outras classes. Neste método, a estimação da distribuição classe-condicional em problemas multiclasse está vinculada à estratégia OAA.

Os parâmetros  $\Theta_1$  e  $\Theta_2$  presentes em (2.25) são estimados com a otimização de (LIN et al., 2007):

$$\min_{\Theta_1, \Theta_2} \left\{ \pi_i (\Theta_1 f_{SVM_k}(\mathbf{x}_i) + \Theta_2) + \log(1 + e^{-\Theta_1 f_{SVM_k}(\mathbf{x}_i) - \Theta_2}) \right\}; \quad i = 1, \dots, m, \quad (2.26)$$

$$k = 1, \dots, c, \mathbf{x}_i \in \mathcal{D}$$

sendo  $\pi_i = \begin{cases} \frac{N_+ + 1}{N_+ + 2} & \text{se } y_i = +1 \\ \frac{1}{N_- + 2} & \text{se } y_i = -1 \end{cases}$ , onde  $N_+$  e  $N_-$  representam a quantidade de exemplos observados com indicadores de classe iguais a  $+1$  e  $-1$ , respectivamente. Um pseudocódigo com um método para otimização de (2.26) é apresentado em Lin et al. (2007).

### 2.3.3 Técnicas de suavização e classificação contextual baseada em SVM

Como já mencionado, o uso de técnicas de suavização é uma forma de produzir classificações contextuais baseadas em SVM. Estas técnicas incluem a aplicação de filtros sobre os rótulos da imagem classificada e/ou a incorporação de bandas adicionais, tais como medidas de textura, antes do processo de classificação pontual.

Aplicação do Filtro da Moda sobre um dado resultado de classificação pontual é uma forma de suavização comumente adotada (STALLINGS et al., 1999). Este processo consiste em contabilizar a frequência com que os pixels de uma dada vizinhança  $\mathcal{V}_\rho(s)$  são classificados segundo as classes de  $\Omega$ , para cada  $s \in \mathcal{S}$ . A classe com maior frequência associada determina a classificação contextual do pixel  $s$ . Na ocorrência de possíveis empates, a escolha aleatória entre as classes de mesma frequência pode ser adotada.

Cabe notar que o raio de influência da vizinhança  $\rho$  é um parâmetro neste processo de classificação contextual. O aumento do valor de  $\rho$  implica na produção de classificações contextuais mais homogêneas, isto é, baixa concentração do efeito “sal e pimenta”. A homogeneização dos resultados de classificação é uma das principais características deste processo de classificação contextual. Outra característica relevante é o baixo custo computacional exigido.

### 3 SVM ADAPTATIVA AO CONTEXTO

Neste capítulo é introduzida uma nova versão do método SVM para classificação contextual de imagens baseada em pixel, a qual está fundamentada nas seguintes premissas:

- *Disponibilidade do contexto*: para qualquer posição de uma dada imagem, a informação completa do contexto (atributos e classes) existe e é conhecida.
- *Deslocamento local*: a influência do contexto se materializará em deslocamentos do hiperplano de separação obtido originalmente pelo método SVM.
- *Influência do contexto*: a influência exercida pelos elementos de um dado contexto deverá ser diretamente proporcional ao nível de confiança que estes elementos possuem, segundo uma classificação inicial definida pelo método SVM.

O método proposto parte da premissa da *disponibilidade do contexto*, supondo que para cada posição de uma dada imagem, em uma dada vizinhança, são conhecidas as informações a respeito dos pixels e das respectivas classificações. Uma vez que é incomum o conhecimento *a priori* a respeito da classificação dos pixels, as mesmas são estimadas pelo método SVM tradicional, isto é, o método SVM atua como um oráculo na definição das classes iniciais dos pixels. Já a premissa do *deslocamento local* determina que o processo de classificação contextual dos pixels deverá ser realizado por deslocamentos no hiperplano de separação obtido inicialmente pelo método SVM, responsável pela estimação da classificação inicial dos pixels. Os deslocamentos proporcionados sobre o hiperplano inicial ocorrem em função da confiabilidade da classificação inicial dos elementos que compreendem o contexto, como estipula a premissa da *influência do contexto*. O hiperplano “deslocado” é utilizado apenas na classificação do pixel observado.

Na Figura 3.1 sintetiza-se as etapas que constituem o método de classificação contextual proposto. Nesta representação,  $F_{SVM}(\mathcal{I})$  é a classificação da imagem  $\mathcal{I}$  pela regra de decisão  $F_{SVM}(\mathbf{x})$  determinada pelo método SVM. Considerando  $s$  um pixel de  $\mathcal{I}$  tal que  $\mathcal{I}(s) = \mathbf{x}_i$ , define-se o contexto de  $s$  pelo conjunto  $\mathcal{D}_s = \{(\mathbf{x}_k, y_k) \in \mathcal{X} \times \mathcal{Y} : t \in \mathcal{V}_\rho(s); \mathcal{I}(t) = \mathbf{x}_k\}$ , formado pelos pares de informação sobre os atributos e as classes, atribuídas por  $F_{SVM}(\mathbf{x})$ , a respeito dos pixels localizados na vizinhança de  $s$ . A partir de  $\mathcal{D}_s$  é definido um novo hiperplano

$f_{Local}(\mathbf{x})$ , baseado nas formulações apresentadas na Seção 2.2. O hiperplano determinado é usado em seguida na definição da regra de decisão  $F_{Local}(\mathbf{x})$ , a qual é aplicada em  $\mathbf{x}_i$  para classificação de  $s$  de forma contextual. Cabe mencionar que é possível determinar  $f_{Local}(\mathbf{x})$  desde que  $\mathcal{D}_s$  possua ao menos um elemento cuja classe é diferente dos demais, caso contrário, quando  $s$  e todos vizinhos possuem mesma classe, admite-se que a classe de  $s$  é correta. Diante da característica de redefinir hiperplanos de separação localmente, em função do comportamento da vizinhança, o método proposto é denominado por Máquina de Vetores de Suporte Adaptativa ao Contexto (*Contextual Adaptive Support Vector Machine - CaSVM*).

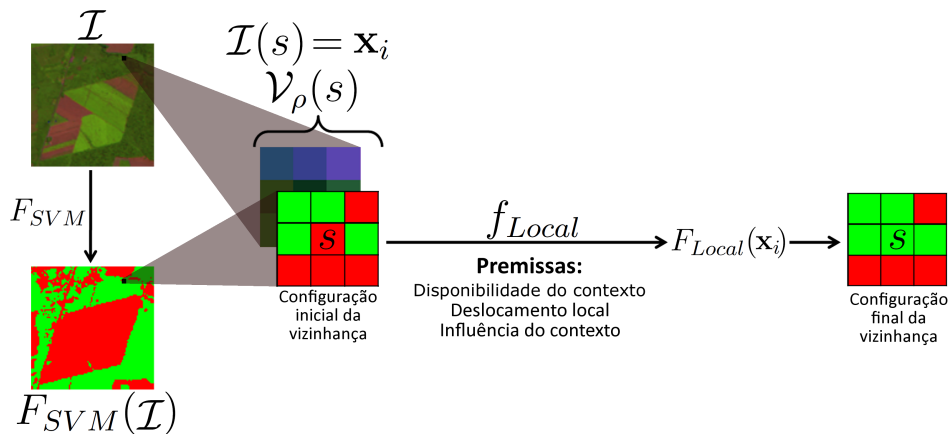


Figura 3.1 - Etapas do método de classificação contextual proposto.

Segundo a premissa do *deslocamento local*, a influência do contexto é transformada em deslocamentos no hiperplano de separação originalmente fornecido pelo SVM, e tais deslocamentos, de acordo com a premissa da *influência do contexto*, estão relacionados de forma diretamente proporcional à confiabilidade dos padrões presentes na vizinhança. No entanto, ao recapitular a discussão realizada na Subseção 2.2.3, a respeito da *confiabilidade* dos vetores que definem o hiperplano de separação, verifica-se que ao empregar os padrões da vizinhança na determinação de um novo hiperplano local, tal hiperplano será influenciado pelos padrões de mais baixa confiabilidade, contrariando assim a premissa da *influência do contexto*. Este fato introduz o conceito de *reprojeção*, que consiste em inverter, com relação aos limites da margem de separação do hiperplano  $f_{SVM}(\mathbf{x}) = 0$  (i.e.,  $|f_{SVM}(\mathbf{x})| = 1$ ), a posição dos pixels no espaço de atributos. Com isso, os pixels classificados inicialmente com alta confiabilidade são reposicionados (*reprojetados*) para posições do espaço de atributos localizadas próximas ao hiperplano  $f_{SVM}(\mathbf{x}) = 0$ . De forma análoga, os pixels classificados com baixa confiabilidade, inicialmente localizados

próximos a  $f_{SVM}(\mathbf{x}) = 0$ , são reprojitados para posições mais distantes deste hiperplano. Esta nova configuração dos padrões no espaço de atributos fará com que padrões de mais alta confiabilidade influenciem na definição do hiperplano, ao contrário dos de mais baixa confiabilidade. A reprojeção é realizada pela seguinte função:

$$h(\mathbf{x}_i) = \mathbf{x}_i + \frac{\alpha(\mathbf{x}_i)}{\|\mathbf{w}\|} \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} \cdot \text{sgn}(f_{SVM}(\mathbf{x}_i)), \quad \forall s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i, \quad (3.1)$$


onde,  $\alpha(\mathbf{x}_i) = \frac{1}{|f_{SVM}(\mathbf{x}_i)|} - |f_{SVM}(\mathbf{x}_i)|$  é denominado *fator de reprojeção*. Em (3.1) o membro  $\frac{\alpha(\mathbf{x}_i)}{\|\mathbf{w}\|}$  representa a quantidade, em termos de  $\mathbf{w}$ , do deslocamento de  $\mathbf{x}_i$  no espaço de atributos,  $\frac{\mathbf{w}}{\|\mathbf{w}\|}$  é o vetor unitário do deslocamento realizado e  $\text{sgn}(f_{SVM}(\mathbf{x}_i))$  é necessária para generalizar a operação de reprojeção, independente de  $f_{SVM}(\mathbf{x}_i)$  ser um valor positivo ou negativo.

Nota-se na função (3.1) que, para padrões  $\mathbf{x}_i$  localizados no limite da margem de separação (i.e.,  $|f_{SVM}(\mathbf{x})| = 1$ ), não ocorre reprojeção, uma vez que  $\alpha(\mathbf{x}_i) = 0$ . Com  $f_{SVM}(\mathbf{x}_i)$  próximo de zero, a confiabilidade da classificação inicial de  $\mathbf{x}_i$  é baixa, e logo,  $\mathbf{x}_i$  é reprojitado para distante do hiperplano  $f_{SVM}(\mathbf{x}) = 0$ . Um comportamento inverso acontece quando  $|f_{SVM}(\mathbf{x}_i)|$  assume valores maiores que 1. Cabe observar ainda que o processo de reprojeção não leva em consideração se o padrão foi classificado corretamente, ou não, por  $f_{SVM}(\mathbf{x})$ .

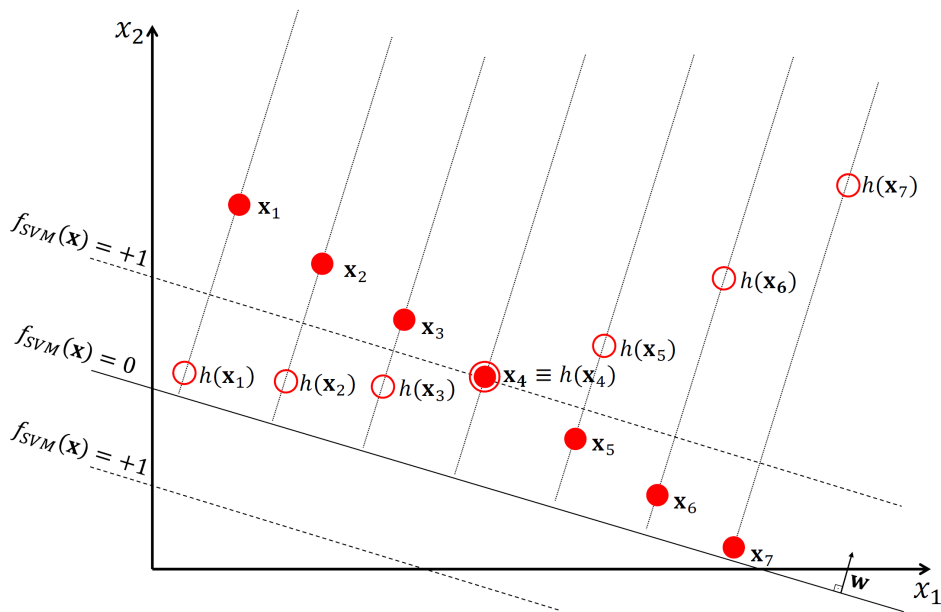
Na Figura 3.2(a) são ilustrados casos de *reprojeção* de padrões classificados com diferentes *confiabilidades*. O padrão  $\mathbf{x}_1$ , classificado inicialmente com alta confiabilidade, é reprojitado para próximo do hiperplano  $f_{SVM}(\mathbf{x}) = 0$ , ao contrário de  $\mathbf{x}_2$ , que sendo de baixa confiabilidade, é afastado deste hiperplano. A aplicação de  $h(\cdot)$  sobre  $\mathbf{x}_3$  não provoca reprojeção já que  $\alpha(\mathbf{x}_3)$  é nula.

Na Figura 3.2(b) é ilustrado o efeito do fator de reprojeção, definido pela função  $\alpha(\mathbf{x})$ , sobre os padrões com diferentes confiabilidades. Os padrões reprojitados são representados por círculos vazios. É possível observar que a reprojeção para próximo, ou distante, de  $f_{SVM}(\mathbf{x}) = 0$  é feita de forma não linear. Embora seja ilustrado o efeito da reprojeção apenas sobre os padrões  $\mathbf{x}_i$  com  $f_{SVM}(\mathbf{x}_i) \geq 0$ , tal comportamento é simétrico para os padrões com  $f_{SVM}(\mathbf{x}_i) < 0$ , devido a presença do fator  $\text{sgn}(f_{SVM}(\mathbf{x}_i))$  em (3.1).

A aplicação de  $h(\cdot)$  sobre a primeira coordenada dos elementos de  $\mathcal{D}_s$  resulta em um novo conjunto, denotado por  $\mathcal{H}_s$ . Para distinção de notação entre os elementos de  $\mathcal{D}_s$  e  $\mathcal{H}_s$ , denota-se  $h(\mathbf{x}_i) = \mathbf{x}'_i$ . Com base nas informações de  $\mathcal{H}_s$ , é possível definir



(a) Casos gerais de reprojeção



(b) Efeitos do fator de reprojeção  $\alpha(\mathbf{x})$

Figura 3.2 - Reprojeção dos padrões com diferentes níveis de confiança.

um hiperplano local, construído apenas com a informação do contexto de  $s$ .

Como mencionado anteriormente, o hiperplano de separação é definido sob forte influência do posicionamento do vetor de atributos dos pixels no espaço de atributos, enquanto a quantidade de pixels pode não ser um fator determinante. No entanto, a premissa da *influência do contexto* específica que as confiabilidades dos elementos

da vizinhança devem influenciar na determinação do hiperplano local. Sendo assim, para que tal premissa seja verificada são utilizados *submodelos de contextualização*. Estes submodelos são responsáveis por quantificar a confiabilidade dos elementos da vizinhança e refletir esse comportamento na definição de um hiperplano de separação local, empregado na classificação do pixel do qual o contexto é observado. Neste trabalho são propostos dois submodelos de contextualização, denominados por *Repulsivo* e *Translativo*, os quais são definidos nas Seções 3.1 e 3.2, respectivamente. A denominação “submodelo” é adotada uma vez que este é parte de um “modelo” mais genérico, o CaSVM.

### 3.1 O submodelo Repulsivo

O submodelo *Repulsivo* é inspirado no fenômeno da repulsão magnética. Ele consiste em utilizar a distância dos padrões reprojatados, com relação ao limite da margem ( $|f_{SVM}(\mathbf{x})| = 1$ ) da respectiva classe, desde que o mesmo encontre-se dentro desta margem, como quantidade de força aplicada na repulsão dos padrões reprojatados da outra classe, e *vice-versa*. Tal submodelo é formalizado por:

$$r(\mathbf{x}'_i) = \mathbf{x}'_i + \lambda \cdot \frac{\mathbf{w}}{\|\mathbf{w}\|} \cdot \frac{G_u(s)}{E_v(s)} \cdot \frac{1}{\|\mathbf{w}\|} \cdot \text{sgn}(f_{SVM}(\mathbf{x}'_i)); \forall t \in \mathcal{V}_\rho(s) : \mathcal{I}(t) = \mathbf{x}_i \quad (3.2)$$

sendo:

$$\begin{cases} u = n; v = p \text{ se } f_{SVM}(\mathbf{x}'_i) \geq 0 \\ u = p; v = n \text{ se } f_{SVM}(\mathbf{x}'_i) < 0, \end{cases} \quad (3.3)$$

$$E_v(s) = \max \{1, \#T_v(s)\}, \quad (3.4)$$

$$G_u(s) = \sum_{\forall \mathbf{x}'_i \in T_u(s)} (1 - |f_{SVM}(\mathbf{x}'_i)|), \quad (3.5)$$

$$T_p(s) = \{\mathbf{x}'_j : (\mathbf{x}'_j, y_j) \in \mathcal{H}_s; 0 \leq f_{SVM}(\mathbf{x}'_j) \leq 1\}, \quad (3.6)$$

$$T_n(s) = \{\mathbf{x}'_j : (\mathbf{x}'_j, y_j) \in \mathcal{H}_s; -1 \leq f_{SVM}(\mathbf{x}'_j) < 0\}, \quad (3.7)$$

onde  $\lambda \in \mathbb{R}_+$  é um parâmetro que pondera a influência do contexto na definição do hiperplano de separação local e  $\#$  é o operador de “cardinalidade”.

Os conjuntos  $T_p(s)$  e  $T_n(s)$ , definidos em (3.6) e (3.7) respectivamente, contém os elementos da vizinhança de  $s$  dentre aqueles localizados sobre a margem, nos lados “positivo” do hiperplano (i.e.,  $f_{SVM}(\mathbf{x}) \geq 0$ ) e “negativo” (i.e.,  $f_{SVM}(\mathbf{x}) < 0$ ), nesta ordem. Nota-se que os índices  $p$  e  $n$  fazem alusão a posição “positiva” ou “negativa” dos padrões com relação a  $f_{SVM}(\mathbf{x}) = 0$ .

As funções  $G_p(s)$  e  $G_n(s)$  quantificam a “força de repulsão” dos elementos dos conjuntos  $T_p(s)$  e  $T_n(s)$ , respectivamente. Como já mencionado, a força de repulsão é quantificada de acordo com a distância entre o padrão reprojeto e o limite da margem da respectiva classe, definida pelo hiperplano  $f_{SVM}(\mathbf{x}) = 0$ . Ainda, o padrão reprojeto deve estar localizado no interior desta margem, caso contrário, sua força de repulsão será nula. Já as funções  $E_p(s)$  e  $E_n(s)$  contabilizam os elementos de  $T_p(s)$  e  $T_n(s)$ , respectivamente, e admitem no mínimo valor 1.

O fator  $\frac{G_u(s)}{E_v(s)}$ , presente em (3.2), determina que a repulsão exercida sobre o padrão reprojeto  $\mathbf{x}'_i$ . Tal repulsão exercida depende da força de repulsão dos padrões reprojetos que pertencem a classe oposta, que é parcialmente reprimida, ou moderada, pela quantidade de padrões reprojetos contidos em  $T_v(s)$ . Nota-se pela definição de (3.2) que a repulsão é realizada sobre os padrões associados aos pixels de uma dada vizinhança  $\mathcal{V}_\rho(s)$ .


Com a aplicação de  $r(\cdot)$  sobre a primeira coordenada dos elementos de  $\mathcal{H}_s$  é produzido o conjunto  $\mathcal{R}_s$ . Novamente, para distinção entre os elementos de  $\mathcal{H}_s$  e  $\mathcal{R}_s$ , denota-se  $r(\mathbf{x}'_i) = \mathbf{x}''_i$ . Baseado nas informações de  $\mathcal{R}_s$  é definido o hiperplano local  $f_{Local}(\mathbf{x}) = 0$ , que modela o contexto de  $s$ . Fazendo  $\lambda = 0$ , o submodelo Repulsivo é desativado, tornando  $\mathcal{H}_s \equiv \mathcal{R}_s$ .

Os diferentes processos que contemplam o ajuste do hiperplano  $f_{Local}(\mathbf{x}) = 0$  em função do contexto local são exemplificados na Figura 3.3. Neste exemplo é admitido, por simplicidade,  $\lambda = 1$ . Na Figura 3.3(a) é representado o processo de reprojeção realizado sobre todos os vetores de atributos dos elementos da vizinhança de um dado pixel, destacado pelo símbolo  $\star$ . A posição inicial dos vetores de atributos destes pixels, no espaço de atributos, é obtida da imagem, enquanto os rótulos (vermelho para  $y_i = +1$  e verde para  $y_i = -1$ ) são provenientes de uma classificação inicial derivada do hiperplano  $f_{SVM}(\mathbf{x}) = 0$ , definido pelo método SVM.

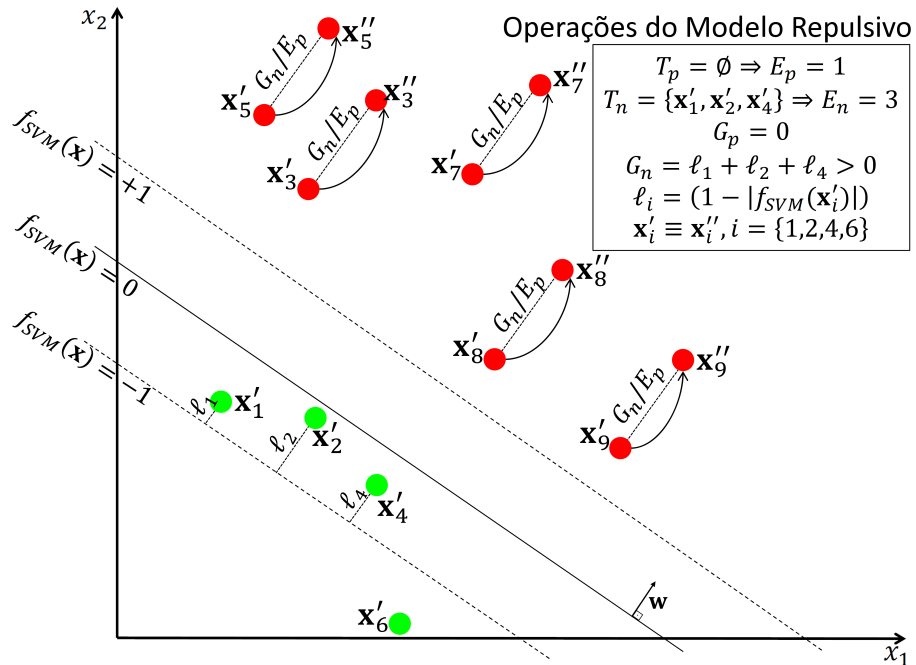
Após a reprojeção é feita a aplicação do submodelo Repulsivo, como ilustrado na Figura 3.3(b). Verifica-se que, na vizinhança observada, apenas os pixels associados ao rótulo  $-1$ , com exceção de  $\mathbf{x}_6$ , são classificados inicialmente com alta confiabilidade. Tais pixels devem influenciar a reclassificação de  $\star$ . Nota-se também que nesta vizinhança os pixels associados ao rótulo  $+1$  são classificados com baixa confiabilidade, proporcionando  $G_p = 0$ . Este comportamento impede que os pixels com rótulo  $+1$  exerçam “repulsão” aos de rótulo  $-1$ . Na Figura 3.3(c) é ilustrado o hiperplano  $f_{Local}(\mathbf{x}) = 0$ , construído por pixels, reprojeto e “repelidos”, que compõem o contexto de  $\star$ . Considerando a regra de classificação



local  $F_{Local} : \mathcal{X} \rightarrow \mathcal{Y}$  tal que  $F_{Local}(\mathbf{x}) = \text{sgn}(f_{Local}(\mathbf{x}))$ , a classificação inicial de  $\star$  é alterada, como ilustra a Figura 3.3(d).




(a) Configuração inicial e reprojeção dos padrões vizinhos de  $\star$  em função de  $f_{SVM}(\mathbf{x}) = 0$



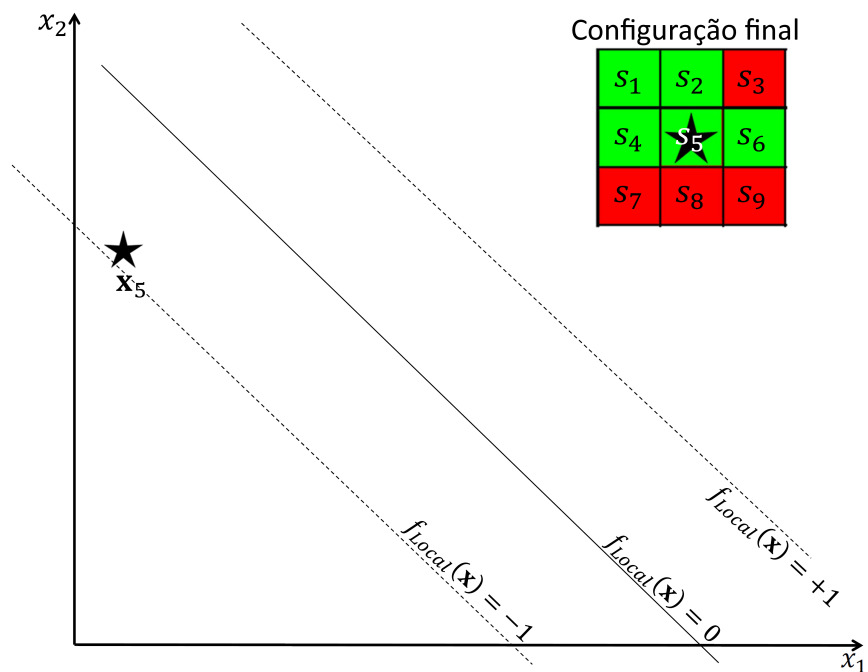
(b) Efeitos do submodelo Repulsivo

(continua...)

(...continuação)



(c) Construção do hiperplano local em função do contexto de ★



(d) Classificação de ★ segundo  $f_{Local}(\mathbf{x})$ .

Figura 3.3 - Etapas de ajuste do hiperplano local  $f_{Local}(\mathbf{x}) = 0$ , segundo o submodelo Repulsivo, com relação ao padrão ★.

### 3.2 O submodelo Translativo

O submodelo *Translativo* transforma a distância dos padrões de  $\mathcal{H}_s$ , com relação ao limite da margem ( $|f_{SVM}(\mathbf{x})| = 1$ ) da respectiva classe, desde que o mesmo encontre-se dentro desta margem, em uma translação do hiperplano  $f_{SVM}(\mathbf{x}) = 0$  a partir adição do termo  $\Delta(\mathbf{x}_i)$  em (2.1). Este escalar é obtido por:

$$\Delta(\mathbf{x}_i) = \lambda \cdot \frac{G_n(s) - G_p(s)}{\|\mathbf{w}\|}; \mathcal{I}(s) = \mathbf{x}_i \quad (3.8)$$

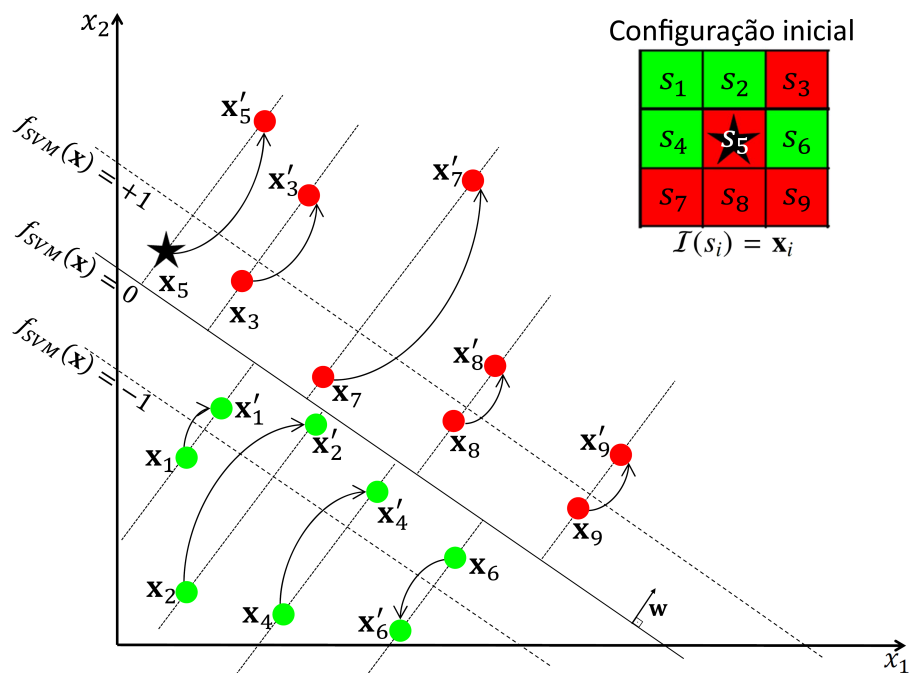
onde  $G_p(s)$  e  $G_n(s)$ , definidos em (3.5), são determinados a partir das informações de  $\mathcal{H}_s$ . Com finalidade análoga à apresentada na função (3.2),  $\lambda \in \mathbb{R}_+$  é um parâmetro inserido para ponderar a influência do contexto na definição do hiperplano de separação local.

Com a adição de  $\Delta(\mathbf{x}_i)$  em (2.1) obtém-se:

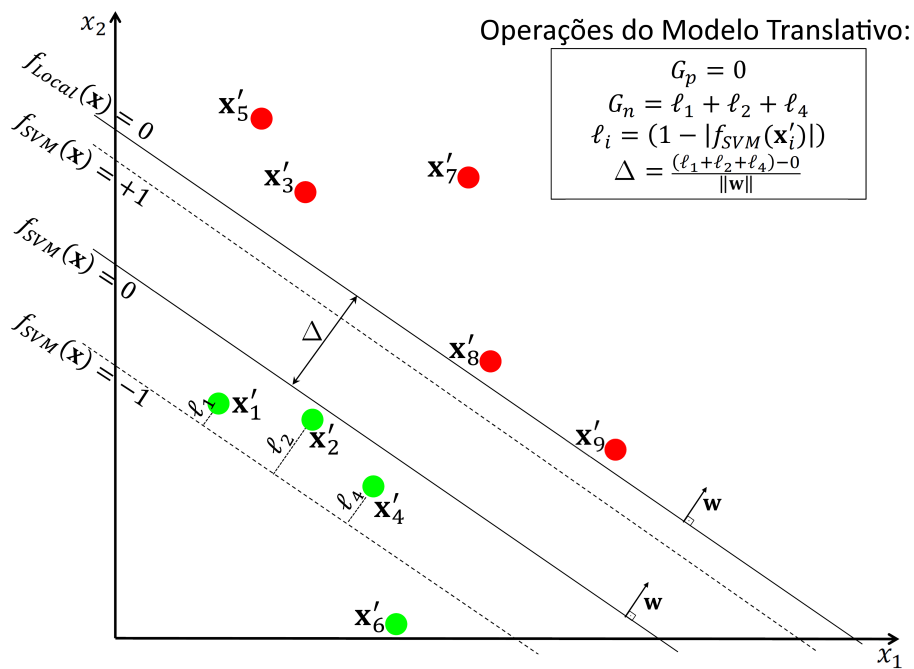
$$f_{Local}(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b + \Delta(\mathbf{x}_i). \quad (3.9)$$

A partir de  $f_{Local}(\mathbf{x})$  é definida a regra de classificação local  $F_{Local} : \mathcal{X} \rightarrow \mathcal{Y}$ , tal que  $F_{Local}(\mathbf{x}) = \text{sgn}(f_{Local}(\mathbf{x}))$ , a qual é aplicada somente na classificação de  $\mathbf{x}_i$ . Assim como no submodelo Repulsivo, quando  $\lambda = 0$  o submodelo Translativo é desativado, e neste caso,  $f_{Local}(\mathbf{x})$  torna-se equivalente a  $f_{SVM}(\mathbf{x})$ .

Na Figura 3.4 é ilustrado o efeito deste submodelo, sobre o mesmo exemplo apresentado na Figura 3.3, que consiste na classificação contextual do padrão  $\star$ . Novamente, por simplicidade, será adotado  $\lambda = 1$ . Após o processo de reprojeção dos padrões, mostrado na Figura 3.4(a), é computado o escalar de deslocamento  $\Delta$ , como apresenta a Figura 3.4(b). A partir da adição deste escalar em (2.1) obtém-se  $f_{Local}(\mathbf{x})$ , que aplicada sobre  $\star$  provoca a mudança de classe, ilustra a Figura 3.4(c).



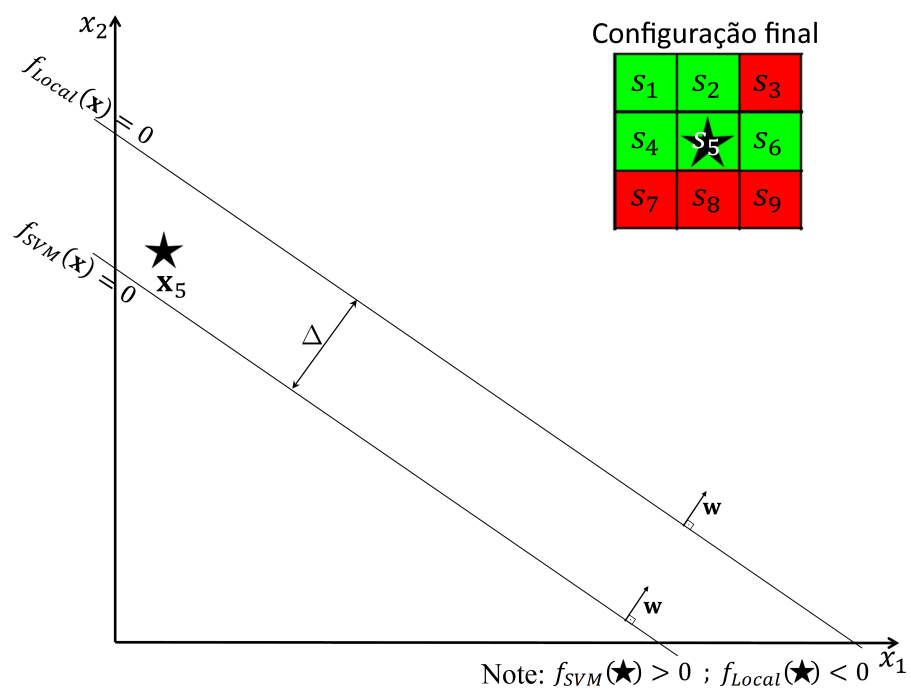
(a) Configuração inicial e reprojeção dos padrões vizinhos de  $\star$  em função de  $f_{SVM}(\mathbf{x}) = 0$ .



(b) Translação do hiperplano original, em função do contexto de  $\star$ .

(continua...)

(...continuação)



(c) Classificação de  $\star$  segundo  $f_{Local}(\mathbf{x})$ .

Figura 3.4 - Etapas de ajuste do hiperplano local  $f_{Local}(\mathbf{x}) = 0$ , segundo o submodelo Translativo, com relação ao padrão  $\star$ .

### 3.3 Etapas da classificação binária

Neste capítulo foi introduzido formalmente o método CaSVM. Nas Seções 3.1 e 3.2 foram apresentados dois submodelos de contextualização, denominados Repulsivo e Translativo. Os submodelos de contextualização são introduzidos para que a premissa da *influência do contexto* seja verificada. Nas Figuras 3.3 e 3.4 foram ilustrados exemplos hipotéticos em que o método CaSVM, associado aos submodelos Repulsivo e Translativo, respectivamente, realiza a classificação contextual de um pixel em função de sua vizinhança espacial. O uso desta formalização para classificação contextual de uma imagem consiste em ajustar hiperplanos locais para cada um de seus pixels, em função dos respectivos contextos.

Considerando o submodelo Repulsivo, para todo  $s \in \mathcal{S}$  tal que  $\mathcal{I}(s) = \mathbf{x}_i$ , é definido o conjunto  $\mathcal{R}_s$  a partir de  $\mathcal{I}$  e  $F_{SVM}(\mathbf{x})$  com relação aos elementos da vizinhança de  $\mathbf{x}_i$ . Este conjunto é determinado pela aplicação das expressões (3.1) e (3.2) nos conjuntos  $\mathcal{D}_s$  e  $\mathcal{H}_s$ , respectivamente. As informações de  $\mathcal{R}_s$  são utilizadas na estimação da regra de decisão  $F_{Local}(\mathbf{x})$ , de acordo com as formalizações apresentadas na Seção 2.2. Determinando  $\mathcal{C}(s) = F_{Local}(\mathbf{x}_i)$ , após a contextualização dos pixels de  $\mathcal{I}$ , em cada posição de  $\mathcal{S}$ , obtém-se em  $\mathcal{C}$  o resultado da classificação contextual.

Ao considerar o submodelo Translativo, a etapa de definição do conjunto  $\mathcal{R}_s$  não ocorre, assim como não são utilizados os conceitos abordados na Seção 2.2 para definir a regra de decisão  $F_{Local}(\mathbf{x})$ . Neste submodelo, para todo  $s \in \mathcal{S}$  tal que  $\mathcal{I}(s) = \mathbf{x}_i$ , são definidos os conjuntos  $\mathcal{D}_s$  e  $\mathcal{H}_s$ . O comportamento apresentado em  $\mathcal{H}_s$  é utilizado no cálculo do escalar  $\Delta \in \mathbb{R}$ , que adicionado a  $f_{SVM}(\mathbf{x})$ , proporciona  $F_{Local}(\mathbf{x})$ .

Os procedimentos descritos a respeito do processo de classificação contextual a partir do método CaSVM, segundo os submodelos Repulsivo e Translativo, são esquematizados no diagrama da Figura 3.5. Nesta representação é possível observar que enquanto submodelo Repulsivo exige a definição do conjunto  $\mathcal{R}_s$ , o submodelo Translativo necessita apenas determinar o escalar  $\Delta$  a partir de  $\mathcal{H}_s$ .

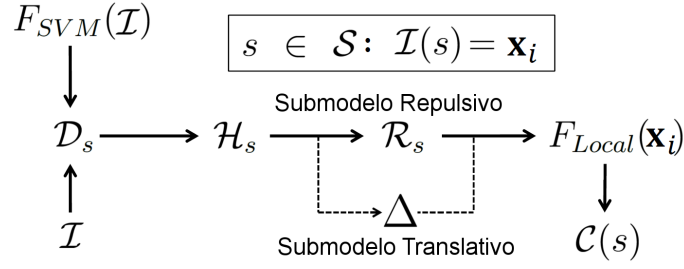


Figura 3.5 - Etapas da classificação contextual de um problema binário, segundo o método CaSVM e os submodelos Repulsivo e Translativo.

### 3.4 Problemas multiclasse

A estrutura discutida na Seção 3.3 formaliza os casos de contextualização de problemas de classificação binária. A extensão do método CaSVM aos problemas multiclasse está vinculada ao uso de estratégias multiclasse que decompõem o problema original em subproblemas binários. Após tal decomposição, cada subproblema binário é tratado individualmente segundo as etapas apresentadas na Seção 3.3. Com a contextualização de cada problema binário, os respectivos resultados são analisados de acordo com a regra de classificação multiclasse, proveniente da estratégia adotada inicialmente, para que então seja obtida a classificação contextual multiclasse.

Esta arquitetura torna o método de classificação contextual proposto independente da estratégia multiclasse adotada, ao contrário, por exemplo, do método proposto em Bruzzone e Persello (2009). Uma restrição imposta ao método proposto é que a estratégia multiclasse deve ser baseada na decomposição em subproblemas binários, como por exemplo, as estratégias OAA e OAO.

### 3.5 Estimação do parâmetro $\lambda$

Como já mencionado, o parâmetro  $\lambda$  definido nos submodelos Repulsivo (Seção 3.1) e Translativo (Seção 3.2) é responsável por ponderar a influência do contexto no processo de classificação pelo método CaSVM. A escolha deste parâmetro implica diretamente na acurácia dos resultados de classificação. Sendo assim, torna-se conveniente a definição de procedimentos capazes de estimar, para um dado problema de classificação, o valor de  $\lambda$  adequado para proporcionar bons resultados.

É conveniente realizar a estimação deste parâmetro com base no comportamento dos padrões do conjunto de treinamento; uma vez que são conhecidas as classes

destes padrões, torna-se possível verificar valores de  $\lambda$  que proporcionam os melhores percentuais de acurácia na classificação contextual dos mesmos. Cabe ressaltar que, para realizar a classificação contextual de tais padrões, são consideradas as informações dos respectivos contextos, segundo o raio de influência da vizinhança adotado.

A partir de testes empíricos realizados, foi verificada uma tendência característica entre o valor associado ao parâmetro  $\lambda$  e o percentual de acurácia, denotado por  $A(\lambda)$ , na classificação dos padrões do conjunto de treinamento. Esta tendência característica é ilustrada no gráfico da Figura 3.6. É possível observar neste gráfico a existência de um intervalo inicial de valores que, quando associados a  $\lambda$ , proporcionam aumento na acurácia. Uma convergência do percentual de acurácia é alcançada quando  $\lambda$  assume valores acima do limite superior do intervalo inicial mencionado, denotado por  $\hat{\lambda}$ .




Figura 3.6 - Tendência característica observada em experimentos empíricos que relaciona os valores associados a  $\lambda$  e o respectivo percentual de acurácia proporcionado.

Embora valores acima de  $\hat{\lambda}$  proporcionem um mesmo percentual de acurácia, cabe observar que esta medida é baseada apenas na acurácia sobre os padrões do conjunto de treinamento, enquanto a acurácia do resultado de classificação é ainda desconhecida. Sendo assim, de forma razoável e conservadora,  $\hat{\lambda}$  é adotada como uma boa estimativa para  $\lambda$ .

Neste trabalho são propostas três alternativas para estimação do parâmetro  $\lambda$ , sendo elas: uma variante do algoritmo de busca binária, a realização de uma busca exaustiva



e o ajuste de um modelo matemático baseado na tendência ilustrada no gráfico da Figura 3.6. Tais procedimentos são discutidos, respectivamente, nas Subseções 3.5.1, 3.5.2 e 3.5.3.

Um conceito necessário às três propostas mencionadas, e que deve ser previamente introduzido, refere-se ao *espaço de busca*. O espaço de busca compreende o intervalo de valores onde se espera encontrar  $\hat{\lambda}$ .

De acordo com a premissa do deslocamento local, a classificação contextual realizada pelo método CaSVM acontece a partir de deslocamentos no hiperplano de separação, originalmente definido pelo método SVM, em função da repulsão (Equação 3.2), ou translação (Equação 3.8), exercida pelos padrões reprojitados, através de (3.1). O maior deslocamento que o hiperplano de separação pode sofrer equivale ao comprimento da diagonal do menor hiperparalelepípedo que contém os padrões de treinamento reprojitados. O comprimento desta diagonal é determinado por:

$$Q = \sqrt{\sum_{k=1}^d (sup_k - inf_k)^2}, \quad (3.10)$$

onde  $d$  é a dimensão de  $\mathcal{X}$ ,  $sup_k = \max \{x'_{ik}; (\mathbf{x}'_i, y_i) \in \mathcal{H}; i = 1, \dots, m\}$ ,  $inf_k = \min \{x'_{ik}; (\mathbf{x}'_i, y_i) \in \mathcal{H}; i = 1, \dots, m\}$ , tal que  $\mathbf{x}'_i = (x'_{i1}, \dots, x'_{id})$  e  $\mathcal{H}$  é o conjunto obtido pela reprojeção de todos os padrões de  $\mathcal{D}$ .

Os deslocamentos efetuados sobre o hiperplano de separação dependem exclusivamente da repulsão, ou translação, efetuada pelo submodelo Repulsivo, ou Translativo, em função dos contextos locais, específicos do problema de classificação. Um indicativo a respeito destes deslocamentos pode ser obtido através do *valor médio de repulsão*, ou *de translação*. Este valor médio é computado a partir do conjunto de padrões contidos no conjunto de treinamento  $\mathcal{D}$  que possuem em suas vizinhanças algum elemento com classe distinta da sua, após a classificação pelo método SVM. Formalmente, tal conjunto é definido por  $\bar{\mathcal{D}} = \{(\mathbf{x}_i, y_i) \in \mathcal{D} : \mathcal{I}(s) = \mathbf{x}_i; \exists t \in \mathcal{V}_\rho(s); \mathcal{I}(t) = \mathbf{x}_j; y_i \neq y_j; i = 1, \dots, m' \leq m\}$  com  $m' \in \mathbb{N}^*$  e  $m = \#\mathcal{D}$ .

Definindo  $\bar{\mathcal{S}} = \{s \in \mathcal{S} : \mathcal{I}(s) = \mathbf{x}_i; (\mathbf{x}_i, y_i) \in \bar{\mathcal{D}}\}$  como o conjunto das posições dos elementos de  $\bar{\mathcal{D}}$ , os valores médios de repulsão e translação, denotados

respectivamente por  $\varrho_{rep}$  e  $\varrho_{tra}$ , são determinados por:

$$\varrho_{rep} = \frac{1}{m'} \sum_{\forall s \in \bar{\mathcal{S}}} \frac{\left| \frac{G_p(s)}{E_n(s)} - \frac{G_n(s)}{E_p(s)} \right|}{\|\mathbf{w}\|}, \quad (3.11)$$

$$\varrho_{tra} = \frac{1}{m'} \sum_{\forall s \in \bar{\mathcal{S}}} \frac{|G_p(s) - G_n(s)|}{\|\mathbf{w}\|}, \quad (3.12)$$

onde  $G_p(s)$ ,  $G_n(s)$ ,  $T_p(s)$  e  $T_n(s)$ , definidos nas equações (3.2) e (3.8), são determinados para cada  $s \in \bar{\mathcal{S}}$ , cujo conjunto  $\mathcal{H}_s$  é conhecido. Nota-se das equações (3.11) e (3.12) que  $\frac{\left| \frac{G_p(s)}{E_n(s)} - \frac{G_n(s)}{E_p(s)} \right|}{\|\mathbf{w}\|}$  e  $\frac{|G_p(s) - G_n(s)|}{\|\mathbf{w}\|}$ , representam, respectivamente, a força com que os padrões são repelidos, no submodelo Repulsivo, ou a amplitude da translação, no submodelo Translativo.

Nessas condições, o *espaço de busca* corresponde ao intervalo  $[0, \lambda_{max}]$ , onde  $\lambda_{max} = Q/\varrho_{rep}$  quando o submodelo Repulsivo é adotado, ou  $\lambda_{max} = Q/\varrho_{tra}$  quando empregado o submodelo Translativo. Nota-se que a definição de  $\lambda_{max}$  é baseada no caso extremo, em que deseja-se provocar um deslocamento  $Q$  a partir de uma repulsão  $\varrho_{rep}$ , ou uma translação  $\varrho_{tra}$ . Para isso, seria necessário o emprego de  $\hat{\lambda}$  aproximadamente igual a  $Q/\varrho_{rep}$ , ou  $Q/\varrho_{tra}$ , respectivamente.

### 3.5.1 Busca binária

Com o conhecimento do espaço de busca  $[0, \lambda_{max}]$ , o algoritmo de busca binária verifica inicialmente os percentuais de acurácia  $A(\lambda_{max})$  e  $A(\lambda_{max}/2)$ , obtidos na classificação dos padrões de  $\mathcal{D}$ , considerando  $\lambda$  igual a  $\lambda_{max}$  e  $\lambda_{max}/2$ . Se  $A(\lambda_{max}/2) \geq A(\lambda_{max})$ , então o espaço de busca é reduzido para  $[0, \lambda_{max}/2]$ , caso contrário, o mesmo é reduzido para  $[\lambda_{max}/2, \lambda_{max}]$ . Este processo é repetido iterativamente sobre os intervalos de busca reduzidos até que a amplitude deste intervalo seja inferior a um valor arbitrário  $\epsilon$  inicialmente definido. Por fim,  $\hat{\lambda}$  é definido como o ponto médio do menor intervalo de busca reduzido obtido. Utilizando uma linguagem de alto nível, o procedimento de busca binária descrito é apresentado no Algoritmo 1.

---

**Algoritmo 1** Algoritmo de busca binária para estimação do parâmetro  $\lambda$ 

---

**Entrada:**  $[\lambda_{min}, \lambda_{max}]$ , intervalo de busca  
 $\mathcal{D}$ , conjunto de treinamento  
 $\epsilon$ , tolerância

**Enquanto**  $\lambda_{max} - \lambda_{min} \geq \epsilon$  **faça**

**Se**  $A(\lambda_{max}/2) < A(\lambda_{min})$  **então**  $\lambda_{min} \leftarrow \lambda_{max}/2$  **senão**  $\lambda_{max} \leftarrow \lambda_{max}/2$   
     $\hat{\lambda} \leftarrow \frac{\lambda_{max} + \lambda_{min}}{2}$

**Saída:**  $\hat{\lambda}$

---

### 3.5.2 Busca exaustiva

Admitindo o espaço de busca  $[0, \lambda_{max}]$ , a determinação de  $\hat{\lambda}$  a partir do processo de Busca Exaustiva consiste em verificar qual é o menor valor associado a este parâmetro que proporciona maior percentual de acurácia na classificação contextual dos padrões do conjunto de treinamento. Ou seja:

$$\hat{\lambda} = \min \left\{ \arg \max_{\lambda_i=0,1\varrho,2\varrho,\dots,\lambda_{max}} \{A(\lambda_i)\} \right\}. \quad (3.13)$$

Cabe observar que os valores observados  $\lambda_i$  correspondem a uma discretização de  $[0, \lambda_{max}]$  baseado nos múltiplos de  $\varrho$ , sendo  $\varrho$  equivalente a  $\varrho_{rep}$ , ou  $\varrho_{tra}$ , caso o submodelo Repulsivo, ou Translativo, seja empregado, respectivamente. Este simples método para estimação de  $\lambda$  é descrito no Algoritmo 2.

---

**Algoritmo 2** Algoritmo de busca exaustiva para estimação do parâmetro  $\lambda$ 

---

**Entrada:**  $\varrho$ , valor de repulsão média  
 $\lambda_{max}$ , limite superior do intervalo de busca  
 $\mathcal{D}$ , conjunto de treinamento

$j \leftarrow \frac{\lambda_{max}}{\varrho}$

$L[0..j] \leftarrow 0$ , vetor nulo de  $j + 1$  posições

**Para**  $i \leftarrow 0$  **até**  $j$  **faça**

$\lambda_i \leftarrow i \cdot \varrho$

$L[i] \leftarrow A(\lambda_i)$

$A_{max} \leftarrow \text{Máximo}(L)$

$\hat{\lambda} \leftarrow \lambda_{max}$

**Para**  $i \leftarrow j$  **até**  $0$  **faça**

**Se**  $L[i] = A_{max}$  **e**  $i \cdot \varrho < \hat{\lambda}$  **então**  $\hat{\lambda} \leftarrow i \cdot \varrho$

**Saída:**  $\hat{\lambda}$

---

### 3.5.3 Ajuste da curva de tendência

Uma terceira alternativa para determinação de  $\hat{\lambda}$  consiste em realizar o ajuste de um modelo matemático referente à curva apresentada na Figura 3.6. Para ajuste deste modelo são realizadas duas etapas iniciais: a redução do espaço de busca e a observação de percentuais de acurácia para valores de  $\lambda$  no espaço de busca reduzido.

Para redução do espaço de busca  $[0, \lambda_{max}]$ , são observados os valores de acurácia em  $A(\lambda_{max})$  e  $A(\lambda_{max}/2)$ . Enquanto  $|A(\lambda_{max}) - A(\lambda_{max}/2)| \leq \epsilon$ , admite-se que  $\lambda_{max} = \lambda_{max}/2$ , e verifica-se novamente se é possível reduzir tal intervalo.

Considerando  $[0, \lambda_{max}]$  o espaço de busca reduzido, são observados valores de  $A(\lambda_i)$ , considerando  $\lambda_i = \frac{i \cdot \lambda_{max}}{10}$ , com  $i = 0, 1, \dots, 9$ . Nestas condições, verifica-se que são observados apenas 10 valores de acurácia proporcionado por valores, sucessivos e equidistantes, associado ao  $\lambda^{(1)}$ . Considerando os pares  $(\lambda_i, A(\lambda_i))$ , com  $i = 0, 1, \dots, 9$ ; é realizado o ajuste de um modelo matemático, referente a curva apresentada na Figura 3.6, cuja formulação é:

$$\Lambda(a; \psi, \hat{\lambda}) = \begin{cases} A(0) + \psi \cdot \left( \frac{3}{2} \cdot \frac{a}{\hat{\lambda}} - \frac{1}{2} \cdot \left( \frac{a}{\hat{\lambda}} \right)^3 \right) & ; \text{ se } a \leq \hat{\lambda} \\ A(0) + \psi & ; \text{ se } a > \hat{\lambda} \end{cases} \quad (3.14)$$

onde  $\psi, \hat{\lambda} \in \mathbb{R}_+$  são parâmetros do modelo.

A determinação dos parâmetros que proporcionam o melhor o ajuste do modelo  $\Lambda(a; \psi, \hat{\lambda})$  às observações  $(\lambda_i, A(\lambda_i))$  é realizada com o emprego do Método dos Mínimos Quadrados. O parâmetro  $\hat{\lambda}$  diante o modelo  $\Lambda(a; \psi, \hat{\lambda})$  ajustado corresponde ao valor de  $\lambda$  onde ocorre a convergência dos percentuais de acurácia, indicado na Figura 3.6. Nestas condições, o valor de  $\hat{\lambda}$  que proporciona o ajuste de  $\Lambda(\lambda; S, \hat{\lambda})$  é adotado como uma estimativa adequada para o parâmetro  $\lambda$ . A heurística apresentada, denominada por *Ajuste da Tendência* é apresentada no Algoritmo 3.

---

<sup>(1)</sup>Foi verificado experimentalmente que a observação em 10 valores, sucessivamente equidistantes, para o parâmetro  $\lambda$ , proporciona um ajuste adequado da curva apresentada na Figura 3.6, cujo modelo matemático é definido a seguir.

---

**Algoritmo 3** A heurística *Ajuste da Tendência* proposta para estimação do parâmetro  $\lambda$

---

**Entrada:**  $\lambda_{max}$ , limite superior do intervalo de busca  
 $\mathcal{D}$ , conjunto de treinamento  
 $\epsilon$ , tolerância

$V[0..9], L[0..9] \leftarrow 0$ , vetores nulos de 10 posições

**Enquanto**  $|A(\lambda_{max}) - A(\lambda_{max}/2)| < \epsilon$  **faça**

$\lambda_{max} \leftarrow \lambda_{max}/2$

**Para**  $i \leftarrow 0$  **até** 9 **faça**

$V[i] \leftarrow \frac{i \cdot \lambda_{max}}{10}$

$L[i] \leftarrow A(V[i])$

$\psi, \hat{\lambda} \leftarrow MMQ(\Lambda, (V, L))^{(2)}$

**Saída:**  $\hat{\lambda}$

---

### 3.6 Restrições no uso de funções *kernel*

Como já discutido na Subseção 2.2.4, as funções *kernel* podem ser empregadas pelo método SVM com objetivo de aumentar a capacidade de separação entre os padrões. Implicitamente, estas funções computam o produto interno entre os padrões após mapeá-los para um espaço característico, através de uma função  $\phi(\cdot)$ . Nestas condições, uma função *kernel* equivale a  $\langle \phi(\cdot), \phi(\cdot) \rangle$ . No entanto,  $\phi(\cdot)$  é geralmente desconhecida.

De acordo com as formalizações apresentadas sobre o método CaSVM, a informação sobre a posição dos padrões no espaço de atributos é necessária nos processos que contemplam a reprojeção e a repulsão, no submodelo Repulsivo, definidas nas equações (3.1) e (3.2). Esta exigência restringe o uso de funções *kernel* àquelas em que  $\phi(\cdot)$  é conhecida. Dentre as funções *kernel* popularmente utilizadas, foram verificados meios de obter  $\phi(\cdot)$  para as funções Polinomial e de Base Radial.

Com o conhecimento da dimensão do espaço de atributos que contém os padrões e definindo o valor do parâmetro  $q$ , é possível determinar analiticamente  $\phi(\cdot)$  responsável pelo *kernel* Polinomial. Para isso basta expandir o polinômio  $(\langle \mathbf{x}_i, \mathbf{x}_j \rangle + 1)^q$  e observar qual produto interno dá origem ao mesmo. Por exemplo,

---

<sup>(2)</sup>  $MMQ(\Lambda, (V, L))$  significa que o Método dos Mínimos Quadrados é empregado para determinar os parâmetros do modelo  $\Lambda$  baseado nos pares  $(V, L)$ .

sejam  $\mathbf{x}, \mathbf{z} \in \mathbb{R}^2$  e  $q = 2$ :

$$\begin{aligned} \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle &= (\langle \mathbf{x}, \mathbf{z} \rangle + 1)^2 = (\langle (x_1, x_2), (z_1, z_2) \rangle + 1)^2 = \\ &= (x_1 z_1 + x_2 z_2 + 1)^2 = x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 z_1 + 2x_2 z_2 + 2x_1 x_2 z_1 z_2 + 1 = \\ &= \left\langle (x_1^2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2, \sqrt{2}x_1 x_2, 1), (z_1^2, z_2^2, \sqrt{2}z_1, \sqrt{2}z_2, \sqrt{2}z_1 z_2, 1) \right\rangle. \end{aligned}$$

$$\text{Logo: } \phi(\mathbf{x}) = (x_1^2, x_2^2, \sqrt{2}x_1, \sqrt{2}x_2, \sqrt{2}x_1 x_2, 1)$$

Com relação à função *kernel* de Base Radial, não é possível determinar  $\phi(\cdot)$ , uma vez que neste caso os padrões podem ser implicitamente mapeados em um espaço de dimensão infinita. No entanto, em [Vempati et al. \(2010\)](#) é apresentada uma aproximação para  $\phi(\cdot)$ . Porém, para que as aproximações sejam precisas, os padrões devem ser mapeados para espaços característicos com milhares de dimensões. Esta característica pode tornar impraticável o uso destas aproximações nos problemas relacionados à classificação de imagens.

## 4 EXPERIMENTOS E RESULTADOS

Neste capítulo são descritos três estudos de caso sobre classificação de imagens que envolvem a aplicação do método CaSVM. O primeiro estudo de caso (Seção 4.1) consiste na classificação binária de imagens simuladas, enquanto no segundo (Seção 4.2) e no terceiro (Seção 4.3) são realizadas classificações multiclasse de imagens reais de Sensoriamento Remoto, obtidas respectivamente pelos sensores PALSAR e MS, a bordo dos satélites ALOS e IKONOS-II, respectivamente.

Em todos os estudos de caso, os resultados de classificação obtidos pelo método proposto (CaSVM) são comparados aos resultados obtidos:

- pelo SVM, tradicional e pontual, discutido na Seção 2.2;
- pela proposta de Bovolo e Bruzzone (2005), onde os resultados obtidos pelo método SVM são integrados ao método ICM para geração de classificações contextuais. Método este discutido na Subseção 2.3.2 e denotado por SVM+ICM;
- pela aplicação do Filtro da Moda sobre o resultado de classificação SVM, para geração de classificações contextuais baseada na distribuição espacial da classe dos pixels. Método discutido na Subseção 2.3.3 e denotado por SVM+Moda.

A função *kernel* Polinomial foi empregada em todos os estudos de caso, por todos os métodos analisados. Além disso, a distância do máximo<sup>(1)</sup> foi utilizada para definição de  $\mathcal{V}_\rho(s)$ , o conjunto de posições vizinhas de um dado pixel  $s$ .

Para realização dos experimentos foi utilizado um computador com processador Intel *Core i5*, 3 GB de memória RAM e sistema operacional Microsoft Windows versão 7. As implementações necessárias para este estudo foram realizadas em linguagem de programação IDL (*Interactive Data Language*). Tais implementações incluem uma biblioteca de funções de uso comum em classificação de imagens e um sistema, denominado *Contextual SVM Classification Suite*, composto por diferentes métodos de classificação baseados em SVM e funções de processamento de imagens. A Figura 4.1 ilustra a interface principal deste sistema. Detalhes a respeito destas implementações são apresentados no Apêndice B.

---

<sup>(1)</sup>Sejam  $s, t \in \mathbb{R}^2$  tal que  $s = (s_1, s_2)$  e  $t = (t_1, t_2)$ , é denominada por *distância do máximo* a medida  $md(s, t) = \max\{|s_1 - t_1|, |s_2 - t_2|\}$ .

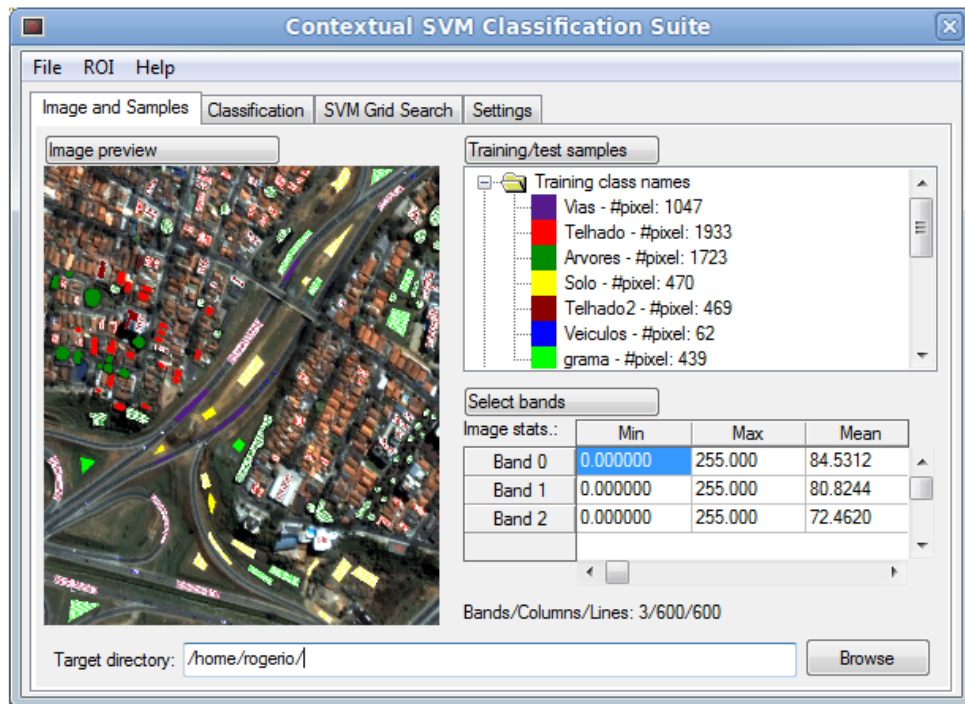


Figura 4.1 - Interface principal do sistema desenvolvido.

#### 4.1 Estudo de caso I: classificação binária de imagens simuladas

O objetivo principal do estudo de caso apresentado nesta seção é verificar, a partir de diferentes problemas de classificação binária, que o método proposto é capaz de produzir resultados válidos. Além disso, neste estudo de caso são realizadas avaliações sobre diferentes métodos disponíveis para resolução do problema (2.12) e sobre os métodos discutidos nas Subseções 3.5.1, 3.5.2 e 3.5.3, para estimação do parâmetro  $\lambda$ . Os resultados obtidos nestas avaliações são utilizados para definir os algoritmos para resolução de (2.12) e estimação de  $\lambda$  não só neste estudo de caso, como também no segundo e terceiro (Seções 4.2 e 4.3).

Para contemplar os objetivos deste estudo de caso, na Subseção 4.1.1 descreve-se o processo adotado para simulação de imagens e se discute características destas imagens. A seleção dos parâmetros do método SVM é apresentada na Subseção 4.1.2. A análise e seleção dos métodos para resolução de (2.12) e estimação de  $\lambda$  são apresentadas nas Subseções 4.1.3 e 4.1.4, respectivamente. Discussões sobre o desempenho do método CaSVM, em comparação com os demais métodos considerados, são apresentadas na Subseção 4.1.5.



#### 4.1.1 Simulação de imagens

O processo adotado para simulação de imagens é composto por duas etapas principais. A primeira etapa consiste na definição de uma imagem *Phantom*, a qual é um modelo idealizado responsável por representar uma dada distribuição espacial de alvos. A segunda etapa tem por objetivo definir o comportamento dos pixels que compõem os diferentes alvos da imagem *Phantom*. Para isso foi adotado um processo de reamostragem, consiste em observar aleatoriamente os atributos dos pixels de determinados alvos em uma imagem real de sensoriamento remoto para construção de uma imagem sintética. Uma vez que o processo de simulação envolve apenas uma reamostragem aleatória, a correlação espacial existente entre os pixels da imagem real de sensoriamento remoto não será conservada na imagem simulada. Por outro lado, a correlação entre os atributos dos pixels da imagem simulada são conservados, uma vez que ao realizar a reamostragem não há alteração na ordem dos atributos dos pixels observados ou realização de qualquer operação sobre os mesmos.

Os alvos reais considerados no processo de simulação foram observados em uma imagem adquirida em 13 de Março de 2009 pelo sensor ALOS, a bordo do satélite ALOS, com aproximadamente 20m de resolução espacial, nas polarizações HH, HV e VV em amplitude, sobre uma região no entorno da Floresta Nacional do Tapajós, no Estado do Pará. A Floresta Nacional do Tapajós é uma unidade de conservação federal com aproximadamente 544 mil hectares. Esta unidade é limitada ao norte pelo município de Belterra, pela rodovia BR-163 a leste, pelo rio Tapajós a oeste e pelos rios Tinga e Cupuari ao sul. É caracterizada pela extração de madeira ocorrida principalmente nas duas últimas décadas, provocando formação significativa de áreas de floresta secundária, concentradas ao longo da rodovia BR-163. As áreas ao leste desta floresta têm recebido incentivo governamental desde o início da década de 2000 para produção mecanizada de grãos para exportação (ZEE BR-163, 2011). Dentre os diferentes tipos de cobertura da terra existentes na cena, foram identificadas amostras de Floresta Primária, Regeneração, Pastagem, Agricultura, subdividida em tipos 1, 2 e 3, em função de suas respostas radiométricas distintas, e Solo Exposto. A Figura 4.2 apresenta a localização espacial da imagem ALOS PALSAR e identifica as amostras dos diferentes tipos de cobertura da terra mencionados.

A partir de uma análise exploratória dos dados, foi verificado que as amostras de Regeneração e Floresta Primária possuem baixo contraste, Regeneração e Agricultura tipo 1 médio contraste, enquanto um alto contraste foi observado entre as amostras de Regeneração e Solo Exposto. Baseado nestes pares de amostras,

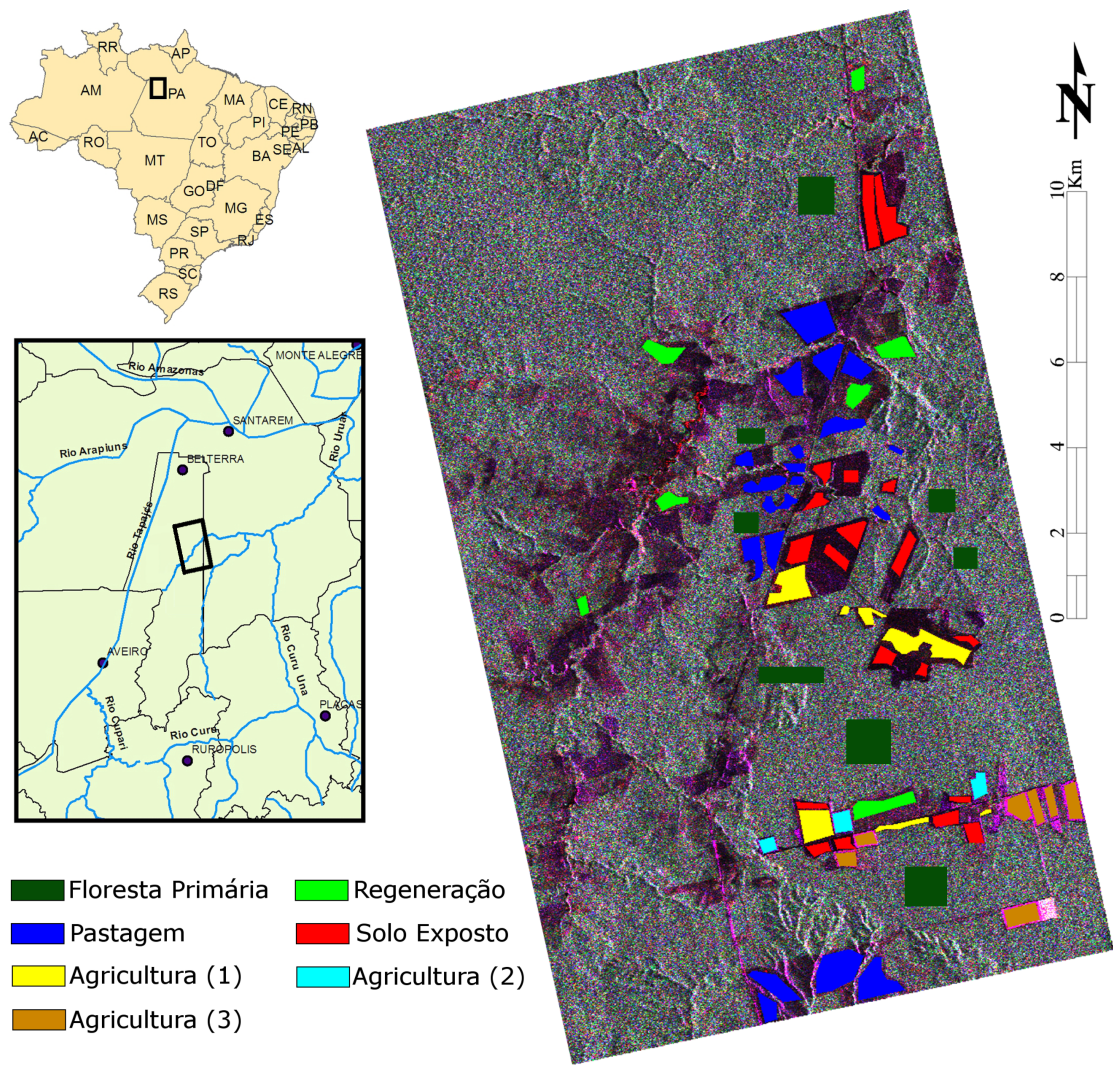


Figura 4.2 - Imagem ALOS PALSAR em amplitude, na composição colorida (HH)R(HV)G(VV)B, entorno da região da Floresta Nacional do Tapajós - PA. Diferentes tipos de cobertura da terra são identificados.

com distintos contrastes entre si, foram simulados três conjuntos de imagens, sendo cada conjunto composto por 1000 imagens. Cabe ressaltar que as imagens simuladas possuem as três polarizações da imagem real adotada, isto é, HH, HV e VV em amplitude.

A imagem *Phantom* empregada no processo de simulação é mostrada na Figura 4.3(a). Esta imagem possui dimensão de 150 × 150 pixels e contém apenas duas classes distintas, representadas na forma de feições (classe 1) distribuídas sobre uma superfície contínua (classe 2), ao fundo. Na Figura 4.3(b) são identificadas as amostras utilizadas para o treinamento dos métodos de classificação, as quais totalizam 470 pixels em cada classe. As Figuras 4.4(a), 4.4(b) e 4.4(c) representam

exemplos de imagens simuladas compostas por classes com baixo, médio e alto contraste entre si, respectivamente.

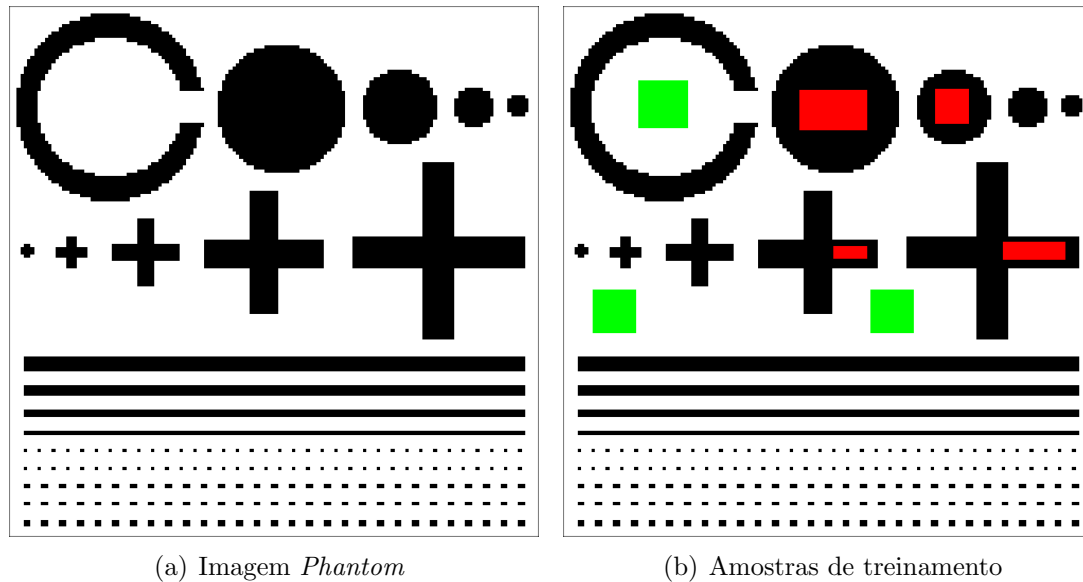


Figura 4.3 - *Phantom* adotado para simulação de imagens e amostras utilizadas para treinamento dos métodos.

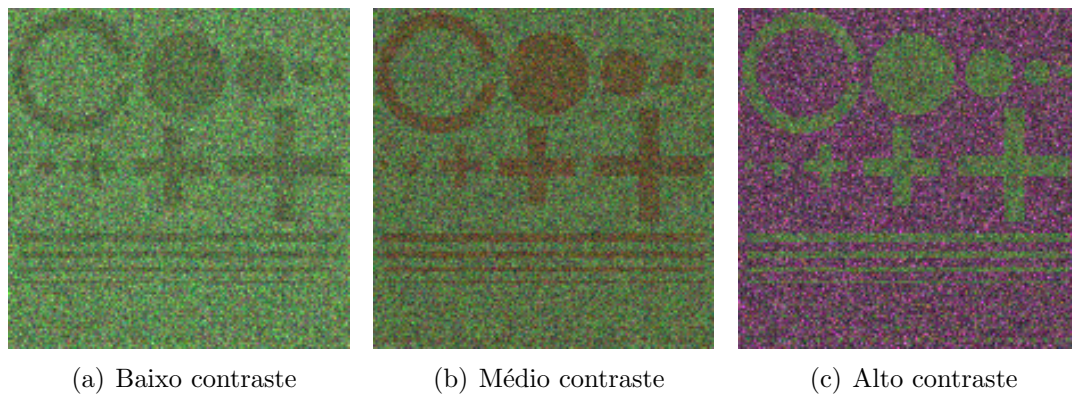


Figura 4.4 - Exemplos de imagens simuladas compostas por classes de diferentes contrastes.

Neste trabalho as feições distribuídas sobre a imagem *Phantom* são discriminadas em regiões largas, finas e pontuais, com base nos seguintes critérios:

- estruturas largas apresentam largura maior que quatro pixels;

- estruturas finas possuem largura igual ou inferior a quatro pixels;
- estruturas pontuais podem ser definidas no interior de um bloco de  $5 \times 5$  pixels.

Na parte superior da imagem *Phantom* estão localizadas duas filas compostas por estruturas circulares e em forma de cruz, em diferentes dimensões. Logo abaixo estão localizadas quatro estruturas lineares com 4, 3, 2 e 1 pixels de largura, respectivamente. Na parte inferior existem 5 filas de estruturas pontuais, sendo as duas primeiras compostas por estruturas de dimensão  $1 \times 1$  pixel, as duas seguintes com dimensão de  $1 \times 2$  e a última por  $2 \times 2$  pixels.

Sobre as regiões largas e finas são definidos os pixels de borda e de interior. Tais pixels devem respeitar os seguintes critérios:

- os pixels de borda referem-se aos pixels que possuem ao menos um pixel vizinho, que não faz parte de sua região, considerando um raio de vizinhança 1;
- os pixels de interior das regiões largas referem-se aos pixels que não estão localizados nas bordas das mesmas;
- os pixels de interior das regiões finas referem-se aos pixels que não estão localizados nas bordas das mesmas.

Esta distinção entre os pixels da imagem *Phantom* tem como objetivo definir diferentes conjuntos de validação, os quais permitirão avaliar a acurácia de classificações nas regiões largas, finas e pontuais, separadamente, como também nos pixels localizados nas bordas das regiões largas e finas. Na Figura 4.5 identificam-se os pixels de interior e de borda das regiões largas e finas assim como os pixels que compõem as regiões pontuais. Os pixels localizados sobre as amostras de treinamento, ilustradas na Figura 4.3(b), são desconsiderados, evitando que o cálculo da acurácia dos resultados utilize padrões empregados no treinamento. Cabe observar que na Figura 4.5 discrimina-se a pertinência dos pixels com relação a algum tipo de região ou borda, porém, não se distingue a classe associada a estes pixels. Para isso, deve ser observada a imagem *Phantom* (Figura 4.3(a)).

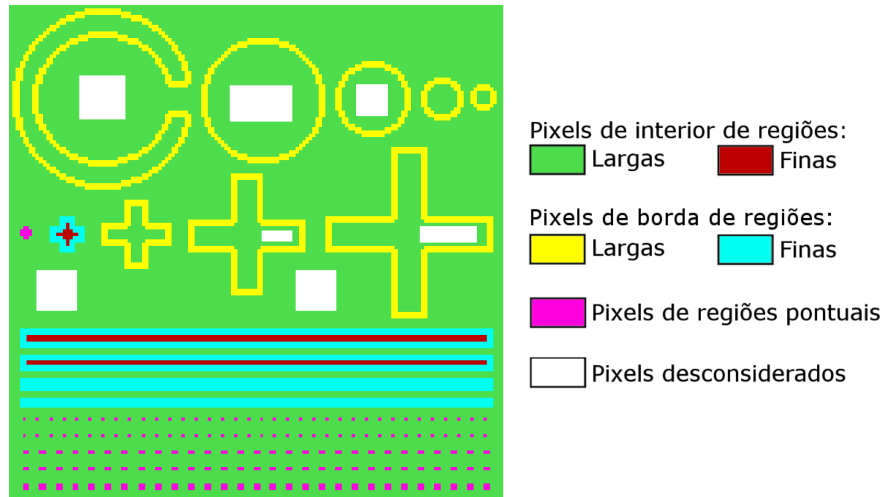


Figura 4.5 - Distinção entre os pixels que compõem os diferentes tipos de regiões ou estão na borda entre duas regiões.

#### 4.1.2 Seleção dos parâmetros do método SVM

Nos problemas de classificação, a adequada seleção dos parâmetros da função *kernel*, caso esta possua parâmetros, e da penalidade ( $C$ ) é de grande importância para o devido treinamento do método SVM. Vários estudos propõem métodos cuja finalidade é auxiliar na seleção dos parâmetros do SVM, como por exemplo: Keerthi (2002), Zhu et al. (2004), Friedrichs e Igel (2005), Sun (2008), Lin et al. (2008), Li e Tan (2010) e Hsu et al. (2010). Neste trabalho, o procedimento de Busca em Grade (*Grid Search*) é empregado. Segundo Hsu et al. (2010), duas motivações simples que tornam preferível o uso do procedimento *Grid Search* são a segurança em utilizar um método de busca exaustiva e o custo computacional, o qual não é muito maior comparado a outros métodos, nos processos que envolvem no máximo dois parâmetros.

O procedimento *Grid Search* consiste em verificar valores de acurácia obtidos por diferentes combinações de parâmetros, possibilitando a escolha de uma configuração conveniente. Os valores de acurácia calculados para as diferentes configurações de parâmetros são obtidos através da classificação de parte dos padrões do conjunto de treinamento ( $\mathcal{D}$ ), enquanto o restante dos padrões deste conjunto é empregado no treinamento do método.

Conjuntamente ao uso do procedimento *Grid Search* é usual o emprego do procedimento de múltipla validação cruzada (*v-fold cross-validation*) (KOHAVI, 1995) no cálculo dos valores de acurácia proporcionados pelas configurações de parâmetros

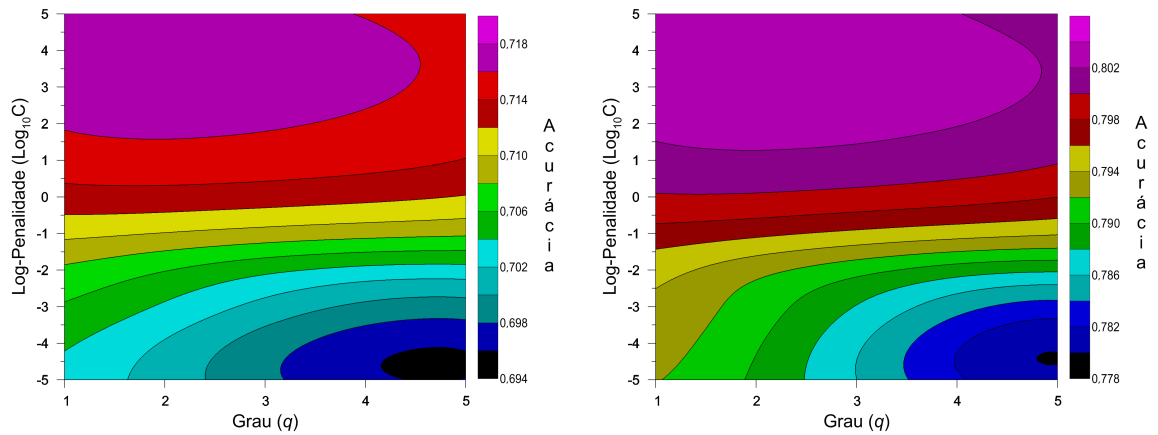
observadas. Procedimento este que, de acordo com [Hsu et al. \(2010\)](#) evita o superajuste dos parâmetros. O procedimento de múltipla validação cruzada consiste em particionar o conjunto  $\mathcal{D}$  em  $v$  subconjuntos mutuamente exclusivos e com aproximadamente mesma cardinalidade. Dado este particionamento, é selecionado um subconjunto para validação do método, treinado com a união dos  $v - 1$  subconjuntos remanescentes. Este procedimento é repetido para cada um dos  $v$  subconjuntos, e a cada repetição é computado o valor de acurácia, utilizando o subconjunto selecionado para validação. Ao fim, a média aritmética entre os  $v$  valores de acurácia obtidos determina o valor de acurácia geral. Segundo [Kohavi \(1995\)](#), a adoção de  $v$  igual a 10 geralmente produz bons resultados.

Nesta subseção, o procedimento *Grid Search*, associado a uma múltipla validação cruzada, é adotado para verificar a relação entre diferentes combinações dos parâmetros  $C$  e  $q$  e as respectivas acurácias retornadas, e apoiar na escolha da configuração adequada para a classificação das imagens simuladas. Idealmente, este procedimento deveria ser realizado para cada uma das 3000 imagens simuladas (i.e., 1000 simulações para cada um dos 3 tipos de contraste entre classes). No entanto, devido ao custo computacional exigido e à grande quantidade de imagens simuladas, tal procedimento é efetuado sobre 5% das imagens simuladas, segundo um dado contraste particular observado. Em seguida, é computado um resultado médio. O ajuste médio obtido determina os parâmetros para classificação de todas as imagens segundo o contraste observado.

Em [Hsu et al. \(2010\)](#) é sugerido que no procedimento *Grid Search*, o parâmetro  $C$  pode ser observado em uma escala exponencial. Neste trabalho, o parâmetro  $C$  admite valores no conjunto  $\{10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3, 10^4, 10^5\}$ . Com relação ao parâmetro  $q$ , da função *kernel* Polinomial, são observados valores no conjunto  $\{1, 2, 3, 4, 5\}$ . O percentual de acurácia sobre cada configuração de parâmetros observada é determinado por um processo de múltipla validação cruzada, com  $v = 10$ . O conjunto de padrões considerados neste experimento é composto pelos polígonos apresentados na [Figura 4.3\(b\)](#).


O resultado do processo descrito é apresentado nos gráficos de contorno da [Figura 4.6](#). Nestes gráficos é possível verificar que os valores de  $q$  igual a 1 e  $C$  igual a 1000 são suficientes para proporcionar altos percentuais de acurácia na classificação das imagens simuladas, para os diferentes tipos contraste entre classes. Embora seja possível verificar que valores superiores aos selecionados também proporcionam valores de acurácia equivalentes, porém os custos computacionais associados a estes

também são maiores.



(a) Imagens com baixo contraste entre classes

(b) Imagens com médio contraste entre classes



(c) Imagens com alto contraste entre classes

Figura 4.6 - Percentuais de acurácia obtidos na classificação de imagens com pares de classes de diferentes contrastes utilizando variadas configurações de parâmetros.

É importante mencionar que, para a escolha da configuração de parâmetros adequada, o treinamento do método SVM foi executado com uso do algoritmo LibSVM (CHANG; LIN, 2011). Na Subseção 4.1.3 é apresentada uma análise sobre o custo computacional de diferentes algoritmos disponíveis para o treinamento do método SVM em função da quantidade de padrões de entrada.

### 4.1.3 Seleção do algoritmo de otimização

Nesta subseção é apresentado um experimento que tem como objetivo comparar diferentes algoritmos disponíveis para resolução do problema de otimização (2.12),

responsável pelo treinamento do método SVM. Os algoritmos considerados foram *Sequential Minimal Optimization* (SMO) (PLATT, 1998), SVM<sup>Light</sup> (JOACHIMS, 1999), LibSVM (CHANG; LIN, 2011) e o método para solução de problemas de otimização quadrática pertencente à biblioteca IMSL (*International Mathematics and Statistics Library*), cuja implementação é apresentada em Powell (1985), o qual será denominado por QP. Cabe ressaltar que o método SMO foi implementado em linguagem IDL, o método QP é uma função da linguagem IDL, e os métodos SVM<sup>Light</sup> e LibSVM foram implementados em linguagem C.

Esta comparação é baseada no tempo computacional despendido e na exatidão dos resultados, considerando diferentes montantes de padrões (pixels) de treinamento. Para isso, foram utilizados os mesmos subconjuntos de imagens simuladas empregados no experimento apresentado na Subseção 4.1.2 (i.e. 5% de cada conjunto de 1000 imagens simuladas, com diferentes contrastes entre classes). Para cada imagem destes subconjuntos o método SVM é treinado adotando conjuntos de treinamento compostos por 10, 25<sup>(2)</sup>, 50, 100, 250, 500, 1000, 2500 e 5000 pixels, distribuídos igualmente entre as duas classes e selecionados aleatoriamente<sup>(3)</sup> sobre a imagem *Phantom* (Figura 4.3(a)). A acurácia dos resultados de classificação consiste no percentual de pixels, não empregados no treinamento, classificados corretamente. Os parâmetros  $C = 1000$  e  $q = 1$  foram usados neste estudo, e equivalem aos valores identificados na Subseção 4.1.2.

Nestas condições, considerando os subconjuntos de imagens simuladas, com um dado contraste comum, são computadas as acurácias e os tempos computacionais médios para cada um dos conjuntos de treinamento mencionados. Nas Figuras 4.7(a), 4.7(b) e 4.7(c) são apresentados os tempos computacionais médios, e os respectivos valores mínimos e máximos, obtidos por cada uma dos métodos considerados. As estatísticas referentes aos gráficos das Figuras 4.7(a) a 4.7(c) encontram-se disponíveis na forma numérica na Tabela C.1 do Apêndice C.

Os percentuais de acurácia obtidos pelos diferentes métodos foram iguais na maioria dos casos observados, e em alguns casos com diferença inferior a  $10^{-4}$ . Nestas condições, a seleção dos algoritmos para o treinamento do método SVM é baseado apenas no tempo computacional. Cabe mencionar que o método SMO não obteve

---

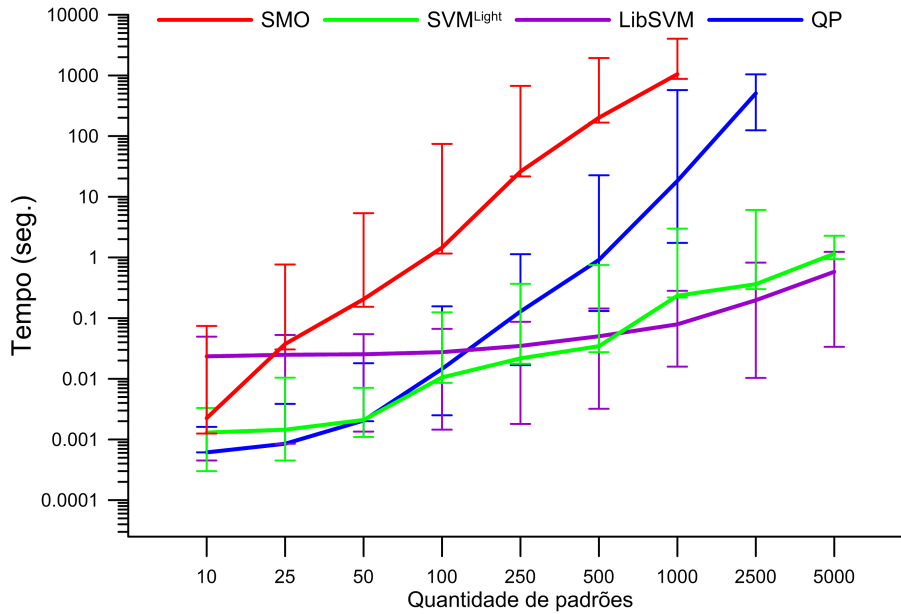
<sup>(2)</sup>Neste caso, 13 pixels foram selecionados para a classe referente às estruturas e 12 para a classe referente ao fundo da imagem simulada.

<sup>(3)</sup>Os conjuntos de treinamento foram definidos de forma aleatória, porém uma única vez. Em seguida, estes conjuntos foram utilizados no treinamento do método SVM, e por sua vez, o método já treinado, aplicado na classificação das imagens utilizadas no experimento.




solução após 3600 segundos quando utilizados mais de 1000 pixels para treinamento, assim como o método QP em problemas com mais de 2500 pixels.

De acordo com os resultados obtidos é possível observar que, para problemas envolvendo até 50 padrões de entrada, os métodos QP e SVM<sup>Light</sup> apresentam os melhores desempenhos no treinamento do método SVM, enquanto que, para




(a) Imagens com classes de baixo contraste



(b) Imagens com classes de médio contraste

(continua...)

(...continuação)



(c) Imagens com classes de alto contraste

Figura 4.7 - Tempo computacional despendido no treinamento do método SVM, considerando classes com diferentes contrastes entre si.

problemas envolvendo acima de 500 padrões, os melhores desempenhos são apresentados pelos métodos LibSVM e SVM<sup>Light</sup>. Observa-se também que os tempos computacionais dos métodos SMO e QP apresentam crescimento exponencial, sendo o método SMO mais custoso em todos os casos observados.

Para análise do tempo computacional, os resultados obtidos por cada um dos métodos analisados foram comparados de forma pareada, visando verificar a diferença estatística entre tais resultados com base em intervalos de credibilidade (MOOD et al., 1974; PIRES, 2009). Ao compara uma série de observações de duas populações de forma pareada, isto é,  $\{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\}$ , é possível observar a frequência  $Fr(A > 0)$  tal que  $A = X_i - Y_i$ , para  $i = 1, \dots, n$ . Um intervalo de credibilidade consiste em um limiar superior, ou uma faixa de frequências, considerado para determinar se as observações pareadas vindas de duas populações distintas são estatisticamente iguais. Se  $Fr(A > 0)$  é inferior a um dado limiar adotado, conclui-se que tais populações são estatisticamente iguais, ou diferentes quando  $Fr(A > 0)$  é superior a este limiar. Neste estudo foram adotados intervalos com 90% credibilidade, o que determina que duas populações são diferentes entre si quando uma delas é 90% das vezes observadas superior a outra.

Sob estas considerações, verifica-se que admitindo até 50 padrões de entrada, os métodos QP e SVM<sup>Light</sup> são estatisticamente iguais nos casos de baixo e médio contraste, enquanto no caso de alto contraste são estatisticamente diferentes, apresentando melhor desempenho o método QP. De forma análoga, considerando os problemas que envolvem mais de 500 padrões, os métodos LibSVM e SVM<sup>Light</sup> são estatisticamente iguais nos casos de baixo e médio contraste, enquanto no caso de alto contraste são estatisticamente diferentes, apresentando melhor desempenho o método LibSVM.

Sendo assim, o algoritmo QP será adotado no processo de ajuste dos hiperplanos locais, quando empregado o submodelo Repulsivo, uma vez que tal submodelo de contextualização contempla o treinamento do método SVM a partir de um conjunto de treinamento pequeno. Por outro lado, no processo de treinamento do método SVM, necessário para determinação da classificação inicial, será empregado o método LibSVM, uma vez que tal problema geralmente utilize quantidades acima de 500 padrões de treinamento.

#### 4.1.4 Seleção do algoritmo de estimação do $\lambda$

Na Seção 3.5 foram apresentadas três alternativas para estimação do parâmetro  $\lambda$ , responsável por determinar a influência do contexto no processo de classificação contextual pelo método CaSVM, seja no uso dos submodelos Repulsivo (Seção 3.1) ou Translativo (Seção 3.2). Nesta subseção tais alternativas são avaliadas. Foram considerados nesta avaliação raios de influência da vizinhança  $\rho$  iguais a 1, 2 e 3, que dão origem a janelas de contexto com dimensão de  $3 \times 3$ ,  $5 \times 5$  e  $7 \times 7$  *pixels*, respectivamente.

Para realização desta avaliação foram utilizados os mesmos três subconjuntos de imagens utilizados nos experimentos conduzidos nas Subseções 4.1.2 e 4.1.3. Cabe recordar que cada um dos três subconjuntos são compostos por 50 imagens (5% do total de 1000 simulações) com diferentes contrastes entre classes (baixo, médio e alto).

Cada imagem, dos três subconjuntos mencionados, foi inicialmente classificada pelo método SVM, treinado pelas amostras demarcadas na Figura 4.3(b) e considerando as configurações de parâmetros identificadas no experimento da Subseção 4.1.2 (i.e.,  $C = 1000$  e  $q = 1$ ). Em seguida, classificações contextuais desta imagem foram obtidas pelo método CaSVM, considerando os diferentes submodelos de contextualização (Repulsivo e Translativo) e diferentes valores de  $\rho$ , fazendo uso dos



de contexto e submodelos de contextualização, para cada uma das imagens dos subconjuntos observados, foram observadas as frequências com que um dado método para estimação de  $\lambda$  é superior a outro. Tais frequências são apresentadas nas Tabelas 4.1 e 4.2. Nestas tabelas o sinal (−) indica que o método da esquerda, como por exemplo, AT na comparação “AT vs. BB”, é superior ao da direita, e *vice-versa* no caso do sinal (+). Ainda, valores superiores ou iguais a 0, 90, que conferem a diferença estatística segundo um intervalo com 90% de credibilidade, são destacados em negrito e fonte itálica.

Com relação à acurácia das classificações, ilustrada nos gráficos da Figura 4.9, verifica-se que o método *Ajuste de Tendência* apresenta, na maioria dos casos observados, uma acurácia superior aos demais métodos, ao contrário do método *Busca Exaustiva*. Na Tabela 4.1 é possível verificar que, admitindo um intervalo com 90% de credibilidade, o método *Ajuste de Tendência* apresenta acurácia superior aos demais.

Ao observar o tempo computacional exigido pelos diferentes métodos, observa-se que com uso do submodelo Repulsivo, os maiores custos estão relacionados ao método *Busca Binária*, enquanto os métodos *Ajuste de Tendência* e *Busca Exaustiva* apresentam custos semelhantes. Já com uso do submodelo Translativo, os maiores tempos computacionais são apresentados pelo método *Busca Exaustiva*, e os menores por *Busca Binária*. Segundo as comparações entre os tempos computacionais exigidos, verifica-se na Tabela 4.2 que, com 90% de credibilidade, o método *Busca Exaustiva* é mais custoso comparado aos demais métodos, principalmente com uso do submodelo Translativo, e que embora na maioria dos casos o método *Busca Binária* apresente menor tempo computacional, existem casos em que seu custo é superior, principalmente com janelas  $3 \times 3$  e submodelo Repulsivo.

Segundo os resultados apresentados, verifica-se que o método *Busca Exaustiva* proporciona os menores índices de acurácia e maiores tempos computacionais, comparados aos demais métodos. Os maiores valores de acurácia estão associados ao método *Ajuste de Tendência*, porém, com custo computacional superior ao apresentado pelo método *Busca Binária*.

Baseado nesta discussão é decidido que o método *Ajuste de Tendência* é mais adequado para estimação do parâmetro  $\lambda$ . A partir desta escolha, os experimentos de classificação apresentados na Subseção 4.1.5, e nas Seções 4.2 e 4.3, farão uso deste método de estimação.

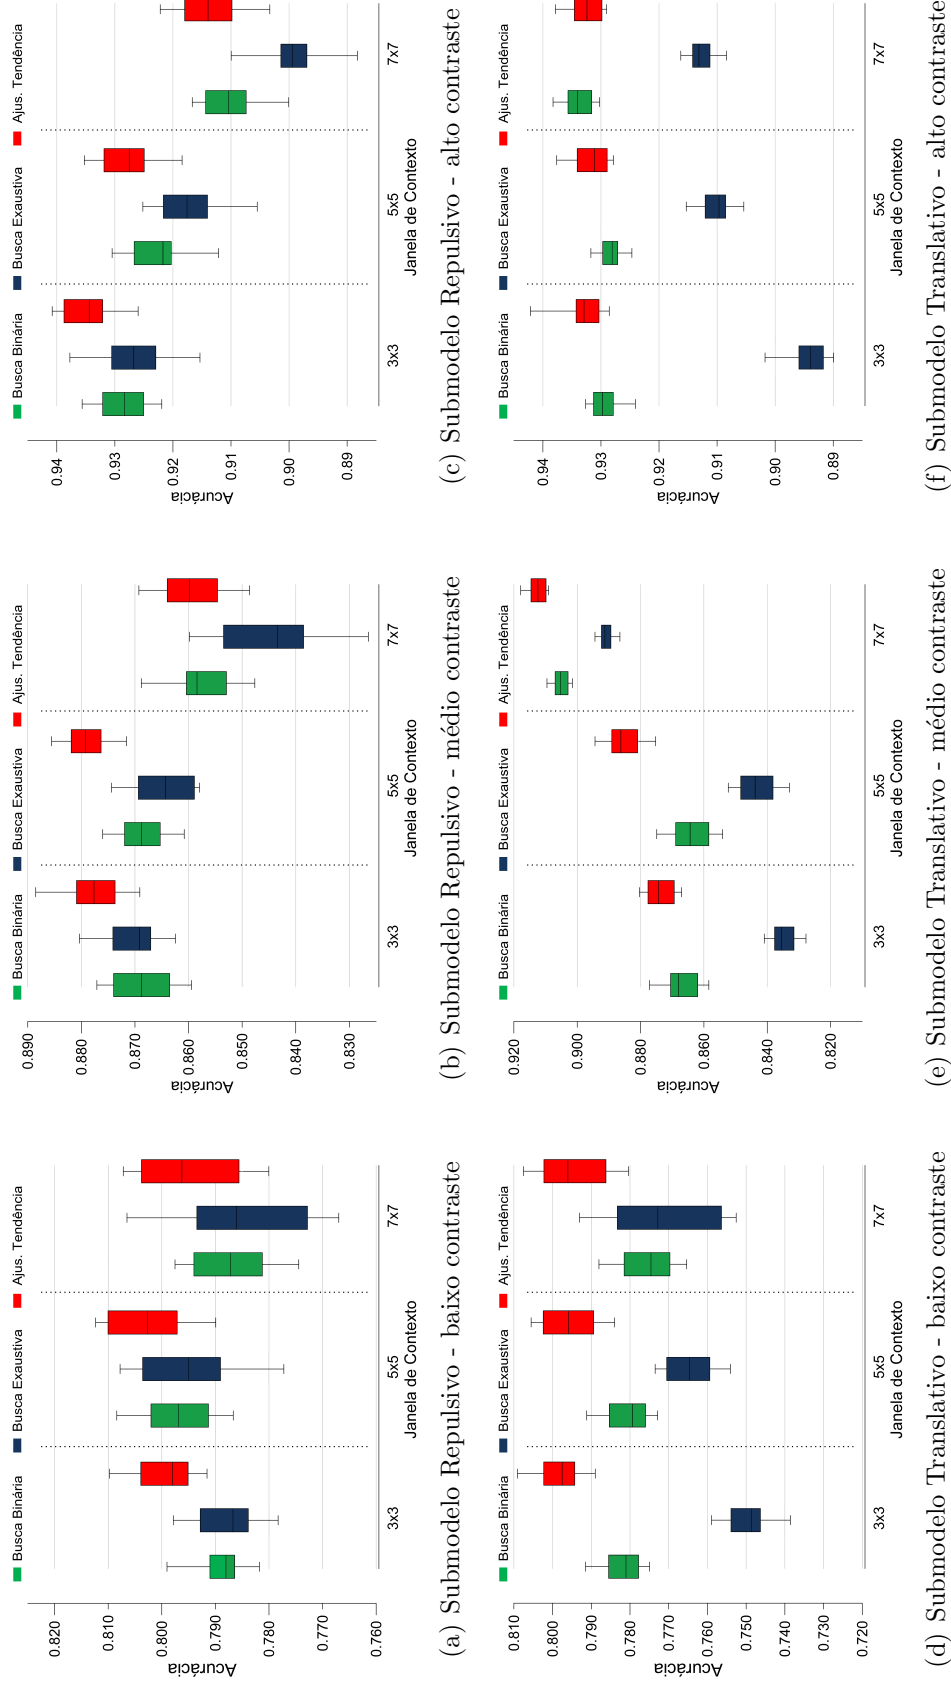





Figura 4.9 - Acurácia média obtida pelo valor estimado de  $\lambda$  pelos métodos analisados, considerando os submodelos Repulsivo e Translativo.




(a) Submodelo Repulsivo - baixo contraste




(b) Submodelo Repulsivo - médio contraste




(c) Submodelo Repulsivo - alto contraste



(d) Submodelo Translativo - baixo contraste



(e) Submodelo Translativo - médio contraste



(f) Submodelo Translativo - alto contraste

Figura 4.10 - Tempo computacional médio exigido na estimação do parâmetro  $\lambda$  pelos métodos analisados, considerando os submodelos Repulsivo e Translativo.

Tabela 4.1 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia obtidos.

		Comparação			
		AT vs. BB	AT vs. BE	BB vs. BE	
Repulsivo	Baixo	3 × 3	<b>1,00(-)</b>	<b>1,00(-)</b>	0,60(-)
		5 × 5	<b>0,90(-)</b>	0,74(-)	0,70(-)
		7 × 7	0,82(-)	<b>0,90(-)</b>	0,64(-)
	Médio	3 × 3	<b>1,00(-)</b>	<b>1,00(-)</b>	0,64(+)
		5 × 5	<b>1,00(-)</b>	<b>1,00(-)</b>	<b>0,90(-)</b>
		7 × 7	0,74(-)	<b>1,00(-)</b>	<b>1,00(-)</b>
	Alto	3 × 3	<b>1,00(-)</b>	<b>1,00(-)</b>	0,82(-)
		5 × 5	0,84(-)	<b>1,00(-)</b>	0,80(-)
		7 × 7	0,80(-)	<b>1,00(-)</b>	<b>1,00(-)</b>
Translativo	Baixo	3 × 3	<b>1,00(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
		5 × 5	<b>1,00(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
		7 × 7	<b>0,94(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
	Médio	3 × 3	<b>0,90(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
		5 × 5	<b>1,00(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
		7 × 7	<b>1,00(-)</b>	<b>1,00(-)</b>	<b>1,00(-)</b>
	Alto	3 × 3	0,64(-)	<b>1,00(-)</b>	<b>1,00(-)</b>
		5 × 5	0,80(-)	<b>1,00(-)</b>	<b>1,00(-)</b>
		7 × 7	0,64(+)	<b>1,00(-)</b>	<b>1,00(-)</b>

Tabela 4.2 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os tempos computacionais exigidos.

		Comparação			
		AT vs. BB	AT vs. BE	BB vs. BE	
Repulsivo	Baixo	3 × 3	<b>0,94(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>
		5 × 5	<b>1,00(-)</b>	0,70(+)	0,80(+)
		7 × 7	0,84(+)	0,52(+)	0,74(-)
	Médio	3 × 3	<b>0,90(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>
		5 × 5	<b>0,90(+)</b>	0,54(+)	0,80(-)
		7 × 7	<b>1,00(+)</b>	0,54(-)	<b>0,94(-)</b>
	Alto	3 × 3	<b>1,00(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>
		5 × 5	0,84(+)	0,64(-)	0,80(-)
		7 × 7	<b>1,00(+)</b>	0,54(+)	<b>1,00(-)</b>
Translativo	Baixo	3 × 3	<b>1,00(-)</b>	0,74(-)	<b>1,00(+)</b>
		5 × 5	<b>1,00(-)</b>	<b>0,90(+)</b>	<b>1,00(+)</b>
		7 × 7	<b>1,00(-)</b>	<b>0,90(+)</b>	<b>1,00(+)</b>
	Médio	3 × 3	<b>1,00(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>
		5 × 5	<b>1,00(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>
		7 × 7	0,60(+)	<b>1,00(+)</b>	<b>1,00(+)</b>
	Alto	3 × 3	<b>0,94(-)</b>	0,64(+)	<b>1,00(+)</b>
		5 × 5	<b>0,94(-)</b>	<b>1,00(+)</b>	<b>0,94(+)</b>
		7 × 7	<b>1,00(-)</b>	<b>1,00(+)</b>	<b>1,00(+)</b>



#### 4.1.5 Classificação binária de imagens simuladas

As subseções anteriores abrangeram o processo de simulação de imagens, seleção da configuração de parâmetros para o devido treinamento do método SVM, escolha do método de otimização para resolução de (2.12), e por fim, a determinação do método mais adequado, dentre os analisados, para estimação do parâmetro  $\lambda$ . Nesta subseção, o método CaSVM, com uso dos submodelos de contextualização Repulsivo e Translativo, é utilizado na classificação dos três conjuntos de imagens simuladas. Com objetivo de avaliar este método, seus resultados são comparados aos alcançados pelos métodos SVM, SVM+Moda e SVM+ICM.

Neste estudo, o raio de influência da vizinhança ( $\rho$ ) adotado nas classificações pelos métodos CaSVM e SVM+Moda equivale a 1, definindo assim uma janela de contexto de  $3 \times 3$  pixels. Com relação ao método SVM+ICM, como discutido na Subseção 2.3.1, o processo de contextualização é determinado iterativamente com uso de uma janela de contexto de  $3 \times 3$  pixels. Com relação à seleção dos critérios de convergência do método ICM (*número máximo de iterações e percentual mínimo de mudança*), também discutido na Subseção 2.3.1, foi aplicado o procedimento *Grid Search* segundo as mesmas considerações<sup>(4)</sup> adotadas no experimento apresentado na Subseção 4.1.2 para seleção dos parâmetros do método SVM.

Nos gráficos da Figura 4.11 são apresentados os resultados do procedimento *Grid Search*, onde é possível visualizar a relação entre diferentes configurações de parâmetros de convergência do método ICM e o valor médio de acurácia proporcionado nas classificações SVM+ICM. É possível verificar a partir destes resultados que os melhores percentuais de acurácia são obtidos admitindo *número máximo de iterações* igual a 12 e *percentual mínimo de mudança* igual a 1%, independente do contraste entre classes. Cabe mencionar que os parâmetros empregados no treinamento do método SVM são conhecidos a partir do experimento apresentado na Subseção 4.1.2.

De acordo com as condições definidas para realização deste experimento, os diferentes métodos citados foram empregados na classificação dos três conjuntos de imagens simuladas pelo procedimento descrito na Subseção 4.1.1. Para avaliar cada classificação gerada por um determinado método, foram calculadas 5 medidas:

---

<sup>(4)</sup>As considerações mencionadas referem-se ao uso da múltipla validação cruzada com  $v$  igual a 10, assim como a utilização do conjunto de treinamento definido na Subseção 4.1.1, ilustrado na Figura 4.3(b), e ao uso dos três subconjuntos compostos pela seleção aleatória de 5% das imagens simuladas segundo os diferentes tipos de contraste entre classes admitidos.


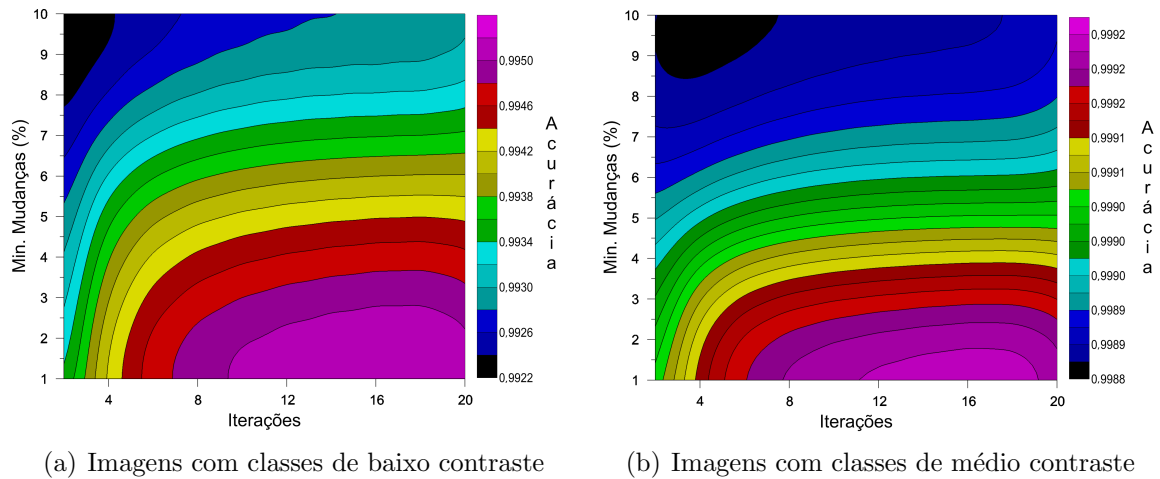


Figura 4.11 - Resultado da aplicação do procedimento *Grid Search* para seleção dos parâmetros adequados do algoritmo ICM, para uso posterior no método SVM+ICM.

percentuais de acurácia com relação à classificação das regiões largas, finas e pontuais, e os coeficientes *Upsilon* com relação à classificação nas bordas das regiões largas e finas. Os conjuntos de validação utilizados para o cálculo destas medidas foram definidos na Subseção 4.1.1 e ilustrados na Figura 4.5.

O percentual de acurácia refere-se simplesmente à quantidade de pixels classificados corretamente com relação aos respectivos conjuntos de validação. Já o coeficiente *Upsilon* é uma medida proposta neste trabalho para o cálculo da acurácia com relação à classificação de pixels localizados nas bordas de regiões. Tal medida é definida por:

$$\Upsilon = \frac{v_1 \cdot v_2 \cdot (v_1 \cdot v_2)}{z_1 \cdot z_2 \cdot (z_1 + z_2)}, \quad (4.1)$$

onde  $z_1$  e  $z_2$  representam a quantidade de pixels de borda de uma dada região entre as classes  $\omega_1$  e  $\omega_2$ ,  $v_1$  e  $v_2$  referem-se a quantidade de pixels classificados corretamente, com relação a  $z_1$  e  $z_2$ . A motivação e desenvolvimento desta medida são apresentados no Apêndice A.

Após a classificação das 1000 imagens simuladas, segundo um dado contraste específico entre classes, por um determinado método de classificação, foi realizada a avaliação dos respectivos resultados com relação a cada uma das 5 medidas mencionadas. Estimativas sobre a média e desvio padrão do tempo computacional exigido no processo de classificação também foram computados. Os gráficos das Figuras 4.12 a 4.17 apresentam os resultados, segundo cada uma das medidas adotadas, obtidos pelos diferentes métodos empregados na classificação de cada um dos conjuntos de imagens simuladas, e os respectivos tempos computacionais. Para distinção entre o uso do submodelo Repulsivo ou Translativo pelo método CaSVM, são empregadas as notações CaSVM.Rep e CaSVM.Tra, respectivamente.

As estatísticas referentes aos gráficos das Figuras 4.12 a 4.17 encontram-se disponíveis na forma numérica nas Tabelas C.2 a C.7 do Apêndice C. Ainda, neste mesmo apêndice são apresentadas tabelas com as frequências com que um dado método é superior a outro. Tais frequências são baseada em uma comparação pareada entre os resultados de cada método segundo uma mesma imagem simulada. Estas frequências são adotadas na determinação de intervalos de credibilidade para comparação entre os resultados. As comparações que seguem são baseadas em um intervalo com 95% de credibilidade.

De acordo com os resultados obtidos, é possível observar que os métodos SVM+ICM e SVM+Moda proporcionam os mais altos valores de acurácia na classificação das regiões largas, independente do contraste entre classes, como apresentado na Figura 4.12. Tais métodos são estatisticamente iguais com relação a classificação de imagens com baixo e médio contraste (cf. Tabela C.8). Resultados muito próximos são alcançados pelo método CaSVM.Rep. O método SVM+ICM alcançou percentuais de acurácia com medianas 10,4%, 2,7% e 1,1% superiores aos obtidos pelo método CaSVM.Rep, na classificação dos conjuntos de imagens com baixo, médio e alto contrastes entre classes, respectivamente.

Dentre os métodos contextuais analisados, CaSVM.Tra ofereceu os menores incrementos de acurácia em comparação ao método SVM, com relação à classificação do interior de regiões largas. Ao comparar as medianas dos resultados proporcionados por CaSVM.Rep com relação ao método SVM, são observados incrementos de 24,5%,

19,4% e 10,8%.

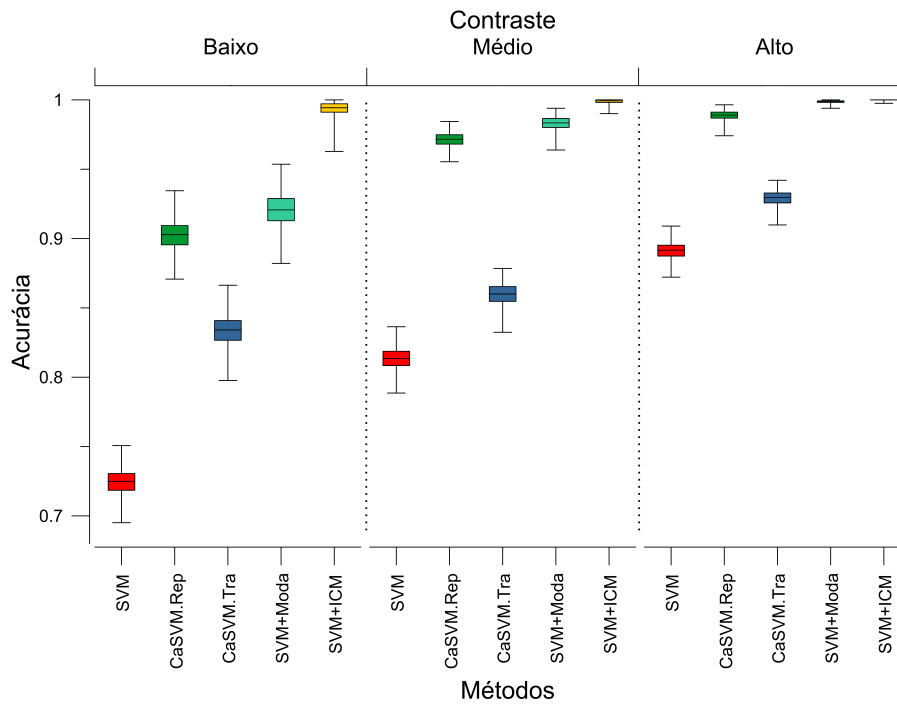


Figura 4.12 - Acurácia segundo a classificação no interior regiões largas, com relação às imagens com diferentes contrastes entre classes.

Na classificação das regiões finas, os maiores percentuais médios de acurácia são exibidos pelo método SVM+Moda. Os métodos SVM+ICM e CaSVM.Rep proporciona resultados estatisticamente iguais, independente do contraste entre classes. Para imagens com baixo contraste entre classes, o método SVM+ICM torna-se estatisticamente igual ao SVM+Moda. Verifica-se ainda que, embora o método CaSVM.Tra alcance valores de acurácia superiores ao SVM, eles são considerados estatisticamente iguais com relação a classificação de imagens com alto contraste entre classes.

É verificado ainda, com relação a classificação das regiões finas, que o método CaSVM, com uso do submodelo Repulsivo, apresentou mediana 6,6%, 1,7% e 1% menos acurado que o método SVM+Moda, enquanto que com uso do submodelo Translativo, o método CaSVM foi 12,1%, 10,1% e 8,1% menos acurado. Ambas as comparações referem-se à classificação dos conjuntos de imagens simuladas com baixo, médio e alto contraste entre classes, respectivamente. Porém, cabe ressaltar que o método CaSVM.Rep alcança resultados com mediana 17,9%, 16,2% e 12,4% superiores ao método SVM. Novamente, o método CaSVM.Tra proporciona os

menores incrementos de acurácia com relação ao método SVM, quando comparado aos demais métodos contextuais analisados. As afirmações expostas são verificadas no gráfico da Figura 4.13 e nas Tabelas C.3 e C.9.




Figura 4.13 - Acurácia média de classificação no interior regiões finas, com relação às imagens com diferentes contrastes entre classes.

A avaliação baseada na classificação dos pixels localizados nas bordas das regiões largas, com uso da medida *Upsilon*, indica que o método CaSVM.Rep é capaz de produzir classificações contextuais estatisticamente superiores às obtidas pelo SVM e pelos demais métodos contextuais, independente do contraste entre classes. Tal afirmação é verificada no gráfico da Figura 4.14 e na Tabela C.10. Observa-se ainda que bons resultados são obtidos com uso do submodelo Translativo, os quais são muito próximos aos resultados fornecidos pelo método SVM+ICM. Por sua vez, o método SVM+Moda proporciona resultados semelhantes aos obtidos pelo método SVM.

Com relação à classificação dos pixels localizados nas bordas das regiões finas, verifica-se que o método CaSVM, com uso dos submodelos Repulsivo e Translativo, proporcionam os maiores valores medianos de coeficientes *Upsilon*, comparados aos demais métodos analisados, como ilustrado no gráfico da Figura 4.15. Ainda, nesta comparação, os resultados dos testes estatísticos mostrados na Tabela C.11 conferem




Figura 4.14 - Coeficiente *Upsilon* dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes.

que o método CaSVM, independente do submodelo de contextualização, é superior ao método SVM+Moda, nos diferentes contrastes entre classes, e superior a método SVM+ICM no caso de baixo contraste. É possível verificar também que o método SVM+Moda apresenta menor acurácia, em comparação ao SVM, na classificação dos pixels localizados nas bordas de regiões finas.

Por fim, os diferentes métodos analisados são comparados com relação à classificação de regiões pontuais. O gráfico da Figura 4.16 mostra os diferentes comportamentos apresentados pelos métodos. Neste caso, todos os métodos contextuais analisados apresentam valores medianos de acurácia inferiores ao proporcionado pelo método SVM (pontual), com exceção do CaSVM.Rep na classificação de imagens com alto contraste entre classes. Verifica-se também que método CaSVM.Rep obtém os índices de acurácia comparado aos demais métodos contextuais, sendo ainda estatisticamente superiores a estes, como apresentado na Tabela C.12.

É verificado também na Figura 4.16 que, com o aumento do contraste entre classes, o percentual de acurácia do método SVM+Moda diminui gradativamente. Uma vez que neste método é considerada apenas a maior frequência dos rótulos das classes em uma dada vizinhança como critério para classificação contextual dos pixels, à medida




Figura 4.15 - Coeficiente *Upsilon* dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes.

que ocorre aumento no contraste entre classes, a acurácia das classificações SVM tendem a aumentar, e por sua vez, as regiões pontuais tendem a estar circundadas em maior número por pixels da classe complementar. Com isso, as regiões pontuais tendem a ser eliminadas, já que a classe complementar apresenta maior frequência. De modo geral, o método SVM+ICM apresenta baixa capacidade na classificação das regiões pontuais.

Cabe observar que o tempo computacional do método CaSVM, com o uso do submodelo de contextualização Repulsivo, é aproximadamente 6,4 vezes maior que o tempo do método SVM com relação ao caso de baixo contraste, enquanto nos casos de médio e alto contrastes este tempo é, respectivamente, 5,9 e 4,8 vezes maior. O elevado custo computacional apresentado pelo CaSVM.Rep é esperado, uma vez que a classificação contextual de cada pixel envolve a resolução de (2.12). A alta variância apresentada pelo CaSVM.Rep nos casos de baixo contraste esta relacionada a maior complexidade exigida na otimização de (2.12) para separação deste tipo de padrões. Com o uso do submodelo Translativo, o método CaSVM possui tempo computacional aproximadamente 1,6 vezes maior que o tempo do método SVM. Os tempos computacionais dos métodos SVM+Moda e SVM+ICM são aproximadamente 1,2 e 1,1 vez maiores que o tempo do método SVM, respectivamente. A Figura 4.17

apresenta um gráfico com o tempo médio de execução dos métodos analisados nos diferentes casos de classificação.




Figura 4.16 - Acúrcia média da classificação nas regiões pontuais, com relação às imagens com diferentes contrastes entre classes.

Nas Figuras 4.18 a 4.20 são apresentados resultados típicos de classificação dos casos de baixo, médio e alto contrastes. É possível verificar nesses resultados que método CaSVM, principalmente com uso do submodelo Repulsivo, comparado aos métodos SVM+Moda e SVM+ICM, apresenta resultados inferiores quanto à classificação de regiões largas, porém, maior capacidade de classificar corretamente as regiões finas e as bordas entre regiões.






Figura 4.17 - Tempo computacional despendido na classificação de imagens com diferentes contrastes entre classes.




Figura 4.18 - Resultados de classificação obtidos sobre uma das imagens simulada com baixo contraste entre classes.




Figura 4.19 - Resultados de classificação obtidos sobre uma das imagens simulada com médio contraste entre classes.

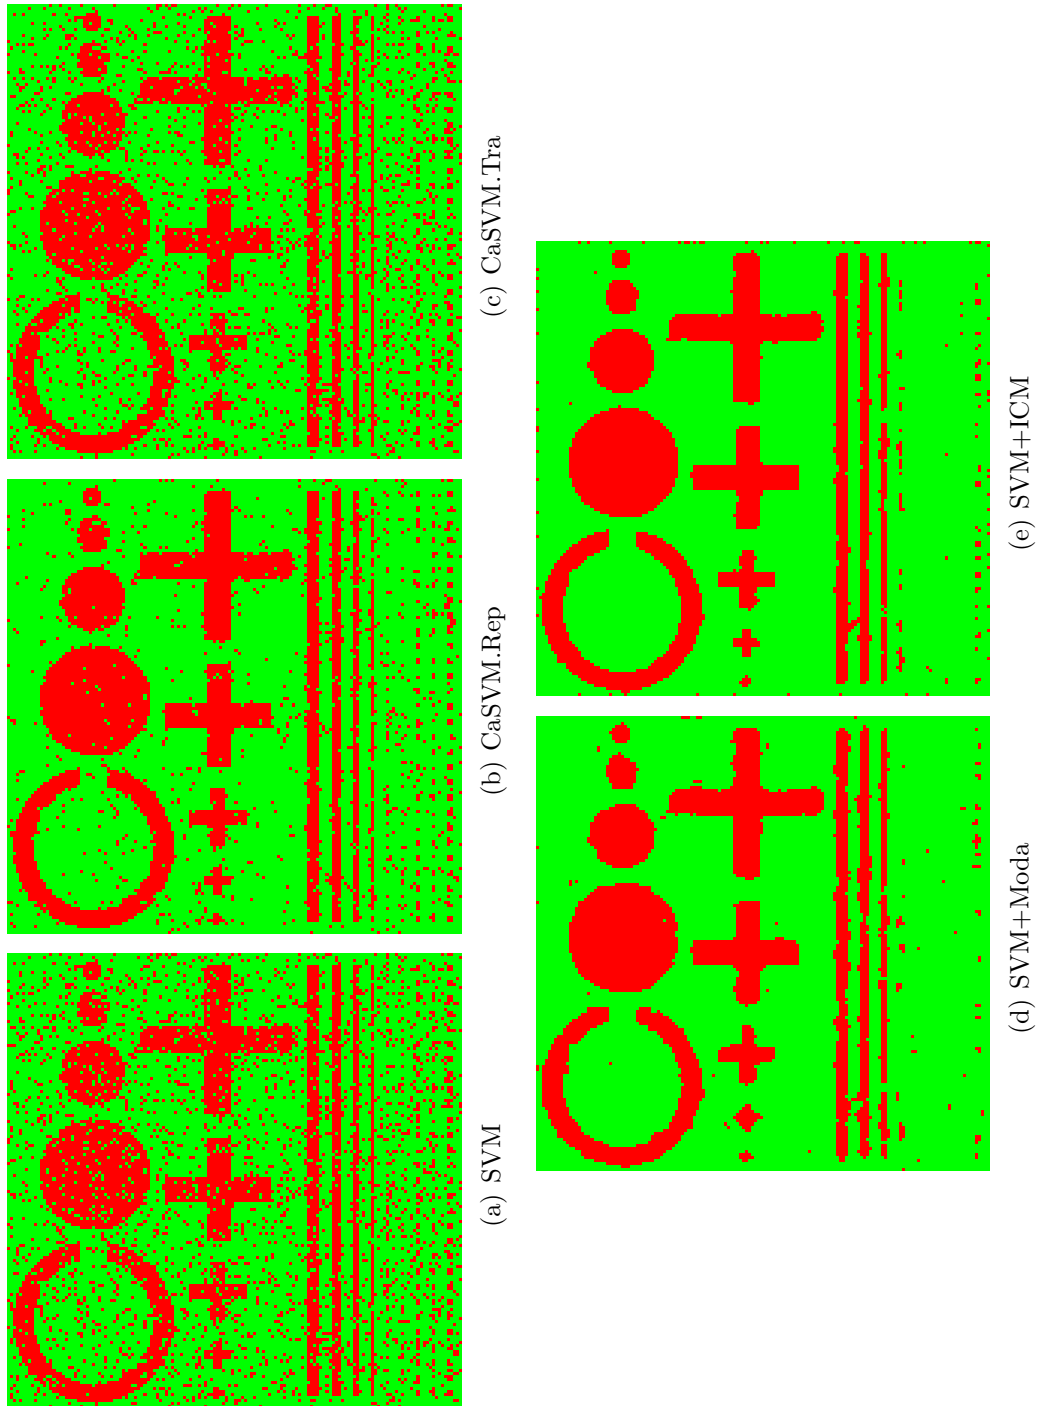


Figura 4.20 - Resultados de classificação obtidos sobre uma das imagens simulada com alto contraste entre classes.

Neste estudo de caso, os métodos SVM, CaSVM, SVM+Moda e SVM+ICM foram avaliados na classificação binária de imagens sintéticas com diferentes contrastes entre classe. Como esperado, verificou-se através dos experimentos realizados que os métodos contextuais proporcionaram resultados mais acurados, em comparação ao SVM (pontual), quando são avaliados de forma convencional. Isto é, as medidas de exatidão são computadas segundo a quantidade de pixels classificados corretamente no interior dos alvos na imagem. No entanto, os métodos contextuais considerados foram também avaliados por formas alternativas, através da verificação da exatidão de classificação em regiões pontuais, e nas bordas das regiões.

Na classificação das regiões pontuais, os métodos SVM+Moda e SVM+ICM apresentaram acurácia inferior ao CaSVM, como já previsto. Tal comportamento é justificado pelo fato da frequência das classes inicialmente associadas aos pixels, por um dado método pontual (neste caso o SVM), em uma dada vizinhança, apresentar forte influencia na determinação da regra de decisão para classificação contextual pelos métodos SVM+Moda e SVM+ICM. No CaSVM, a classe inicialmente associada aos pixels é tão importante quanto os atributos destes pixels na determinação da regra de decisão para classificação contextual.

A justificativa apresentada a respeito do desempenho dos métodos CaSVM, SVM+Moda e SVM+ICM na classificação das regiões pontuais é também válida para justificar o desempenho de tais métodos na classificação em bordas. A frequência das classes inicialmente associadas aos pixels, em uma dada vizinhança, podem provocar o alargamento, ou estreitamento, dos limites das regiões quando os métodos SVM+Moda e SVM+ICM são adotados para classificação contextual.

A respeito dos submodelos de contextualização, os resultados mostraram que o submodelo Repulsivo é superior ao Translativo. Comportamento este já esperado, uma vez que o submodelo Repulsivo possibilita maior flexibilidade na adaptação do hiperplano de separação em função da informação contextual, comparado ao Translativo. Em contrapartida à acurácia, o submodelo Repulsivo despende maior tempo computacional.

## 4.2 Estudo de caso II: classificação multiclasse de uma imagem do sensor ALOS PALSAR

Nesta seção, os métodos SVM, CaSVM, SVM+Moda e SVM+ICM são utilizados na classificação multiclasse de uma imagem real de sensoriamento remoto. Uma vez que a aplicação consiste em um problema multiclasse, estratégias multiclasse tornam-se necessárias. Para isso, são consideradas as estratégias OAA e OAO. Ainda, são utilizados neste experimento três valores para  $\rho$ , iguais a 1, 2 e 3, o que determinam por sua vez que a contextualização dos pixels será realizada com base nas informações contidas em janelas espaciais de dimensão  $3 \times 3$ ,  $5 \times 5$  e  $7 \times 7$  pixels, respectivamente.

A imagem utilizada neste experimento corresponde a um extrato de dimensão  $600 \times 600$  pixels, nas polarizações HH, HV e VV em amplitude, da imagem ALOS PALSAR adotada na Subseção 4.1. Neste segmento de imagem foram identificadas amostras de Floresta Primária, Agricultura de tipo 1, Pastagem e Solo Exposto. A Figura 4.21 apresenta a localização da área de estudo considerada neste experimento, com relação à imagem utilizada na Subseção 4.1, assim como as respectivas amostras empregadas no treinamento dos métodos e na validação dos resultados de classificação. A quantidade de pixels que compreendem as amostras de treinamento e validação, referentes às classes consideradas, são apresentadas na Tabela 4.3.

Na Figura 4.21 são ilustrados também três conjuntos de pixels localizados nas bordas de regiões entre as classes Floresta Primária e Solo Exposto (FP-SE), Pastagem e Floresta Primária (PS-FP) e Agricultura de tipo 1 e Floresta Primária (AG1-FP). A seleção destes pixels foi realizada a partir da análise visual da imagem, considerando o mesmo critério empregado no primeiro estudo de caso<sup>(5)</sup>. O objetivo da seleção destes pixels é quantificar a acurácia dos resultados gerados pelos métodos analisados com relação à classificação das bordas das regiões em um problema multiclasse. A quantidade de pixels utilizados para avaliar a classificação nas bordas das regiões consideradas é apresentada na Tabela 4.4. A avaliação da classificação nas bordas é realizada com uso do coeficiente *Upsilon*.

De modo análogo aos experimentos conduzidos com imagens simuladas, a função *kernel* Polinomial foi adotada neste estudo de caso e a distância do máximo na definição das vizinhanças. A escolha dos parâmetros penalidade ( $C$ ) e grau do *kernel* Polinomial ( $q$ ) é baseada no procedimento *Grid Search*, associado à múltipla validação cruzada, e fazendo uso das amostras de treinamento ilustradas na

---

<sup>(5)</sup>Os pixels localizados em bordas de regiões devem possuir ao menos outro pixel vizinho que não faz parte da sua região, considerando um raio de vizinhança 1 e a distância do máximo.

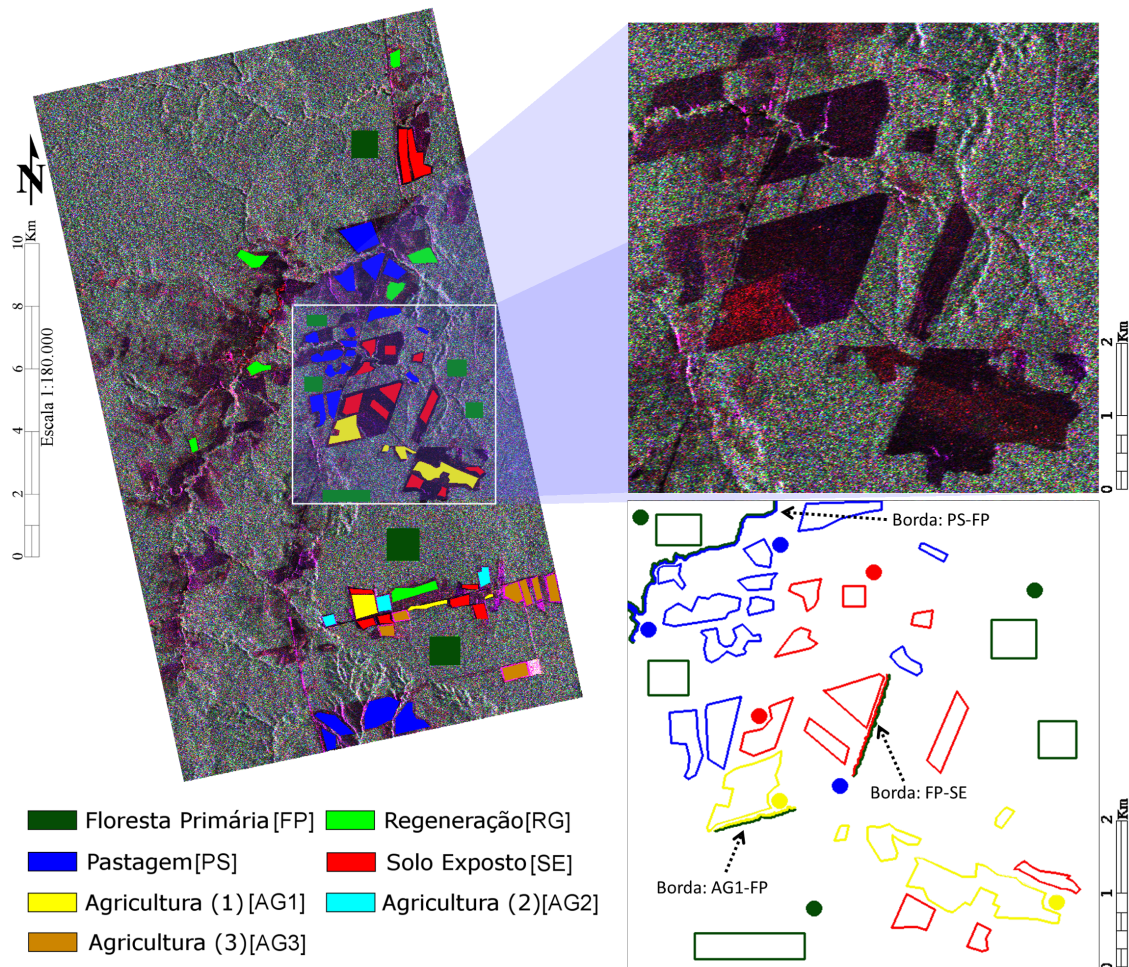


Figura 4.21 - Imagem ALOS PALSAR contendo as amostras de treinamento (círculos cheios) e de validação (polígonos vazios), e os pixels selecionados para avaliação das classificações nas bordas entre regiões de diferentes classes.

Figura 4.21. Para realização do processo de múltipla validação cruzada, o conjunto de treinamento foi particionado em 10 subconjuntos de aproximadamente mesma cardinalidade.

O procedimento *Grid Search* também é empregado para auxiliar na seleção das configurações de parâmetros de convergência do método ICM. Como mencionado na Subseção 2.3.2, a aplicação do método SVM+ICM em problemas multiclasse está vinculada ao uso da estratégia OAA. Assim, inicialmente, são utilizadas as configurações de parâmetros indicadas pelo procedimento *Grid Search* para o treinamento do método SVM, considerando a estratégia OAA. Em seguida, o resultado gerado pelo método SVM é utilizado como classificação inicial no método ICM. Sobre este resultado de classificação é realizado o procedimento *Grid Search*

Tabela 4.3 - Amostras de treinamento e validação.

<i>Classes</i>	<i>Quantidade de pixels</i>	
	<i>Treinamento</i>	<i>Validação</i>
Floresta Primária (FP)	768	14136
Agricultura tipo 1 (AG1)	512	14678
Pastagem (PS)	768	14395
Solo Exposto (SE)	512	14207

Tabela 4.4 - Quantidade de pixels selecionados para verificar a acurácia nas bordas entre regiões de diferentes classes.

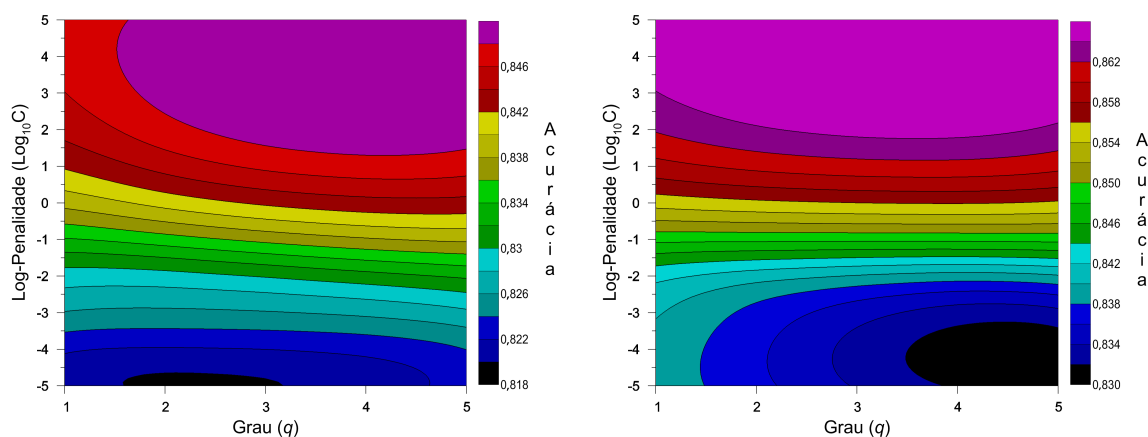
<i>Bordas</i>	<i>Quantidade de pixels</i>
Floresta Primária/Solo Exposto (FP-SE)	314/343
Pastagem/Floresta Primária (PS-FP)	804/720
Agricultura de tipo 1/Floresta Primária (AG1-FP)	276/242

para seleção dos parâmetros de convergência do método ICM.


Os resultados obtidos pelo procedimento *Grid Search* são apresentados nos gráficos da Figura 4.22. Verifica-se que o método SVM, com o uso da estratégia OAA, alcança altos percentuais de acurácia ao adotar  $C = 10000$  e  $q = 2$ . Com relação à estratégia OAO, altos percentuais de acurácia são obtidos com  $C = 10000$  e  $q = 1$ . Com relação aos parâmetros do método ICM, verifica-se que os maiores percentuais de acurácia são atingidos ao admitir *número máximo de iteração* igual a 16 e *percentual mínimo de mudança* igual a 1%. Utilizando os parâmetros selecionados, os métodos SVM, CaSVM, SVM+Moda e SVM+ICM foram aplicados na classificação da imagem ALOS PALSAR ilustrada na Figura 4.21.

Para avaliar cada um dos resultados de classificação produzidos, com relação a acurácia na classificação das diferentes classes, foram definidos aleatoriamente 1000 conjuntos de validação, a partir das amostras de validação ilustradas na Figura 4.21. A quantidade de pixels de validação referentes a cada uma das classes nestes conjuntos de validação correspondem a 10% do total de pixels disponível nesta classe. Cada conjunto de validação definido é utilizado no cálculo da acurácia global de cada uma das classificações realizadas. Após a realização deste procedimento é computados o valor médio de acurácia global e uma medida de variabilidade que corresponde ao intervalo entre o menor e maior valor observado, após descartar 2,5% dos menores e maiores valores observados. Além disso, a maneira adotada para avaliação permite a comparação pareada entre resultados de classificação dos





(a) Relação entre os parâmetros  $C$  e  $q$  e o percentual de acurácia proporcionado pelo método SVM, com emprego da estratégia OAA  
 (b) Relação entre os parâmetros  $C$  e  $q$  e o percentual de acurácia proporcionado pelo método SVM, com emprego da estratégia OAO



(c) Relação entre os parâmetros *número máximo de iterações* e *percentual mínimo de alteração* e o percentual de acurácia proporcionado pela classificação contextual SVM+ICM

Figura 4.22 - Representação dos resultados do procedimento *Grid Search*, aplicado para auxílio na seleção dos parâmetros dos métodos SVM (estratégia multiclasse OAA e OAO) e do método SVM+ICM.

diferentes métodos de classificação, e por sua vez, a construção de intervalos de credibilidade para verificação de igualdade estatística entre tais resultados, conforme discutido na Subseção 4.1.3.

As avaliações sobre classificação nas bordas entre regiões, quantificada com uso do coeficiente *Upsilon*, será conduzida de forma qualitativa. Esta determinação é baseada nas dificuldades quanto a identificação precisa dos pixels localizados nas bordas, que por sua vez inviabiliza a realização de uma avaliação precisão.

Na Figura 4.23 são apresentados os valores médios de acurácia, e os respectivos intervalos de variabilidade (ilustrado pela barra de erros), com relação às diferentes classificações geradas. Na Tabela 4.5 são apresentadas as frequências observadas, a partir de comparações pareadas, em que as medidas de acurácia produzida por um dado método é superior a outro. Ainda nesta tabela, os métodos listados na primeira coluna destas tabelas são comparados aos métodos dispostos entre a segunda e décima primeira coluna. Usa-se o símbolo (–) para identificar que o método cujo nome está na primeira coluna é superior na comparação realizada, caso contrário, é adotado o símbolo (+). Para auxiliar na visualização dos resultados da Tabela 4.5, valores iguais ou superiores a 0,90 estão destacados em negrito e fonte itálica, indicando assim que os dois métodos comparados são estatisticamente diferentes, com uma credibilidade de 90%.

Nos gráficos a seguir, com objetivo de facilitar a referência dos diferentes métodos analisados, sob diferentes considerações, foi acrescentado um sufixo ao nome do método contendo o nome da estratégia e a dimensão da janela de contexto empregada. Por exemplo, “SVM+Moda.OAO(3x3)” refere-se ao método SVM+Moda obtido com uso da estratégia OAO e janela de contexto com dimensão de  $3 \times 3$  pixels. Foram consideradas ainda as representações “CaSVM.Rep” e “CaSVM.Tra” para referir-se o uso dos submodelos de contextualização Repulsivo e Translativo no método CaSVM.




Figura 4.23 - Acurácias globais obtidas pelos métodos analisados.

Inicialmente, ao analisar de forma isolada o método CaSVM, verifica-se que o

submodelo de contextualização Repulsivo proporciona melhores resultados, em comparação aos resultados obtidos com uso do submodelo Translativo, segundo janelas de contexto de mesmas dimensões. É possível notar também que as estratégias OAO e OAA influenciaram menos os resultados obtidos com uso do submodelo Repulsivo. Ainda, observa-se que os maiores incrementos na precisão dos resultados acontecem ao aumentar a janela de contexto de  $3 \times 3$  para  $5 \times 5$  pixels.

O método SVM+Moda apresenta os mais altos valores de acurácia, com relação aos demais métodos, quando considerada a estratégia OAO e janelas de contexto de dimensão  $5 \times 5$  e  $7 \times 7$ . Com uso de janelas de contexto de dimensão  $3 \times 3$ , o resultado obtido torna-se estatisticamente igual ao produzido pelo CaSVM, com submodelo Repulsivo.

Verifica-se também que o uso da estratégia OAA implica, na maioria das vezes, em índices de concordância mais baixos, comparados a estratégia OAO. Ainda, ao considerar a estratégia OAA e janelas de contexto de mesmas dimensões ( $3 \times 3$  ou  $5 \times 5$ ) os métodos SVM+Moda e CaSVM, com submodelo Translativo, são estatisticamente iguais, porém, com uso do submodelo Repulsivo, o método CaSVM proporciona resultados superiores.

O método SVM+ICM apresenta resultados estatisticamente superiores aos demais métodos. Seus resultados são estatisticamente inferiores aos fornecidos pelo método CaSVM, com uso do submodelo Repulsivo, independente da estratégia multiclasse, e pelo métodos SVM+Moda, com uso de estratégia OAO, ambos com janelas de contexto com  $5 \times 5$  ou  $7 \times 7$  pixels. Todas as classificações contextuais analisadas apresentam resultados superiores aos obtidos pelo método SVM.

Nos gráficos das Figuras 4.24, 4.25 e 4.26 são apresentados os coeficientes *Upsilon* referentes ao desempenho dos diferentes métodos analisados com relação à classificação dos pixels localizados nas bordas entre as regiões Floresta Primária e Solo Exposto, Pastagem e Floresta Primária e Agricultura de tipo 1 e Floresta Primária, respectivamente.

Inicialmente, os resultados indicam que a estratégia multiclasse adotada provoca diferentes efeitos com relação à classificação dos pixels localizados nas bordas das regiões analisadas. Observa-se também que, geralmente, o aumento da dimensão da janela de contexto proporciona diminuição no coeficiente *Upsilon*. Ao considerar estratégias e janelas de contextualização comuns, o submodelo Repulsivo faz com que o método CaSVM produza resultados mais acurados, ou no mínimo semelhantes,

aos resultados produzidos com uso do submodelo Translativo.

De modo geral, o método SVM+ICM alcança coeficientes *Upsilon* superiores, comparados ao método SVM+Moda. Por sua vez, é possível observar que, na classificação das bordas analisadas, existem diversas configurações envolvendo os submodelos de contextualização, as estratégia multiclasse e as dimensões de janela de contexto que fazem o método CaSVM produzir resultados superiores ao SVM+ICM.

No gráfico da Figura 4.24 são apresentados resultados sobre a avaliação da classificação nas bordas entre regiões das classes Floresta Primária e Solo Exposto. É possível observar que o método CaSVM, com uso do submodelo Repulsivo, mas independente da estratégia multiclasse e dimensão da janela de contextualização, é capaz de proporcionar coeficientes *Upsilon* superiores aos obtidos pelo SVM. No entanto, este comportamento não é verificado quando feito uso do submodelo Translativo.

Ao examinar os desempenhos dos métodos analisados com relação a classificação nas bordas entre regiões das classes Pastagem e Floresta Primária, ilustrados no gráfico da Figura 4.25, verifica-se que o método CaSVM, independente do submodelo de contextualização, é superior ao SVM+Moda, para quaisquer estratégia multiclasse e dimensão de janela de contexto adotada. O método SVM+ICM é superior ao CaSVM quando feito uso de janelas  $7 \times 7$  e da estratégia OAA, simultaneamente. Verifica-se ainda que o uso da estratégia OAO faz com que os métodos CaSVM, SVM e SVM+Moda proporcionem resultados mais acurados, comparados aos obtidos com uso da estratégia OAA.

Tabela 4.5 - Frequências relativas as comparações entre a acurácia das classificações obtidas pelos métodos no processo de avaliação realizado. O método SVM+ICM é denotado por [U].

	[B]	[C]	[D]	[E]	[F]	[G]	[H]	[I]	[J]	[K]
[A] - SVM.OAO	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[B] - CaSVM.Rep.OAO(3x3)		1,00(+)	1,00(+)	1,00(-)	0,99(-)	0,77(+)	0,93(-)	1,00(+)	1,00(+)	1,00(-)
[C] - CaSVM.Rep.OAO(5x5)			0,82(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(+)	1,00(+)	1,00(-)
[D] - CaSVM.Rep.OAO(7x7)				1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(+)	1,00(+)	1,00(-)
[E] - CaSVM.Tra.OAO(3x3)					1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[F] - CaSVM.Tra.OAO(5x5)						1,00(+)	0,64(+)	1,00(+)	1,00(+)	1,00(-)
[G] - CaSVM.Tra.OAO(7x7)							0,96(-)	1,00(+)	1,00(+)	1,00(-)
[H] - SVM+Moda.OAO(3x3)								1,00(+)	1,00(+)	1,00(-)
[I] - SVM+Moda.OAO(5x5)									1,00(+)	1,00(-)
[J] - SVM+Moda.OAO(7x7)										1,00(-)
	[L]	[M]	[N]	[O]	[P]	[Q]	[R]	[S]	[T]	[U]
[A] - SVM.OAO	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)
[B] - CaSVM.Rep.OAO(3x3)		1,00(-)	1,00(+)	1,00(-)	0,99(-)	1,00(+)	1,00(-)	0,99(-)	0,93(+)	1,00(+)
[C] - CaSVM.Rep.OAO(5x5)			0,85(-)	0,93(+)	1,00(-)	0,99(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)
[D] - CaSVM.Rep.OAO(7x7)				0,69(-)	1,00(-)	0,96(-)	1,00(-)	1,00(-)	1,00(-)	0,99(-)
[E] - CaSVM.Tra.OAO(3x3)					1,00(+)	1,00(+)	1,00(-)	1,00(-)	0,99(+)	1,00(+)
[F] - CaSVM.Tra.OAO(5x5)						0,99(-)	1,00(-)	0,73(-)	0,99(+)	1,00(+)
[G] - CaSVM.Tra.OAO(7x7)							1,00(+)	1,00(-)	0,84(+)	0,99(+)
[H] - SVM+Moda.OAO(3x3)								0,80(-)	1,00(+)	1,00(+)
[I] - SVM+Moda.OAO(5x5)									1,00(-)	1,00(-)
[J] - SVM+Moda.OAO(7x7)										1,00(-)
[K] - SVM.OAA										1,00(+)
[L] - CaSVM.Rep.OAA(3x3)										1,00(+)
[M] - CaSVM.Rep.OAA(5x5)										1,00(-)
[N] - CaSVM.Rep.OAA(7x7)										1,00(-)
[O] - CaSVM.Tra.OAA(3x3)										1,00(+)
[P] - CaSVM.Tra.OAA(5x5)										1,00(+)
[Q] - CaSVM.Tra.OAA(7x7)										0,89(-)
[R] - SVM+Moda.OAA(3x3)										1,00(+)
[S] - SVM+Moda.OAA(5x5)										1,00(+)
[T] - SVM+Moda.OAA(7x7)										0,92(+)




Figura 4.24 - Coeficientes *Upsilon* computados a partir da classificação dos pixels localizados na borda entre regiões das classes Floresta Primária e Solo Exposto, segundo os métodos de classificação analisados.

Os resultados obtidos pela avaliação da classificação nas bordas entre regiões das classes Agricultura tipo 1 e Floresta Primária são apresentados no gráfico da Figura 4.26. De maneira distinta dos comportamentos analisados anteriormente (Floresta Primária e Solo Exposto; Pastagem e Floresta Primária), são observados diferentes casos em que o método SVM+Moda é superior ao CaSVM.Tra. O método CaSVM fornece resultados semelhantes quando empregada a estratégia OAA.

Dentre todos os resultados obtidos a respeito das classificações nas bordas das regiões consideradas, é possível notar no gráfico da Figura 4.24 um comportamento distinto. Enquanto na maioria dos casos observados o aumento nas dimensões da janela de contexto provoca, por menor que seja, um decremento no coeficiente *Upsilon*, o método CaSVM.Tra apresenta aumento deste coeficiente. A observação dos resultados de classificação leva a acreditar que este comportamento atípico está associado à combinação entre características dos dados e do submodelo de contextualização.

O tempo computacional exigido por cada um dos métodos analisados é representado no gráfico da Figura 4.27, em escala logarítmica. O maior custo computacional é exigido pelo método CaSVM, com uso do submodelo Repulsivo. A estratégia multiclasse OAO e a dimensão da janela de contexto contribuem para o aumento do custo computacional. A estratégia OAO exige a contextualização de um maior número de subproblemas binários, quando comparado à OAA. O aumento na

dimensão da janela de contexto provoca aumento do número de termos na função objetivo do problema de otimização (2.12), que por sua vez, aumenta a complexidade em sua resolução.

O submodelo Translativo exige menor tempo computacional, comparado ao




Figura 4.25 - Coeficientes *Upsilon* computados a partir da classificação dos pixels localizados na borda entre regiões das classes Pastagem e Floresta Primária, segundo os métodos de classificação analisados.




Figura 4.26 - Coeficientes *Upsilon* computados a partir da classificação dos pixels localizados na borda entre regiões das classes Agricultura de tipo 1 e Floresta Primária, segundo os métodos de classificação analisados.

submodelo Repulsivo, uma vez que não é necessária a resolução do problema (2.12) no processo de classificação contextual. O aumento na dimensão da janela de contexto provoca pouco aumento no tempo computacional. Os demais métodos contextuais apresentam tempos computacionais muito próximos ao exigido pelo método SVM.




Figura 4.27 - Tempo computacional exigido pelos métodos de classificação analisados.


Na Figura 4.28 são ilustrados alguns dos resultados de classificação mais relevantes obtidos neste estudo de caso. A partir da análise visual das classificações, é possível verificar que o método SVM+Moda homogeneiza, como esperado, a classificação fornecida pelo método SVM. O método CaSVM também proporciona resultados homogêneos, porém, com menor intensidade quando comparado ao SVM+Moda. Por sua vez, verifica-se que o uso do submodelo Repulsivo, comparado ao Translativo, faz o método CaSVM proporcionar resultados mais homogêneos. Embora o resultado obtido pelo método SVM+ICM possua maior homogeneidade, comparado ao CaSVM, nota-se que as classes Pastagem e Agricultura de tipo 1 foram classificadas erroneamente, em diferentes localidades da imagem, como Floresta Primária. Matrizes de confusão referentes a cada uma das classificações realizadas são apresentadas no Apêndice D. Tais matrizes são computadas com uso de todos pixels de validação quantificados na Tabela 4.3.

Este estudo de caso apresentou uma comparação entre os métodos SVM, CaSVM, SVM+Moda e SVM+ICM baseado em um problema de classificação multiclasse




de imagem de Sensoriamento Remoto. Segundo os índices de acurácia computados, verifica-se novamente que o desempenho do método CaSVM é similar aos demais métodos contextuais analisados. No entanto, foram realizadas avaliações quanto a classificação nas bordas de diferentes regiões, cujos resultados apontam maiores exatidões ao CaSVM com uso do modelo Repulsivo.


No geral, maiores índices de acurácia podem ser obtidos pelos métodos CaSVM e SVM+Moda através do aumento no raio de influência da vizinhança, porém, ao custo da diminuição na acurácia de classificação nas bordas das regiões. Ainda, não foi possível observar a existência dos efeitos sobre o método CaSVM em função da combinação entre as estratégias OAA e OAO e os modelos de contextualização propostos.




(a) SVM.OAO




(b) SVM.OAA




(c) CaSVM.Rep.OAO(5 × 5)



(d) CaSVM.Tra.OAA(5 × 5)



(e) SVM+Moda.OAO(7 × 7)



(f) SVM+ICM

Figura 4.28 - Alguns resultados de classificação relevantes obtidos pelos diferentes métodos analisados. Legenda: ■ Floresta Primária ■ Solo Exposto ■ Pastagem ■ Agricultura tipo 1

### 4.3 Estudo de caso III: classificação multiclasse de uma imagem do sensor IKONOS-II MS

Este terceiro estudo de caso tem como objetivo reproduzir, em uma aplicação distinta, as avaliações apresentadas na Seção 4.2. Tal aplicação consiste na classificação multiclasse de uma área urbana, especificamente, parte da região sul da cidade de São José dos Campos, Estado de São Paulo, com uso de uma imagem de alta resolução do sensor MS do satélite IKONOS-II, disponível em Santos (2013). O sensor MS, a bordo do satélite IKONOS-II, é capaz de adquirir imagens com 4 metros de resolução nos intervalos espectrais do azul ( $0,45 - 0,52\mu m$ ), verde ( $0,52 - 0,60\mu m$ ), vermelho ( $0,63 - 0,69\mu m$ ) e infravermelho próximo ( $0,76 - 0,90\mu m$ ). A área de estudo adotada para classificação abrange uma porção de  $600 \times 600$  pixels de dimensão, extraída da imagem original. Apenas a banda referente ao intervalo espectral do infravermelho próximo não foi utilizada neste estudo.

Sobre a área de estudo são consideradas as seguintes classes de cobertura do solo: Vegetação Alta, Vegetação Baixa, Telhado de Cerâmica, Telhado de Concreto/Metal, Solo Exposto e Asfalto. Vegetação Alta se refere a localizações onde a cobertura do solo é composta por árvores, enquanto áreas cobertas por grama, ou mesmo pequenos arbustos, são consideradas como Vegetação Baixa. As edificações são distinguidas entre as classes Telhado de Cerâmica<sup>(6)</sup>, usualmente associado a residências, e Telhado de Concreto/Metal<sup>(7)</sup>, geralmente relacionado a prédios ou edificações de fim comercial. Solo Exposto refere-se a áreas sem edificações ou mesmo com algum tipo de cobertura vegetal. Por fim, a classe Asfalto está atribuída às áreas pavimentadas.

Devido à alta resolução da imagem utilizada, é possível identificar alvos pontuais, o que permite avaliar a capacidade de classificação de alvos pontuais pelos métodos analisados. Os alvos pontuais considerados neste estudo referem-se a veículos nas proximidades da classe Asfalto. Com objetivo de distingui-los das demais classes presentes na cena, a resposta espectral dos veículos identificados foi manualmente alterada. Após tal alteração, estes alvos assumiram tonalidade magenta, quando a imagem de estudo é representada em composição natural.

A avaliação das classificações nas bordas entre regiões neste estudo de caso é

---

<sup>(6)</sup>Os elementos desta classe apresentam diferentes tonalidades da cor marrom, quando a imagem está representada em composição natural. A composição natural é obtida associando as bandas referentes aos intervalos espectrais do vermelho, verde e azul aos canais vermelho, verde e azul, respectivamente.

<sup>(7)</sup>Os elementos desta classe geralmente apresentam alta resposta espectral nas diferentes bandas, apresentando colorações claras.

realizada de forma distinta da apresentada na Seção 4.2. Enquanto na Seção 4.2 a avaliação baseia-se na borda entre regiões de duas classes específicas, neste terceiro estudo é avaliada a classificação na borda entre uma determinada classe, denominada por “borda interna”, com relação as demais classes, agrupadas e designadas por “borda externa”. Devido à forma regular e fácil identificação visual, apenas as classes Telhado de Cerâmica e Asfalto são empregadas na definição das bordas internas. A seleção dos pixels de borda é baseada no mesmo critério empregado nas Seções 4.1 e 4.2.


Na Figura 4.29(a) é ilustrada a imagem empregada neste estudo de caso. Amostras empregadas no treinamento e na validação dos resultados são identificadas na Figura 4.29(b). A Figura 4.29(c) apresenta os conjuntos de pixels selecionados para avaliação dos métodos com relação ao desempenho de classificação nas bordas de regiões das classes Asfalto e Telhado de Cerâmica. Uma legenda referente às Figuras 4.29(b) e 4.29(c) é apresentada na Figura 4.29(d). A Figura 4.30 ressalta os alvos pontuais após a edição de sua cor na composição natural. Na Tabela 4.6 são apresentadas as quantidades de pixels utilizados no treinamento dos métodos e na validação dos respectivos resultados, com relação a cada uma das classes consideradas. A quantidade de pixels utilizados na avaliação da classificação das bordas é apresentada na Tabela 4.7.

De maneira semelhante à realizada na Seção 4.2, o procedimento *Grid Search*, associado à múltipla validação cruzada ( $v = 10$ ), é empregado como ferramenta auxiliar na seleção dos parâmetros  $C$  e  $q$ , referente ao método SVM, assim como os parâmetros *número máximo de iterações* e o *percentual mínimo de mudança*, utilizados no método ICM. Os resultados deste processo, ilustrados nos gráficos da Figura 4.31, indicam novamente que altos percentuais de acurácia podem ser obtidos admitindo  $C = 10000$  e  $q = 2$ , quando feito uso da estratégia OAA, ou  $q = 1$  quando empregada a estratégia OAO. Com relação aos parâmetros do método ICM, verifica-se que o *percentual mínimo de mudanças* igual a 1% e *número máximo de iterações* igual a 12 podem oferecer bons resultados.


Baseado nas amostras de treinamento, e nos parâmetros selecionados, os métodos SVM, CaSVM, SVM+Moda e SVM+ICM são aplicados na classificação da imagem IKONOS-II MS, considerando, quando aplicável, janelas de contextualização de dimensão  $3 \times 3$ ,  $5 \times 5$  e  $7 \times 7$  pixels, e as estratégias multiclasse OAA e OAO. Os resultados de classificação obtidos são avaliados de forma semelhante a metodologia adotada no estudo de caso anterior (Seção 4.2). O gráfico da Figura 4.32 apresenta



(a) Imagem IKONOS-II MS em composição natural. Região sul de São José dos Campos - SP



(b) Amostras de treinamento (polígonos cheios) e validação (polígonos vazios)



(c) Amostras utilizadas para avaliação da classificação nas bordas de região das classes Asfalto e Telhado de Cerâmica



(d) Legenda referente às amostras das classes identificadas na imagem IKONOS-II MS

Figura 4.29 - Imagem utilizada no estudo, amostras utilizadas para treinamento e validação dos experimentos e legenda referente as amostras selecionadas.

os valores médios de acurácia, e os respectivos intervalos de variabilidade (ilustrado pela barra de erros).

De acordo com as frequências observadas na Tabela 4.8 e com a consideração de




Figura 4.30 - Identificação de veículos na imagem para avaliação dos métodos quanto à capacidade de classificação de alvos pontuais. A colorização destes alvos foi editada manualmente.

Tabela 4.6 - Amostras de treinamento e validação.


<i>Classe</i>	<i>Quantidade de pixels</i>	
	<i>Treinamento</i>	<i>Validação</i>
Vegetação Alta	1723	5828
Vegetação Baixa	439	4119
Telhado de Cerâmica	1933	4026
Telhado de Concreto/Metal	469	4261
Solo Exposto	470	4299
Asfalto	1047	4026
Veículos	62	160

Tabela 4.7 - Quantidade de pixels selecionados para quantificar a acurácia nas bordas das regiões.

<i>Bordas</i>	<i>Quantidade de pixels (interno/externo)</i>
Asfalto	8700/6067
Telhado de Cerâmica	5124/2792



(a) Relação entre os parâmetros  $C$  e  $q$  e o percentual de acurácia proporcionado pelo método SVM, com emprego da estratégia OAA  
 (b) Relação entre os parâmetros  $C$  e  $q$  e o percentual de acurácia proporcionado pelo método SVM, com emprego da estratégia OAO



(c) Relação entre os parâmetros *número máximo de iterações* e *percentual mínimo de alteração* e o percentual de acurácia proporcionado pela classificação contextual SVM+ICM

Figura 4.31 - Representação dos resultados do procedimento *Grid Search*, aplicado para auxílio na seleção dos parâmetros dos métodos SVM (estratégia multiclasse OAA e OAO) e do método SVM+ICM.

intervalos com 90% de credibilidade, verifica-se diversos casos em que os métodos analisados são estatisticamente iguais entre si. Todos os métodos contextuais considerados são estatisticamente superiores ao SVM. O método CaSVM.Rep alcança resultados superiores ao SVM+Moda com uso de janelas de contexto  $3 \times 3$  e estratégia OAO. Verifica-se ainda que o CaSVM.Rep é superior ao SVM+ICM quando empregadas janelas com  $5 \times 5$  e  $7 \times 7$  pixels de dimensão. No entanto, o CaSVM.Tra proporciona as médias de acurácia mais baixas, comparadas aos demais métodos contextuais. De modo geral, e semelhante ao estudo de caso

apresentado na Seção 4.2, nota-se que o aumento no raio de influência da vizinhança proporciona aumento nos valores de acurácia das classificações geradas pelos métodos CaSVM.Rep e SVM+Moda.




Figura 4.32 - Acurácias globais obtidas pelos métodos analisados.

Nas Figuras 4.33 e 4.34 são apresentados os valores do coeficiente *Upsilon* obtidos pelos métodos analisados com relação à classificação dos pixels localizados nas bordas que limitam regiões das classes Telhado de Cerâmica e Asfalto das demais, respectivamente, como ilustrado na Figura 4.29(c).

Com relação à classificação dos pixels localizados nas bordas de regiões da classe Telhado de Cerâmica (Figura 4.33) é observado que, ao considerar a estratégia OAO e janela de contexto com  $7 \times 7$  pixels de dimensão, o método SVM+Moda obtém resultados inferiores aos obtidos pelo SVM. Ao considerar a estratégia OAA, o método SVM+Moda é menos acurado que o método SVM quando utiliza janelas com  $5 \times 5$  e  $7 \times 7$  pixels de dimensão. Já os mais altos valores de coeficiente *Upsilon* observados nesta análise são conferidos ao método CaSVM, com uso do submodelo Repulsivo, independente da estratégia multiclasse adotada. O desempenho dos métodos SVM+ICM e CaSVM.Tra são semelhantes entre si.



Tabela 4.8 - Frequências relativas as comparações entre a acurácia das classificações obtidas pelos métodos no processo de avaliação realizado. O método SVM+ICM é denotado por [U].

	[B]	[C]	[D]	[E]	[F]	[G]	[H]	[I]	[J]	[K]
[A] - SVM.OAO	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	0,78(+)
[B] - CaSVM.Rep.OAO(3x3)	0,99(+)	1,00(+)	1,00(+)	0,93(-)	0,53(-)	0,68(-)	0,96(-)	0,99(+)	1,00(+)	1,00(-)
[C] - CaSVM.Rep.OAO(5x5)	0,85(+)	0,85(+)	1,00(+)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	0,56(+)	0,99(+)	1,00(-)
[D] - CaSVM.Rep.OAO(7x7)		1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	0,76(-)	0,94(+)	1,00(-)
[E] - CaSVM.Tra.OAO(3x3)			0,90(+)	0,77(-)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[F] - CaSVM.Tra.OAO(5x5)			0,77(-)	0,94(-)	0,98(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[G] - CaSVM.Tra.OAO(7x7)				0,86(-)	0,99(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[H] - SVM+Moda.OAO(3x3)					1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[I] - SVM+Moda.OAO(5x5)						1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(-)
[J] - SVM+Moda.OAO(7x7)							1,00(+)	1,00(+)	1,00(+)	1,00(-)

	[L]	[M]	[N]	[O]	[P]	[Q]	[R]	[S]	[T]	[U]
[A] - SVM.OAO	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)
[B] - CaSVM.Rep.OAO(3x3)	0,62(+)	1,00(+)	0,95(+)	0,99(-)	0,76(-)	0,54(-)	0,96(-)	0,80(+)	0,99(+)	0,85(+)
[C] - CaSVM.Rep.OAO(5x5)	0,92(-)	0,99(+)	0,51(+)	1,00(-)	1,00(-)	0,98(-)	1,00(-)	0,81(-)	0,75(+)	0,91(-)
[D] - CaSVM.Rep.OAO(7x7)	0,98(-)	0,94(+)	0,77(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	0,95(-)	0,51(+)	0,94(-)
[E] - CaSVM.Tra.OAO(3x3)	0,86(+)	1,00(+)	0,99(+)	0,94(-)	0,55(+)	0,78(+)	0,79(-)	0,99(+)	1,00(+)	0,97(+)
[F] - CaSVM.Tra.OAO(5x5)	0,61(+)	1,00(+)	0,97(+)	0,99(-)	0,76(-)	0,53(-)	0,95(-)	0,81(+)	0,98(+)	0,87(+)
[G] - CaSVM.Tra.OAO(7x7)	0,72(+)	1,00(+)	0,98(+)	0,97(-)	0,62(-)	0,61(+)	0,89(-)	0,89(+)	0,99(+)	0,92(+)
[H] - SVM+Moda.OAO(3x3)	0,94(+)	1,00(+)	1,00(+)	0,80(-)	0,75(+)	0,89(+)	0,60(-)	0,99(+)	1,00(+)	0,99(+)
[I] - SVM+Moda.OAO(5x5)	0,95(-)	0,98(+)	0,54(-)	1,00(-)	1,00(-)	0,98(-)	1,00(-)	0,88(-)	0,73(+)	0,86(-)
[J] - SVM+Moda.OAO(7x7)	1,00(-)	0,55(+)	0,99(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	0,95(-)	1,00(-)
[K] - SVM.OAA	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)	1,00(+)
[L] - CaSVM.Rep.OAA(3x3)		1,00(+)	0,93(+)	1,00(-)	0,93(-)	0,71(-)	0,99(-)	0,73(+)	0,99(+)	0,83(+)
[M] - CaSVM.Rep.OAA(5x5)			1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	1,00(-)	0,95(-)	1,00(-)
[N] - CaSVM.Rep.OAA(7x7)				1,00(-)	1,00(-)	0,99(-)	1,00(-)	0,86(-)	0,78(+)	0,93(-)
[O] - CaSVM.Tra.OAA(3x3)					0,99(+)	1,00(+)	0,73(+)	1,00(+)	1,00(+)	1,00(+)
[P] - CaSVM.Tra.OAA(5x5)						0,86(+)	0,85(-)	0,95(+)	1,00(+)	0,99(+)
[Q] - CaSVM.Tra.OAA(7x7)							0,94(-)	0,84(+)	1,00(+)	0,92(+)
[R] - SVM+Moda.OAA(3x3)								1,00(+)	1,00(+)	1,00(+)
[S] - SVM+Moda.OAA(5x5)									0,99(+)	0,53(+)
[T] - SVM+Moda.OAA(7x7)										0,96(-)

Ao observar simultaneamente os resultados mostrados no gráfico da Figura 4.33, é possível notar que o aumento nas dimensões da janela de contexto não determina uma tendência comum, seja ela de aumento ou diminuição, no coeficiente *Upsilon*. Além disso, a amplitude de variação dentre os coeficientes *Upsilon* computados equivale a aproximadamente 0,07<sup>(8)</sup>.




Figura 4.33 - Coeficientes *Upsilon* obtidos pelos métodos analisados na classificação dos pixels localizados na borda entre regiões da classe Telhado de Cerâmica e as demais classes.

Na Figura 4.34, onde são apresentados resultados de classificação nas bordas de regiões da classe Asfalto, verifica-se novamente que o melhor desempenho é fornecido pelo método CaSVM, com uso do submodelo Repulsivo, independentemente da estratégia multiclasse e dimensão da janela de contexto. Com uso do submodelo Translativo, o método CaSVM apresenta bons resultados apenas com o uso da estratégia OAO, enquanto que com uso da estratégia OAA são fornecidos resultados inferiores aos proporcionados pelo SVM. Também foi observado que os métodos SVM+ICM e SVM+Moda apresentam resultados inferiores ao SVM.

A avaliação dos classificadores segundo o desempenho de classificação de alvos pontuais foi baseado no percentual de pixels classificados corretamente, com relação aos veículos identificados sobre a imagem de estudo. Os percentuais de acurácia obtidos pelos métodos analisados são apresentados no gráfico da Figura 4.35.

<sup>(8)</sup> Valor obtido pela subtração entre os coeficientes *Upsilon* obtidos por CaSVM.Rep.OAO(7 × 7) e SVM+Moda.OAA(7 × 7)




Figura 4.34 - Coeficientes *Upsilon* obtidos pelos métodos analisados na classificação dos pixels localizados na borda entre regiões da classe Asfalto e as demais classes.

De modo geral, verifica-se que o aumento da dimensão da janela de contexto provoca queda na acurácia na classificação dos alvos pontuais. Tal comportamento é mais acentuado no caso do método SVM+Moda. Observa-se ainda que o método SVM+ICM apresenta acurácia 42,7% inferior ao método SVM.OAO, e 38,2% inferior ao SVM.OAA. Já o método CaSVM, com uso do submodelo Repulsivo, alcança percentuais de acurácia inferiores ao método SVM ao adotar janelas de contexto de dimensões  $5 \times 5$  e  $7 \times 7$  pixels, para qualquer estratégia multiclasse. Com uso do submodelo Translativo, o método CaSVM apresenta percentuais inferiores ao SVM quando utilizada a estratégia OAO e janelas de contexto com  $5 \times 5$  e  $7 \times 7$  pixels de dimensão, ou com janelas  $7 \times 7$  quando adotada a estratégia OAA. Com uso da estratégia OAA e janelas de contexto de dimensão  $3 \times 3$ , o método CaSVM obtém acurácias superiores ao método SVM, independente do submodelo de contextualização.

Os tempos computacionais exigidos pelos métodos de classificação analisados são ilustrados na Figura 4.36. Assim como observado no primeiro e segundo estudo de caso, o método CaSVM, principalmente quando associado ao submodelo Repulsivo, exige maior tempo de processamento. É possível observar também a influência das estratégias multiclasse no custo computacional do método CaSVM. Já o custo exigido pelos demais métodos contextuais são próximos ao obtido pelo SVM.

Com base nos resultados apresentados sobre a acurácia global e coeficientes *Upsilon*,




Figura 4.35 - Acurácia na classificação de alvos pontuais.




Figura 4.36 - Tempo computacional exigido pelos métodos de classificação analisados.

foi possível verificar que a combinação entre a estratégia OAA e o submodelo Translativo pode influenciar negativamente na geração dos resultados. A justificativa para tal fenômeno é baseada em características do submodelo Translativo e da regra de decisão que compreende a estratégia OAA.

Recapitulando os conceitos apresentados na Subseção 2.2.5, quando a estratégia OAA é empregada nos problemas multiclasse, a decisão de classificação é determinada em função da distância entre o padrão e um dos hiperplanos, que

separa uma classe específica das demais. Com relação ao submodelo Translativo, a classificação contextual dos padrões é dada através de translações no hiperplano de separação, inicialmente definido pelo SVM, em função da informação contextual. Uma vez que este submodelo não oferece um tratamento sobre as relações de distância entre os padrões e os hiperplanos, após a realização das translações, acredita-se que sua associação à estratégia OAA pode implicar, em alguns casos, em comportamentos indesejados. Por outro lado, a estratégia OAO mostra-se mais robusta a este submodelo de contextualização, uma vez que sua decisão de classificação é baseada em uma “maioria de votos” (cf. Subseção 2.2.5).


Por outro lado, não são verificados os efeitos negativos da combinação entre OAA e o submodelo Translativo na classificação dos alvos pontuais. Neste caso, há indícios que levam a crer que a alteração manual realizada sobre os alvos pontuais, ilustrado na Figura 4.30, tornou sua discriminação mais simples e independente de estratégias multiclasse.

Na Figura 4.37 são ilustrados alguns dos resultados de classificação mais relevantes obtidos neste estudo de caso. Os resultados apresentados nesta figura ilustram uma semelhança muito grande entre os métodos CaSVM, com submodelo Repulsivo, SVM+Moda e SVM+ICM. As diferenças entre estas classificações são mais perceptíveis ao se observar os limites das regiões compostas por pixels associados à classe Telhado de Cerâmica. O resultado apresentado fornecido pelo método CaSVM, com uso do submodelo Translativo e estratégia OAA, é semelhante a classificação inicial, fornecida pelo método SVM. Matrizes de confusão referentes a cada uma das classificações realizadas são apresentadas no Apêndice E. Tais matrizes são computadas com uso de todos os pixels de validação quantificados na Tabela 4.6.


Neste terceiro e último estudo de caso foi apresentada mais uma aplicação dos métodos analisados em um problema de classificação multiclasse de imagem de Sensoriamento Remoto. O tipo de imagem adotada, a quantidade de classes e a análise na classificação de regiões pontuais diferem este do segundo estudo de caso.

Verificou-se, mais uma vez, que os métodos CaSVM, SVM+Moda e SVM+ICM fornecem resultados semelhantes, segundo os valores de acurácia global médio, computados segundo o procedimento adotado, sobre as amostras de validação selecionadas (Figura 4.29(b) e Tabela 4.6). Já avaliação baseada na classificação de regiões pontuais e nas bordas entre regiões, indicam superioridade do método CaSVM, com uso do submodelo Repulsivo.


Este estudo de caso ressaltou relações, não apontadas no segundo estudo de caso, entre as estratégias multiclasse e os submodelos de contextualização. Foi verificado que submodelo Repulsivo alcança resultados válidos, independentemente da estratégia multiclasse, enquanto o Translativo é mais adequado com uso da estratégia OAO.




(a) SVM.OAO




(b) SVM.OAA




(c) CaSVM.Rep.OAO(5 x 5)



(d) CaSVM.Tra.OAA(5 x 5)



(e) SVM+Moda.OAO(7 x 7)



(f) SVM+ICM

Figura 4.37 - Alguns resultados de classificação relevantes obtidos pelos diferentes métodos analisados. Legenda: ■ V.Alta ■ V.Baixa ■ Telha.(Cer.) ■ Telha.(Con.) ■ Solo.Exp. ■ Asfalto ■ Veículos





## 5 CONCLUSÕES E PERSPECTIVAS FUTURAS

Neste trabalho foi introduzido, desenvolvido e implementado um novo método contextual de classificação de imagens fundamentado no método SVM, denominado CaSVM. De maneira distinta de propostas já apresentadas na literatura, o método apresentado consiste em adaptar localmente o hiperplano de separação, originalmente obtido pelo método SVM, em função da informação contextual dos pixels. A informação contextual refere-se a classificações, inicialmente definidas pelo método SVM, e às *confiabilidades* associadas a estas classificações, com relação aos pixels definidos em uma vizinhança espacial. A interpretação da informação contextual, materializada em adaptações hiperplano de separação em função do contexto dos pixels, é determinada a partir dos denominados *submodelos de contextualização* e do conceito de *reprojeção*. Dois submodelos de contextualização foram apresentados: Repulsivo e Translativo. O conceito de reprojeção foi introduzido para que os hiperplanos adaptados fossem definidos em função de padrões de alta confiabilidade. Foi também necessária a investigação e desenvolvimento de métodos para estimação de um parâmetro ( $\lambda$ ) inserido nos submodelos de contextualização, responsável por ponderar a influência do contexto durante o processo de classificação contextual. Em virtude da formulação do método proposto, o uso de funções *kernel* está limitado àquelas cujo mapeamento dos atributos para espaços característicos possa ser realizado explicitamente, como é o caso do *kernel* Polinomial.

Baseado nas formalizações realizadas, foi desenvolvido um sistema de classificação de imagens, que contém a implementação dos métodos SVM, CaSVM e outros métodos contextuais baseados em SVM. Parte das funcionalidades deste sistema é baseada em uma pequena biblioteca de funções, com utilidade específica em classificação de imagens, desenvolvida ao longo deste trabalho.

A partir do sistema implementado, foram realizados três estudos de caso. O primeiro estudo de caso contemplou a aplicação dos métodos citados em problemas de classificação binária utilizando imagens sintéticas. No segundo e terceiro estudo de caso foram realizadas classificações multiclases utilizando imagens reais de Sensoriamento Remoto.

O objetivo destes estudos foi avaliar o método proposto a partir de comparações com o método SVM, com a aplicação de técnica de suavização sobre as classificações obtidas pelo SVM, a partir da aplicação do filtro da moda, e através da integração do método SVM ao algoritmo ICM. A comparação entre os diferentes métodos foi baseada na comparação entre os respectivos resultados de classificação. Os resultados

foram comparados através de percentuais de acurácia e intervalos de credibilidade. Além disso, foi proposta e empregada uma medida para avaliação de classificação em bordas de regiões, denominado por Coeficiente *Upsilon*.

Com base nos resultados obtidos foi verificado que o método CaSVM, com uso do submodelo Repulsivo, é capaz de produzir resultados de classificação semelhantes à de outros métodos contextuais baseados em SVM, quando a avaliação é fundamentada na quantidade de acertos de classificação observados no interior de alvos (cf. Figuras 4.12, 4.13, 4.23 e 4.32). No entanto, foi verificado que o método CaSVM apresenta capacidade de produzir classificações mais acuradas com relação a alvos pontuais e em bordas entre regiões de diferentes classes, quando comparado aos métodos contextuais considerados (cf. Figuras 4.14 a 4.16, Figuras 4.24 a 4.26 e Figuras 4.33 a 4.35).

Os resultados indicam ainda que quando o submodelo Translativo é empregado pelo CaSVM em problemas de classificação multiclasse, o uso da estratégia OAO torna-se preferível. Esta justificativa é fundamentada em características do submodelo Translativo e da regra de decisão que compreende a estratégia OAA: “...quando a estratégia OAA é empregada nos problemas multiclasse, a decisão de classificação é determinada em função da distância entre o padrão e um dos hiperplanos, que separa uma classe específica das demais. Com relação ao submodelo Translativo, a classificação contextual dos padrões é dada através de deslocamentos no hiperplano de separação, inicialmente definido pelo SVM, em função da informação contextual. Uma vez que este submodelo não oferece um tratamento sobre as relações de distância entre os padrões e os hiperplanos, após a realização dos deslocamentos, acredita-se que sua associação à estratégia OAA pode implicar, em alguns casos, em comportamentos indesejados.”

Foi verificada também, na maioria dos casos, uma relação direta entre o raio de influência da vizinhança na acurácia das classificações. A medida que este raio de influência aumenta, verifica-se maior homogeneização dos resultados de classificação, porém, ao custo da diminuição na acurácia de classificação em regiões pontuais e nas bordas entre regiões. Nestas condições, conclui-se que o uso de janela  $5 \times 5$  proporciona um equilíbrio entre homogeneização dos resultados e acurácia na classificação sobre regiões pontuais e em bordas.

Devido a maior complexidade do método CaSVM, principalmente com uso do submodelo Repulsivo, o tempo computacional apresentado por este método foi consideravelmente superior aos demais métodos analisados. A investigação de

estratégias computacionais para redução do custo computacional torna-se uma necessidade.

Pode-se concluir ainda que os submodelos de contextualização exercem papel fundamental no desempenho do CaSVM. Dentre os dois submodelos apresentados, o Repulsivo apresenta maior robustez. O submodelo Translativo é fortemente influenciado pela estratégia multiclasse adotada. O uso de vizinhança espacial (i.e., janela de contexto) com dimensão  $5 \times 5$  pixels apresentou resultados superiores aos obtidos com uso de janelas  $3 \times 3$  pixels, e similares aos obtidos com janelas  $7 \times 7$  pixels, na maioria dos casos analisados. Além disso, conclui-se também que o CaSVM é indicado para aplicações cujo objetivo é realizar classificações contextuais onde existe especial preocupação quanto a preservação de bordas e regiões pontuais, caso contrário, métodos como SVM+Moda e SVM+ICM podem ser adotados, uma vez que o custo computacional é consideravelmente menor.

Como sugestões para trabalhos futuros, são citadas:

- O desenvolvimento de novos submodelos de contextualização, visando o aumento da acurácia e a redução do custo computacional;
- Investigar a implementação paralela como forma de reduzir o tempo computacional;
- Verificar o comportamento do método desenvolvido usando outras estratégias multiclasse baseadas em decomposição binária;
- Desenvolver novas funções para *reprojeção* e investigar seus efeitos no desempenho do método CaSVM;
- Desvincular a inicialização do CaSVM, atualmente dada pelo método SVM, possibilitando tal inicialização por qualquer outro resultado de classificação. Com esta extensão, o método CaSVM torna-se genérico quanto à contextualização de qualquer resultado de classificação;
- Investigar novos métodos para estimação do parâmetro  $\lambda$ , uma vez que apenas três alternativas foram investigadas neste trabalho. O valor estimado pode implicar na qualidade dos resultados, logo, deve-se garantir um bom estimador de tal parâmetro;
- Desenvolver um quantificador para incertezas de classificação. Tal

quantificador pode ser baseado na distância entre os padrões classificados e o hiperplano de separação responsável pela classificação. Nota-se que este quantificador pode apresentar uma formulação específica para cada estratégia multiclases, quando adotada;

- Desenvolver uma medida de incerteza para o coeficiente *Upsilon*.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADOBE. **TIFF: Revision 6.0**. 1992. Acesso em 24 abr. 2013. Disponível em: <<http://partners.adobe.com/public/developer/en/tiff/TIFF6.pdf/>>. 116
- BESAG, J. On the statistical analysis of dirty pictures. **Journal of the Royal Statistical Society**, B-48, p. 259–302, 1986. 2, 18
- 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. 2
- BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. In: ANNUAL WORKSHOP ON COMPUTATIONAL LEARNING THEORY, 5., 1992, Pittsburgh. **Proceedings...** Pittsburgh: ACM Press, 1992. p. 144–152. ISBN 0-89791-497-X. 2
- BOVOLO, F.; BRUZZONE, L. A context-sensitive technique based on Support Vector Machines for image classification. Springer, Kolkata, v. 3776, p. 260–265, 2005. 3, 18, 43
- BOVOLO, F.; BRUZZONE, L.; MARCONCINI, M. A novel context-sensitive SVM for classification of remote sensing images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2006, Denver. **Proceedings...** Denver: IEEE, 2006. p. 2498–2501. ISBN 0-7803-9510-7. 3, 18
- BRUZZONE, L.; PERSELLO, C. A novel context-sensitive semisupervised SVM classifier robust to mislabeled training samples. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 7, p. 2142–2154, 2009. 3, 17, 18, 35
- CHANG, C.; LIN, C. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, p. 1–27, 2011. 51
- CHESNEL, A.; BINET, R.; WALD, L. Object oriented assessment of damage due to natural disaster using very high resolution images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2007, Barcelona. **Proceedings...** Barcelona: IEEE, 2007. p. 3736–3739. ISBN 978-1-4244-1211-2. 1
- CORTIJO, F. J.; BLANCA, N. P. Improving classical contextual classifications. **International Journal of Remote Sensing**, v. 19, n. 8, p. 1591–1613, 1998. 2

EXELIS. **Exelis: visual information solutions**. 2012. Acesso em 17 abr. 2013. Disponível em: <<http://www.exelisvis.com/>>. 115

FREITAS, C. C.; SOLER, L.; SANT'ANNA, S. J. S.; DUTRA, L. V.; SANTOS, J. R.; MURA, J. C.; CORREIA, A. H. Land use and land cover mapping in the Brazilian Amazon using polarimetric airborne P-Band SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 10, p. 2956–2970, 2008. 1

FRIEDRICHS, F.; IGEL, C. Evolutionary tuning of multiple SVM parameters. **Neurocomputing**, v. 64, p. 107–117, 2005. ISSN 09252312. 49

GEMAN, S.; GEMAN, D. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 6, n. 6, p. 721–741, 1984. 18

GURRAM, P.; KWON, H. Contextual SVM using Hilbert space embedding for hyperspectral classification. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 5, p. 1031–1034, 2013. 3, 19

HAMEL, L. Visualization of Support Vector Machines with unsupervised learning. In: SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE IN BIOINFORMATICS AND COMPUTATIONAL BIOLOGY, 2006, Toronto. **Proceedings...** Toronto: IEEE, 2006. p. 1–8. ISBN 1-4244-0623-4. 17

HSU, C.; CHANG, C.; LIN, C. **A practical guide to support vector classification**. Taiwan: [s.n.], 2010. Relatório técnico. 49, 50

HSU, C.; LIN, C. A comparison of methods for multiclass Support Vector Machines. **IEEE Transactions on Neural Networks**, v. 13, n. 2, p. 415–425, 2002. 15

JOACHIMS, T. Making large-scale Support Vector Machine learning practical. In: SCHÖLKOPF, B.; BURGESS, C. J. C.; SMOLA, A. J. (Ed.). Cambridge: MIT Press, 1999. p. 169–184. ISBN 0-262-19416-3. *Advances in Kernel Methods*. 51, 122

KASANKO, M.; SAGRIS, V.; LAVALLE, C.; BARREDO, J. I.; PETROV, L.; STEINNOCHER, K.; LOIBL, W.; HOFFMANN, C. GEOLAND spatial planning observatory: How remote sensing data can serve the needs of urban and regional planning. In: URBAN REMOTE SENSING JOINT EVENT, 2007., 1997, Paris.

**Proceedings...** Paris: IEEE, 2007. p. 1–10. ISBN 1-4244-0712-5. 1

KAVZOGLU, T. T.; COLKESEN, I. A kernel functions analysis for Support Vector Machines for land cover classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 11, n. 5, p. 352–359, 2009. 14

KEERTHI, S. Efficient tuning of SVM hyperparameters using radius/margin bound and iterative algorithms. **IEEE Transactions on Neural Networks**, v. 13, n. 5, p. 1225–1229, 2002. 49

KHEDAM, R.; BELHADJ-AISSA, A.; RANCHIN, T. Study of ICM parameters influence on images satellite contextual classification. In: GEOINFORMATION FOR EUROPEAN-WIDE INTEGRATION, 12., 2003, Prague. **Proceedings...** Prague: EARSEL, 2002. p. 79–85. ISBN 90-77017-71-2. 1, 20

KHODADADZADEH, M.; GHASSEMIAN, H. Contextual classification of hyperspectral remote sensing images using SVM-PLR. **Journal of Applied Sciences Research**, v. 7, p. 374–382, 2011. 3, 18

KIYASU, S.; YAMADA, Y.; MIYAHARA, S. Semi-supervised land cover classification of remotely sensed data using two different types of classifiers. In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND SYSTEMS, 2009, Fukuoka. **Proceedings...** Fukuoka: SICE, 2009. p. 4874–4877. ISBN 978-4-907764-34-0. 1

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 14., 1995, Montreal. **Proceedings...** San Francisco: Morgan Kaufmann Publishers Inc., 1995. v. 2, p. 1137–1143. ISBN 1-55860-363-8. 49, 50

LI, C.; KUO, B.; LIN, C.; HUANG, C. A spatial-contextual Support Vector Machine for remotely sensed image classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 3, p. 784–799, 2012. 3, 18

LI, K.; TENG, G. Unsupervised svm based on p-kernels for anomaly detection. In: INTERNATIONAL CONFERENCE ON INNOVATIVE COMPUTING, INFORMATION AND CONTROL, 1., 2006, Beijing. **Proceedings...** Washington: IEEE, 2006. v. 2, p. 59–62. ISBN 0-7695-2616-0. 17

- LI, S.; TAN, M. Tuning SVM parameters by using a hybrid CLPSO-BFGS algorithm. **Neurocomputing**, v. 73, n. 10, p. 2089–2096, 2010. ISSN 0925-2312. 49
- LI, S.; ZHANG, B.; CHEN, D.; GAO, L.; PENG, M. Adaptive Support Vector Machine and Markov Random Field model for classifying hyperspectral imagery. **Journal of Applied Remote Sensing**, v. 5, n. 1, p. 1–11, 2011. 3, 18
- LIN, H.; LIN, C.; WENG, R. C. A note on Platt's probabilistic outputs for support vector machines. **Machine Learning**, v. 68, n. 3, p. 267–276, 2007. 18, 21, 22
- LIN, S.; LEE, Z.; CHEN, S.; TSENG, T. Parameter determination of Support Vector Machine and feature selection using simulated annealing approach. **Applied Software Computing**, v. 8, n. 4, p. 1505–1512, 2008. 49
- MARROQUIN, J.; MITTER, S.; POGGIO, T. **Probabilistic solution of ill-posed problems in computational vision**. Cambridge: Massachusetts Institute of Technology, 1987. Relatório técnico. 18
- MOOD, A. M.; BOES, D. C.; GRAYBILL, F. A. **Introduction to the theory of statistics**. 3th. ed. [S.l.]: McGraw-Hill, 1974. 564 p. ISBN 0070854653. 54
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support Vector Machines in Remote Sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing Society**, v. 66, n. 3, p. 247–259, 2011. 3, 17
- NEGRI, R. G.; DUTRA, L. V.; SANT'ANNA, S. J. S. Support Vector Machine and Bhattacharyya kernel function for regionbased classification. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2012, Munich. **Proceedings...** Munich: IEEE, 2012. p. 5422–5425. 17
- NEGRI, R. G.; SANT'ANNA, S. J. S.; DUTRA, L. V. Aplicação de modelos de aprendizado semissupervisionado na classificação de imagens de sensoriamento remoto. **Revista de Informática Teórica e Aplicada**, v. 20, n. 2, p. 32–55, 2013. ISSN 2175-2745. 17
- NIEDERMEIER, A.; LEHNER, S.; SANDEN, J. Monitoring big river estuaries using SAR images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2001, Sydney. **Proceedings...** Sydney: IEEE, 2001. v. 4, p. 1756–1758. ISBN 0-7803-7031-7. 1



PANTALEAO, E. **Análise de cenários para classificação de dados de sensoriamento remoto usando otimização multiobjetivo e hierarquia de classes**. 85 p. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. 115

PIRES, R. M. **Inferência bayesiana objetiva e frequentista para a probabilidade de sucesso**. 269 p. Dissertação (Mestrado) — Universidade Federal de São Carlos, São Carlos, 2009. 54

PLATT, J. C. **Sequential minimal optimization: A fast algorithm for training Support Vector Machines**. [S.l.: s.n.], 1998. 21 p. Technical Report MSR-TR-98-14. 51

\_\_\_\_\_. Probabilistic outputs for Support Vector Machines and comparisons to regularized likelihood methods. In: SMOLA, A.; BARTLETT, P.; SCHÖELKOPF, B.; SCHUURMANS, D. (Ed.). Cambridge: MIT Press, 2000. p. 61–74. ISBN 9780262194488. *Advances in Large Margin Classifiers*. 18, 21

POWELL, M. On the quadratic programming algorithm of Goldfarb and Idnani. **Mathematical Programming Study**, n. 25, p. 46–61, 1985. 52

RSI. **ENVI User's Guide**. Boulder: Research Systems Incorporated, 2004. 116

SANTOS, R. D. C. **Java Image Processing Cookbook**. 2013. Acesso em 2 mai. 2013. Disponível em: <<http://www.lac.inpe.br/JIPCookbook/>>. 87

SHIMABUKURO, Y. E.; ALMEIDA-FILHO, R.; KUPLICH, T. M.; FREITAS, R. M. Mapping and monitoring land cover in Corumbiara area, Brazilian Amazonia, using JERS-1 SAR multitemporal data. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2007, Barcelona. **Proceedings...** Barcelona: IEEE, 2007. p. 3370–3373. ISBN 978-1-4244-1211-2. 1

STALLINGS, C.; KHORRAM, S.; HUFFMAN, R. Incorporating ancillary data into a logical filter for classified satellite imagery. **Geocarto International**, v. 14, n. 2, p. 41–50, 1999. 22

SUN, J. Fast tuning of SVM kernel parameter using distance between two classes. In: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM AND KNOWLEDGE ENGINEERING, 2008, Xiamen. **Proceedings...** Xiamen: IEEE,

2008. v. 1, p. 108–113. ISBN 978-1-4244-2196-1. 49

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4th. ed. San Diego: Academic Press, 2008. 984 p. ISBN 9781597492720. 7, 14

TZOTSOS, A. A support vector machine approach for object based image analysis. In: ISPRS INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 2006, Salzburg. **Proceedings**. Salzburg: ISPRS, 2006. 17

VEMPATI, S.; VEDALDI, A.; ZISSERMAN, A.; JAWAHAR, C. V. Generalized RBF feature maps for efficient detection. In: BRITISH MACHINE VISION CONFERENCE, 2010, Aberystwyth. **Proceedings...** Aberystwyth: BMVA Press, 2010. p. 1–11. ISBN 1-901725-40-5. 42

VIEIRA, P. R. **Desenvolvimento de Classificadores de Máxima Verossimilhança e ICM para Imagens SAR**. 251 p. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1996. 21

WEBB, A. R. **Statistical Pattern Recognition**. 2nd. ed. Chichester: John Wiley & Sons, 2002. 514 p. 8, 15

WHITEHEAD, K.; MOORMAN, B.; WAINSTEIN, P. Determination of variations in glacier surface movements through high resolution interferometry: Bylot Island, Canada. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2009, Cape Town. **Proceedings...** Cape Town: IEEE, 2009. v. 2, p. 230–233. ISBN 978-1-4244-3394-0. 1

XU, L.; SCHUURMANS, D. Unsupervised and semi-supervised multi-class Support Vector Machines. In: CONFERENCE ON ARTIFICIAL INTELLIGENCE, 20., 2005, Pittsburgh. **Proceedings...** Pittsburgh: AAAI Press, 2005. p. 904–910. ISBN 1-57735-236-x. 17

ZEE BR-163. **Zoneamento ecológico-econômico da rodovia BR-163**. 2011. Acesso em 12 dez. 2011. Disponível em: <<http://zeebr163.cpatu.embrapa.br>>. 45

ZHU, Y.; LI, C.; ZHANG, Y. A practical parameters selection method for SVM. In: **International Symposium on Neural Networks**. Dalian: Springer, 2004. (Lecture Notes in Computer Science, v. 3173), p. 518–523. ISBN 3-540-22841-1. 49

ZORTEA, M.; MARTINO, M. D.; SERPICO, S. A SVM ensemble approach for

spectral-contextual classification of optical high spatial resolution imagery. In:  
IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING  
SYMPOSIUM, 2007, Barcelona. **Proceedings...** Barcelona, 2007. p. 1489–1492.  
ISBN 978-1-4244-1211-2. 3



## APÊNDICE A - MEDIDA PARA AVALIAÇÃO DE CLASSIFICAÇÃO EM BORDAS

Uma forma alternativa de avaliar resultados de classificação é através da quantificação da acurácia nas bordas de objetos (regiões) da imagem classificada. Este apêndice introduz uma medida de quantificação de acurácia em bordas. A motivação da medida, denominada Coeficiente *Upsilon* ( $\Upsilon$ ), é quantificar não só a quantidade de pixels classificados corretamente nas bordas, como também a fidelidade com relação à posição das bordas nos resultados de classificação.

O termo “bordas” é definido como a transição entre duas classes temáticas. Pixels localizados em bordas correspondem aos pixels que compõem a região de uma dada classe e possuem algum pixel vizinho que faz parte de outra região, relativa a outra classe. Baseado nesta definição, um *conjunto de pixels de borda* é composto por pixels associados a duas classes diferentes e estão localizados nas bordas entre tais classes.

O desenvolvimento da medida de avaliação parte de um resultado de classificação e de um conjunto de pixels de borda, composto por  $z_1$  pixels referentes a uma dada classe  $\omega_1$  e  $z_2$  pixels referentes a  $\omega_2$ . São denotados por  $v_1$  e  $v_2$  a quantidade de elementos do conjunto de pixels de borda classificados corretamente, com relação as classes  $\omega_1$  e  $\omega_2$ , respectivamente. Por sua vez,  $\bar{v}_1$  e  $\bar{v}_2$  representam as quantidades classificadas incorretamente, com relação às classes  $\omega_1$  e  $\omega_2$ , respectivamente, tal que  $\bar{v}_1 = z_1 - v_1$  e  $\bar{v}_2 = z_2 - v_2$ . Baseado nestas quantidades, é formulada a seguinte expressão:


$$\Upsilon = \frac{\left(1 - \frac{\bar{v}_1}{z_1}\right) \cdot \left(1 - \frac{\bar{v}_2}{z_2}\right) \cdot (v_1 + v_2)}{z_1 + z_2}. \quad (\text{A.1})$$

Na expressão (A.1) os fatores  $\left(1 - \frac{\bar{v}_1}{z_1}\right)$  e  $\left(1 - \frac{\bar{v}_2}{z_2}\right)$  atuam como ponderadores no cálculo da medida, fazendo com que ao aumentar o número de classificações incorretas, seja com relação a classe  $\omega_1$  ou  $\omega_2$ , menor será o valor de  $\Upsilon$ . Em termos práticos, estes fatores impedem que o valor resultante de  $\Upsilon$  possa depender apenas do percentual de classificações corretas em  $\omega_1$  ou  $\omega_2$ .


Com algumas manipulações algébricas em (A.1) é obtida a seguinte expressão equivalente, em função apenas dos valores  $z_1$ ,  $z_2$ ,  $v_1$  e  $v_2$ :

$$\Upsilon = \frac{v_1 \cdot v_2 \cdot (v_1 + v_2)}{z_1 \cdot z_2 \cdot (z_1 + z_2)} \quad (\text{A.2})$$

Na Figura A.1 são mostrados dois gráficos que ilustram o comportamento do Coeficiente Upsilon em função de diferentes valores de  $v_1$  e  $v_2$ , para  $z_1$  e  $z_2$  ambos iguais a 1000. É possível verificar na Figura A.1(a) que  $\Upsilon \rightarrow 0$  quando  $v_1 \rightarrow 0$  ou  $v_2 \rightarrow 0$ ; por outro lado,  $\Upsilon \rightarrow 1$  quando  $v_1 \rightarrow z_1$  e  $v_2 \rightarrow z_2$ , simultaneamente. O gráfico da Figura A.1(b) é uma representação da superfície apresentada na Figura A.1(a), na forma de curvas de nível.



(a) Comportamento do índice Upsilon



(b) Comportamento do índice Upsilon representado em curvas de nível

Figura A.1 - Gráfico do coeficiente *Upsilon*, considerando dois conjuntos com 1000 pixels em cada classe.

## APÊNDICE B - IMPLEMENTAÇÕES

Visando validar o método CaSVM, formalizado no Capítulo 3, no Capítulo 4 são apresentados estudos onde o método proposto, e outros métodos presentes na literatura, adotados como referencial, são aplicados em problemas práticos de classificação de imagens. Antecedendo a realização destes estudos, foi necessária a implementação computacional do método proposto e dos demais métodos considerados.

De modo geral, as implementações realizadas estão organizadas em dois grupos. O primeiro grupo de implementações consistem em uma biblioteca com funções de uso comum pelos métodos de classificação de imagem. O segundo grupo de implementações refere-se a um sistema, munido de interface com usuário, que gerencia diferentes métodos de classificação e funções de pré e pós-processamento de imagens. Este sistema faz uso da biblioteca de funções que compõe o primeiro grupo.

As implementações fizeram uso da linguagem de programação IDL (*Interactive Data Language*) (EXELIS, 2012), versão 7.1. Esta linguagem apresenta vantagens nas aplicações em processamento de imagens, pois, além de oferecer as ferramentas básicas de programação, como diferentes tipos numéricos, vetoriais, *strings*, ponteiros, estruturas de controle, seleção e repetição; ela oferece também diferentes funções para manipulação de matrizes e vetores, geração de gráficos, *etc* (PANTALEAO, 2012).

Na Seção B.1 é apresentada uma organização geral da biblioteca desenvolvida. Na Seção B.2 são descritas, a partir de sua interface, as funcionalidades do sistema implementado.

### B.1 Biblioteca de funções para classificação de imagens

A biblioteca desenvolvida, denominada SLIC (*Small Library for Image Classification*), é composta por funções de uso comum em diferentes etapas que envolvem os procedimentos de classificação de imagens. A Figura B.1 apresenta uma organização desta biblioteca em módulos e suas principais finalidades.

Antes de discutir sobre os diferentes módulos desta biblioteca, é conveniente especificar os padrões a respeito dos dados de entrada. Os dados de entrada referem-se às imagens e ROIs utilizados no processo de treinamento e/ou validação.

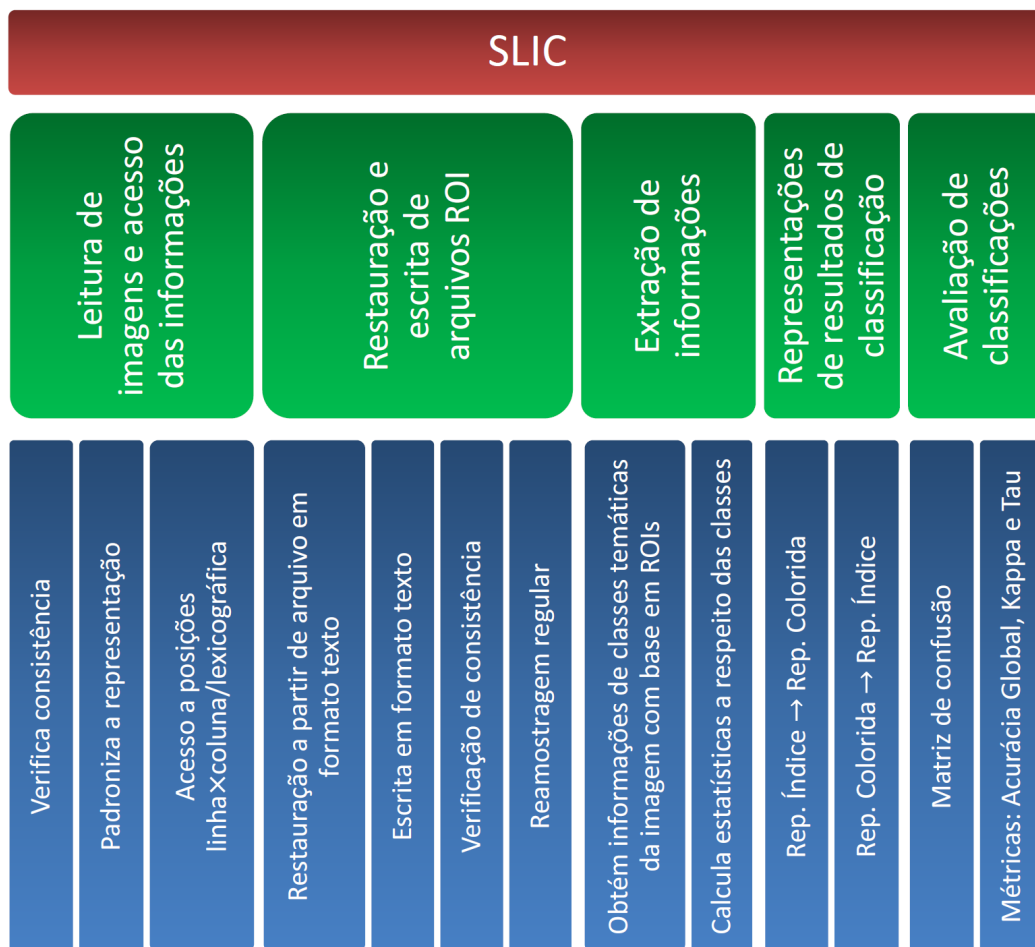


Figura B.1 - Organização das funções da biblioteca desenvolvida, segundo suas finalidades.

As imagens de entrada devem estar em formato TIFF (*Tagged Image File Format*) (ADOBE, 1992) e com codificação BSQ (*Band Sequential*). Imagens complexas não são suportadas.

A sigla ROI refere-se a “Regiões de Interesse” (*Regions of Interest*). Os ROIs correspondem a amostras de classes temáticas identificadas nas imagens e que são utilizados na composição dos conjuntos de treinamento e de validação. Um “arquivo ROI” tem como finalidade armazenar diferentes amostras, sejam elas de classes distintas ou não. Uma forma conveniente de armazenar ROIs é utilizando arquivos de texto e a estrutura adotada pelo *software* ENVI (RSI, 2004) para sua construção. Neste arquivo os pixels são identificados apenas pela sua posição lexicográfica na imagem.

As funções do módulo *leitura de imagens e acesso das informações* possibilitam



verificar se uma dada imagem encontra-se nos padrões esperados pelas demais funções da biblioteca. Caso a imagem em processo de leitura esteja fora dos padrões, existem funções disponíveis neste módulo que possibilitam padronizá-la no formato esperado. Outras funções deste módulo permitem o acesso a posições específicas da imagem, através de índices lexicográficos ou matriciais dos pixels.

O segundo módulo corresponde às funções de *restauração e escrita de arquivos ROI*. A restauração de um arquivo ROI em formato texto consiste em interpretar as informações deste arquivo e armazená-las em variáveis segundo uma estrutura definida. A escrita em formato texto consiste no processo inverso, ou seja, o conteúdo armazenado nas estruturas que representam às ROIs é escrito em arquivo de texto, seguindo os padrões adotados. São ainda disponíveis funções para verificação de consistência dos arquivos ROI e para realização de reamostragem regular sobre os mesmos.

Informações a respeito de classes temáticas identificadas nas imagens, através de ROIs, podem ser extraídas fazendo uso das funções que compõem o módulo *extração de informações*. O principal objetivo das funções deste módulo é a organização das informações para treinamento de métodos de classificação supervisionada.

Os resultados de classificação são usualmente representados na forma de mapas de classes ou mapas de índices. Nos mapas de classe os pixels são coloridos de acordo com uma cor associada às suas classificações, enquanto no mapa de índices os pixels são representados por um índice associado a cada classe. De modo geral, os mapas de classes são empregados na representação visual dos resultados de classificação, enquanto os mapas de índice, em análises qualitativas dos resultados. O módulo *representação de resultados de classificação* fornece funções que permitem o intercâmbio entre as diferentes formas de representação de classificação mencionadas.

Por fim, a avaliação dos resultados de classificação pode ser realizada a partir de matrizes de confusão ou medidas de acurácia, como os índices de acerto global, *kappa* e *tau*. No módulo *avaliação de classificações* são disponibilizadas funções para cálculo da matriz de confusão e das medidas de acurácia mencionadas.

O código-fonte e documentação desta biblioteca encontram-se disponíveis em <http://www.rgnegri.com/desc-siclib>.

## B.2 Descrição do sistema desenvolvido

O sistema implementado, denominado por *Contextual SVM Classification Suite* (Suíte de Classificação Contextual SVM), possui suas funcionalidades organizadas em quatro segmentos:

- entrada e saída de dados;
- seleção dos métodos de classificação e respectivos parâmetros;
- execução do método *Grid Search* para auxílio na seleção de parâmetros para o treinamento do método SVM;
- definição de ajustes gerais, que abrangem a seleção de métodos para resolução do problema de otimização (2.12), parâmetros dos métodos de otimização e seleção da heurística para estimação do parâmetro  $\lambda$  do método CaSVM.

O primeiro segmento mencionado, onde é definida a entrada e saída de dados, é ilustrado na Figura B.2. Os índices identificados nesta figura apresentam as seguintes finalidades:

1. Este menu possibilita a seleção da imagem para classificação (em *File*), a qual deve estar em formato TIFF. Na opção (*ROI*) encontram-se as opções para seleção e edição de amostras, sobre a imagem selecionada, assim como a leitura de arquivos com amostras utilizadas nos processos de treinamento e validação dos resultados;
2. Esta tela exibe a imagem selecionada (através da opção *File*) assim como as respectivas amostras de treinamento (polígonos cheios) e validação (polígonos hachurados), selecionados a partir da opção *ROI*;
3. Este botão fornece uma ferramenta para realizar um recorte sobre a imagem selecionada pela opção *File*, assim como selecionar um subconjunto menor de bandas. Após a edição da imagem, o resultado gerado pode ser salvo em disco;
4. Possibilita a seleção de um subconjunto de classes, baseado nos arquivos de amostras selecionados em *ROI*, para uso no processo de classificação;

5. Apresenta as informações a respeito das classes, recuperadas a partir do arquivo de amostras selecionado em *ROI*. Estas informações abrangem o nome, a cor e a quantidade total de pixels referentes a cada uma das classes;
6. Permite selecionar um subconjunto de bandas, da imagem selecionada, e considerá-lo no processo de classificação;
7. Esta tabela apresenta estatísticas (valores mínimo e máximo, média e desvio padrão) a respeito de cada banda da imagem selecionada;
8. Dimensões da imagem selecionada;
9. Botão para seleção de diretório onde serão armazenados os resultados do processo de classificação.

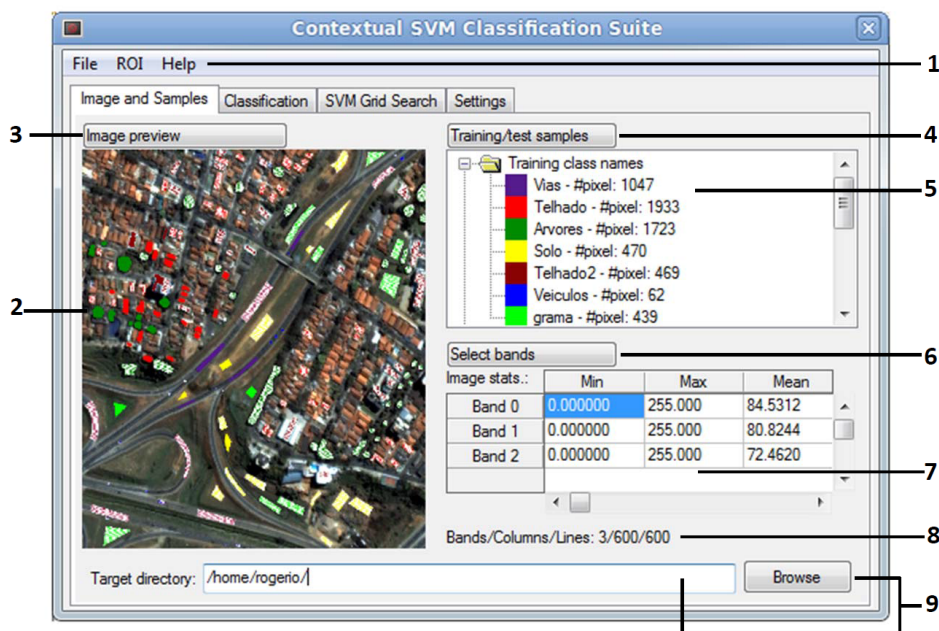


Figura B.2 - Aba principal: informações sobre a imagem e amostras utilizadas no processo de classificação.

A seleção dos diferentes métodos de classificação disponíveis é feita a partir do segundo segmento, ilustrado na Figura B.3. Os índices denotados nesta figura possuem as seguintes finalidades:

10. Possibilita a seleção das funções kernel linear e polinomial, assim como o valor para o parâmetro penalidade ( $C$ ) e o grau ( $q$ ) do *kernel* polinomial,

caso esta função tenha sido selecionada;

11. Permite a seleção entre as estratégias multiclasse OAA e OAO.
12. Campo para definição de opções e parâmetros específicos aos diferentes métodos de classificação contextual baseado em SVM, implementados neste sistema;
13. Quando selecionado, faz com que resultados intermediários (por exemplo, gráficos com estimação do parâmetro  $\lambda$ , resultados das iterações do método ICM e resultados de classificação de subproblemas binários) sejam salvos;
14. Exibe resultados intermediários e final obtido pelo processo de classificação;
15. Permite a adição de um prefixo ao nome dos arquivos produzidos pelo processo de classificação;
16. Utilizado para seleção do método de classificação desejado;
17. Inicia o processo de classificação.

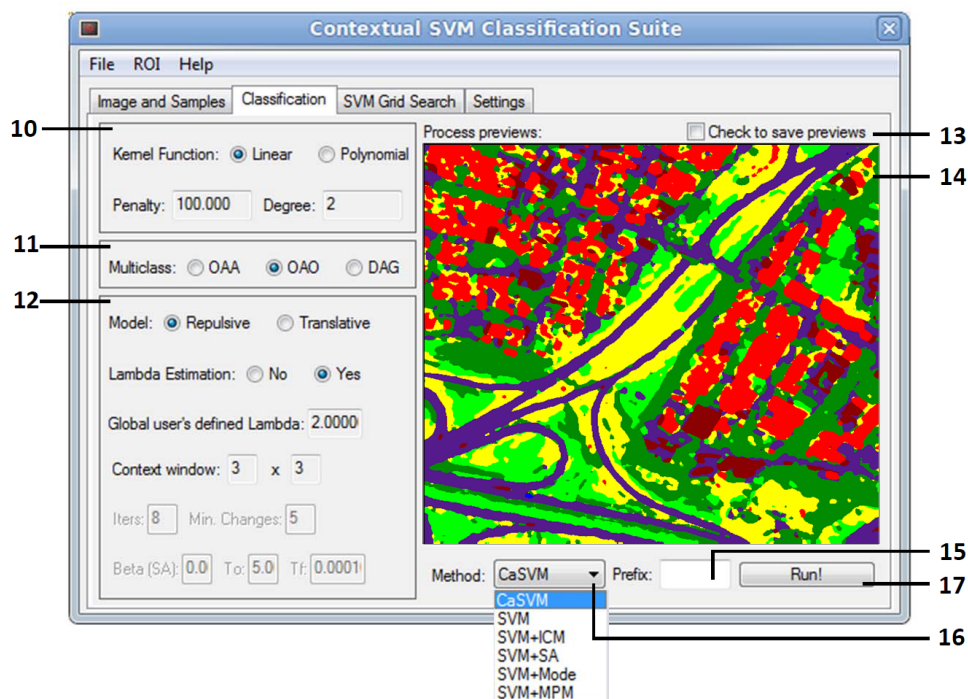


Figura B.3 - Interface de seleção do método de classificação e ajuste dos respectivos parâmetros.

O procedimento *Grid Search*, que atua como ferramenta no auxílio da seleção dos parâmetros do método SVM, é oferecido no terceiro segmento. Segundo os índices identificados:

18. Campo geral para seleção da função *kernel* e da estratégia multiclasse, utilizadas no procedimento *Grid Search*. É possível ainda analisar a variação do parâmetro penalidade ( $C$ ) em escala linear ou logarítmica, definir o intervalo e o passo de discretização dos parâmetros  $C$  e  $q$ , e determinar a quantidade de validações cruzadas;
19. Exibe gráficos com os resultados do procedimento *Grid Search*;
20. Dispara a execução do procedimento *Grid Search*;
21. Abre uma janela de diálogo para salvar os resultados gráficos do procedimento *Grid Search*;
22. Abre uma janela de diálogo para salvar os resultados numéricos do procedimento *Grid Search*.

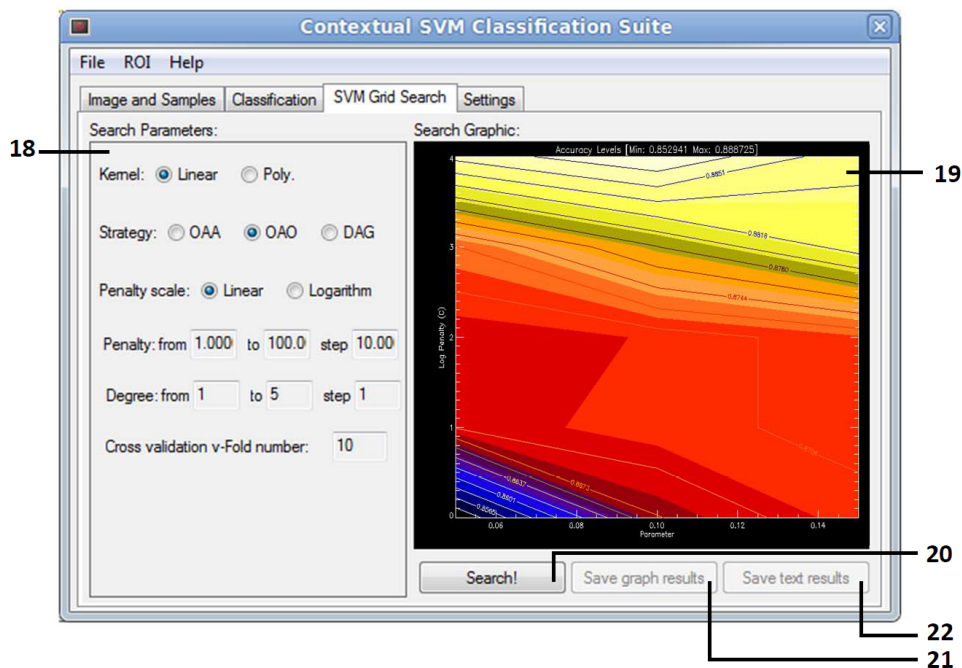


Figura B.4 - Definição dos parâmetros para execução do procedimento *Grid Search*.

O último segmento compreende opções gerais que podem ser alteradas no sistema implementado.

23. Possibilita a escolha do método de otimização responsável pela resolução do problema (2.12). É permitido ainda definir o método que será utilizado na resolução de problemas envolvendo um numero grande de padrões de treinamento, ou nos casos que envolvem pequenas quantidades, como durante o cálculo dos hiperplanos locais pelo método CaSVM com uso do modelo Repulsivo;
24. Valor de precisão, utilizado nos diferentes métodos considerados para resolução de (2.12);
25. Parâmetros exigidos pelo método  $SVM^{Light}$  (JOACHIMS, 1999);
26. Permite o uso de uma heurística implementada no método  $SVM^{Light}$  (JOACHIMS, 1999). O objetivo desta heurística é diminuir, em alguns casos, o tempo de otimização exigido;
27. Disponibiliza a escolha do método para estimação do parâmetro  $\lambda$ , exigido pelo CaSVM.

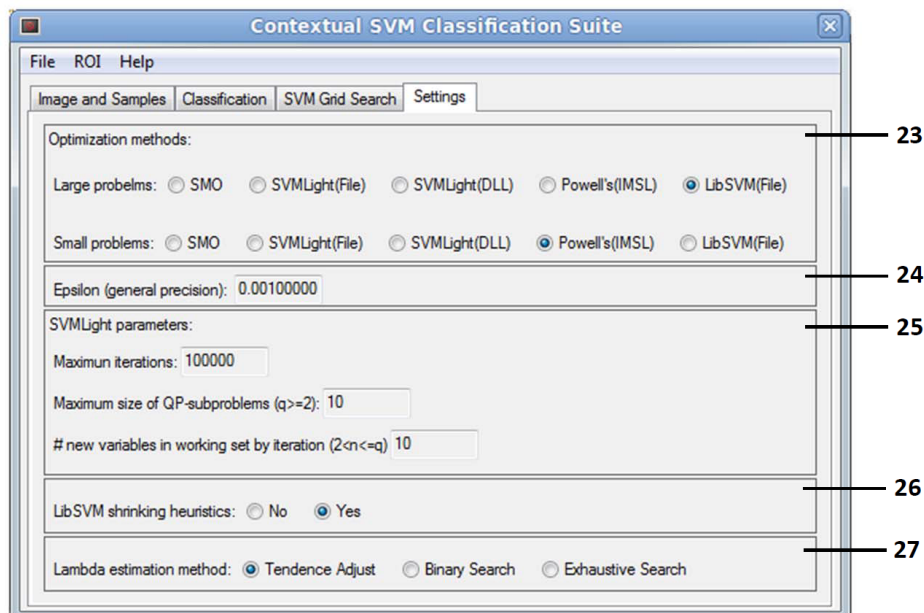


Figura B.5 - Opções gerais de processamento: seleção dos métodos de otimização, responsáveis pela resolução do problema (2.12), e estimação de  $\lambda$ .

## APÊNDICE C - ESTATÍSTICAS DO ESTUDO DE CASO I

Tabela C.1 - Médias e respectivos valores mínimos e máximos, entre parênteses, a respeito do tempo computacional despendido pelos métodos analisados.

Padrões	SMO	SVM <sup>Light</sup>	LibSVM	QP
Baixo	10	0,002(0,001~0,072)	0,023(0,023~0,026)	0,001(0~0,001)
	25	0,037(0,007~0,728)	0,025(0,024~0,028)	0,001(0~0,003)
	50	0,205(0,052~5,159)	0,025(0,024~0,029)	0,002(0,002~0,016)
	100	1,454(0,294~72,724)	0,027(0,026~0,039)	0,014(0,012~0,142)
	250	25,99(4,37~646,467)	0,035(0,033~0,052)	0,129(0,112~1,002)
	500	201,174(34,265~1733,888)	0,034(0,007~0,717)	0,911(0,78~21,671)
	1000	1048,357(173,456~2973,646)	0,234(0,015~2,746)	18,288(16,552~554,721)
	2500		0,363(0,063~5,709)	505,062(380,391~538,606)
	5000		1,154(0,219~1,123)	
				0,58(0,546~0,655)
Médio	10	0,002(0,001~0,073)	0,024(0,023~0,027)	0,001(0~0,001)
	25	0,029(0,007~0,79)	0,026(0,023~0,029)	0,001(0~0,004)
	50	0,198(0,043~3,205)	0,026(0,024~0,037)	0,003(0,002~0,016)
	100	1,273(0,269~79,451)	0,027(0,026~0,038)	0,014(0,013~0,169)
	250	22,642(2,42~210,607)	0,034(0,032~0,05)	0,152(0,134~1,089)
	500	125,577(20,791~1211,951)	0,06(0,007~0,422)	0,994(0,899~20,317)
	1000	514,913(89,422~844,087)	0,081(0,014~1,214)	19,31(18,316~641,27)
	2500		0,234(0,046~1,03)	512,913(371,861~592,941)
	5000		0,744(0,172~6,116)	
				0,453(0,437~0,468)
Alto	10	0,005(0,001~0,129)	0,024(0,022~0,028)	0(0~0,001)
	25	0,043(0,007~0,448)	0,026(0,025~0,03)	0,001(0~0,004)
	50	0,227(0,027~8,234)	0,028(0,027~0,034)	0,003(0,003~0,017)
	100	2,03(0,159~33,053)	0,032(0,031~0,05)	0,016(0,014~0,178)
	250	10,79(2,06~43,126)	0,071(0,029~0,378)	0,173(0,157~2,314)
	500	26,773(6,154~146,428)	0,172(0,066~0,375)	1,35(1,143~47,093)
	1000	74,709(10,836~236,203)	0,25(0,146~1,024)	24,494(14,264~264,654)
	2500		0,61(0,468~1,638)	255,652(249,46~258,804)
	5000		1,172(0,92~1,591)	
				0,659(0,639~0,671)

Contraste

Nas Tabelas C.8 a C.12 são apresentadas as frequência observada, a partir de comparações pareadas, segundo os resultados de classificação de cada uma das imagens simuladas. Os métodos listados na primeira coluna destas tabelas são comparados aos métodos dispostos entre a segunda e quinta coluna. Usa-se o símbolo

Tabela C.2 - Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia de classificação no interior das regiões largas, com relação às imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	0,725(0,695~0,751)	0,814(0,789~0,836)	0,892(0,872~0,909)
CaSVM.Rep	0,903(0,871~0,934)	0,972(0,955~0,984)	0,989(0,974~0,996)
CaSVM.Tra	0,835(0,799~0,868)	0,863(0,846~0,875)	0,931(0,916~0,938)
SVM+Moda	0,921(0,882~0,954)	0,983(0,964~0,994)	0,999(0,994~1,000)
SVM+ICM	0,994(0,963~1,000)	0,999(0,990~1,000)	1,000(0,998~1,000)

Tabela C.3 - Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia de classificação no interior das regiões finas, com relação às imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	0,767(0,688~0,838)	0,840(0,764~0,898)	0,881(0,826~0,933)
CaSVM.Rep	0,904(0,807~0,952)	0,976(0,931~0,998)	0,990(0,952~1,000)
CaSVM.Tra	0,860(0,760~0,924)	0,902(0,840~0,940)	0,925(0,884~0,951)
SVM+Moda	0,964(0,893~0,998)	0,993(0,962~1,000)	1,000(0,979~1,000)
SVM+ICM	0,917(0,705~1,000)	0,988(0,929~1,000)	0,998(0,969~1,000)

Tabela C.4 - Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito do coeficiente *Upsilon* dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	0,723(0,695~0,756)	0,812(0,782~0,836)	0,892(0,870~0,911)
CaSVM.Rep	0,825(0,796~0,852)	0,893(0,855~0,914)	0,950(0,932~0,967)
CaSVM.Tra	0,772(0,743~0,803)	0,857(0,824~0,878)	0,924(0,906~0,939)
SVM+Moda	0,721(0,675~0,759)	0,813(0,774~0,843)	0,892(0,862~0,915)
SVM+ICM	0,789(0,710~0,835)	0,867(0,835~0,890)	0,927(0,892~0,942)

(-) para identificar que o método cujo nome está na primeira coluna é superior na comparação realizada, caso contrário, é adotado o símbolo (+).



Tabela C.5 - Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito do coeficiente *Upsilon* dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	0,721(0,690~0,748)	0,811(0,776~0,837)	0,892(0,869~0,910)
CaSVM.Rep	0,750(0,715~0,781)	0,851(0,814~0,878)	0,929(0,907~0,948)
CaSVM.Tra	0,743(0,715~0,773)	0,835(0,807~0,864)	0,911(0,886~0,931)
SVM+Moda	0,664(0,618~0,700)	0,755(0,702~0,787)	0,848(0,815~0,882)
SVM+ICM	0,705(0,635~0,779)	0,808(0,758~0,843)	0,837(0,799~0,863)

Tabela C.6 - Medianas e respectivos valores mínimos e máximos, entre parênteses, a respeito da acurácia da classificação nas regiões pontuais, com relação às imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	0,766(0,668~0,836)	0,842(0,760~0,914)	0,882(0,819~0,944)
CaSVM.Rep	0,700(0,549~0,855)	0,743(0,598~0,900)	0,946(0,802~1,000)
CaSVM.Tra	0,503(0,332~0,651)	0,618(0,474~0,757)	0,783(0,668~0,882)
SVM+Moda	0,359(0,197~0,510)	0,243(0,141~0,395)	0,112(0,043~0,234)
SVM+ICM	0,046(0,000~0,201)	0,072(0,000~0,283)	0,151(0,000~0,438)

Tabela C.7 - Médias e respectivos desvios padrão, entre parênteses, a respeito do tempo computacional despendido na classificação de imagens com diferentes contrastes entre classes.

<b>Método</b>	<b>Contraste</b>		
	<b>Baixo</b>	<b>Médio</b>	<b>Alto</b>
SVM	1,808(0,027)	1,767(0,027)	1,747(0,021)
CaSVM.Rep	11,601(2,685)	10,428(0,222)	8,478(0,234)
CaSVM.Tra	3,127(0,055)	2,959(0,048)	2,641(0,060)
SVM+Moda	2,246(0,033)	2,187(0,032)	2,170(0,024)
SVM+ICM	2,073(0,038)	1,922(0,039)	1,863(0,030)

Tabela C.8 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia de classificação no interior das regiões largas, com relação às imagens com diferentes contrastes entre classes.

Baixo	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		0,742(-)	0,943(+)	<b>1,000(+)</b>
CaSVM.Tra			<b>0,984(+)</b>	<b>1,000(+)</b>
SVM+Moda				<b>1,000(+)</b>
Médio	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	0,887(+)	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		<b>1,000(-)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Tra			<b>1,000(+)</b>	<b>1,000(+)</b>
SVM+Moda				<b>1,000(+)</b>
Alto	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>0,956(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		<b>1,000(-)</b>	<b>0,999(+)</b>	<b>1,000(+)</b>
CaSVM.Tra			<b>1,000(+)</b>	<b>1,000(+)</b>
SVM+Moda				0,912(+)

Tabela C.9 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os valores de acurácia de classificação no interior das regiões finas, com relação às imagens com diferentes contrastes entre classes.

Baixo	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		0,859(-)	<b>0,995(+)</b>	0,519(-)
CaSVM.Tra			<b>1,000(+)</b>	0,660(+)
SVM+Moda				<b>0,955(-)</b>
Médio	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		0,912(-)	<b>0,976(+)</b>	0,829(+)
CaSVM.Tra			<b>1,000(+)</b>	<b>0,996(+)</b>
SVM+Moda				0,842(-)
Alto	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	0,922(+)	<b>1,000(+)</b>	<b>1,000(+)</b>
CaSVM.Rep		<b>1,000(-)</b>	0,853(+)	0,793(+)
CaSVM.Tra			<b>1,000(+)</b>	<b>1,000(+)</b>
SVM+Moda				0,803(-)

Tabela C.10 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os coeficientes *Upsilon* dos resultados de classificação nas bordas de regiões largas, com relação às imagens com diferentes contrastes entre classes.

Baixo	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	0,562(-)	<b>0,999(+)</b>
CaSVM.Rep		<b>0,979(-)</b>	<b>1,000(-)</b>	<b>0,973(-)</b>
CaSVM.Tra			<b>0,999(-)</b>	0,846(+)
SVM+Moda				<b>1,000(+)</b>
Médio	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	0,535(+)	<b>1,000(+)</b>
CaSVM.Rep		<b>0,999(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Tra			<b>1,000(-)</b>	0,678(+)
SVM+Moda				<b>1,000(+)</b>
Alto	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>1,000(+)</b>	<b>1,000(+)</b>	0,508(+)	<b>1,000(+)</b>
CaSVM.Rep		<b>0,998(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Tra			<b>1,000(-)</b>	0,689(+)
SVM+Moda				<b>1,000(+)</b>

Tabela C.11 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo os coeficientes *Upsilon* dos resultados de classificação nas bordas de regiões finas, com relação às imagens com diferentes contrastes entre classes.

Baixo	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>0,971(+)</b>	<b>0,996(+)</b>	<b>1,000(-)</b>	0,808(-)
CaSVM.Rep		0,739(-)	<b>1,000(-)</b>	<b>0,966(-)</b>
CaSVM.Tra			<b>1,000(-)</b>	<b>0,979(-)</b>
SVM+Moda				<b>0,983(+)</b>
Médio	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>0,990(+)</b>	<b>1,000(+)</b>	<b>1,000(-)</b>	<b>0,990(-)</b>
CaSVM.Rep		0,854(-)	<b>1,000(-)</b>	0,728(-)
CaSVM.Tra			<b>1,000(-)</b>	0,601(-)
SVM+Moda				<b>1,000(+)</b>
Alto	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>0,998(+)</b>	<b>1,000(+)</b>	<b>1,000(-)</b>	0,851(-)
CaSVM.Rep		0,958(-)	<b>1,000(-)</b>	0,751(-)
CaSVM.Tra			<b>1,000(-)</b>	0,751(-)
SVM+Moda				<b>1,000(+)</b>

Tabela C.12 - Frequência observada, a partir de comparações pareadas, a respeito da superioridade de um método com relação a outro, segundo a acurácia de classificação das regiões pontuais, com relação às imagens com diferentes contrastes entre classes.

Baixo	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>0,989(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Rep		<b>1,000(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Tra			<b>0,999(-)</b>	<b>1,000(-)</b>
SVM+Moda				<b>1,000(-)</b>
Médio	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	<b>0,964(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Rep		<b>1,000(+)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Tra			<b>1,000(-)</b>	<b>1,000(-)</b>
SVM+Moda				<b>0,999(-)</b>
Alto	CaSVM.Rep	CaSVM.Tra	SVM+Moda	SVM+ICM
SVM	0,888(-)	<b>1,000(-)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Rep		<b>1,000(+)</b>	<b>1,000(-)</b>	<b>1,000(-)</b>
CaSVM.Tra			<b>1,000(-)</b>	<b>1,000(-)</b>
SVM+Moda				0,669(+)

## APÊNDICE D - MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS NO ESTUDO DE CASO II

Neste apêndice são apresentadas as matrizes de confusão referente às classificações efetuadas no estudo de caso realizado na Seção 4.2. Tais matrizes foram construídas a partir das amostras de validação sumarizadas na Tabela 4.3.

Tabela D.1 - Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAO.

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	9744	4328	3064	201	17337
Pasto	2226	8686	1746	12	12670
Agricultura	1891	1635	8900	918	13344
Solo Exposto	275	29	685	13076	14065
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.2 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12186	2505	2201	28	16920
Pasto	1479	11958	1513	1	14951
Agricultura	461	215	10640	436	11752
Solo Exposto	10	0	41	13742	13793
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.3 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12775	2048	2150	21	16994
Pasto	1111	12571	1309	0	14991
Agricultura	245	59	10933	401	11638
Solo Exposto	5	0	3	13785	13793
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.4 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12716	1941	2323	24	17004
Pasto	1152	12679	1364	0	15195
Agricultura	267	58	10707	352	11384
Solo Exposto	1	0	1	13831	13833
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.5 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	11712	2663	2424	57	16856
Pasto	1780	11682	1652	1	15115
Agricultura	615	333	10213	597	11758
Solo Exposto	29	0	106	13552	13687
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.6 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12028	2103	2435	60	16626
Pasto	1473	12278	1610	0	15361
Agricultura	606	297	10245	601	11749
Solo Exposto	29	0	105	13546	13680
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.7 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12175	1615	2325	68	16183
Pasto	1254	12763	1682	0	15699
Agricultura	644	299	10237	630	11810
Solo Exposto	63	1	151	13509	13724
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.8 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	14082	5505	2066	0	21653
Pasto	44	8990	8	0	9042
Agricultura	0	183	11675	0	11858
Solo Exposto	10	0	646	14207	14863
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.9 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13759	2705	1726	3	18193
Pasto	332	11799	379	0	12510
Agricultura	38	174	12286	54	12552
Solo Exposto	7	0	4	14150	14161
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.10 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	14011	2087	1281	0	17379
Pasto	125	12518	179	0	12822
Agricultura	0	73	12935	15	13023
Solo Exposto	0	0	0	14192	14192
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.11 - Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAA.

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	10290	5249	3373	147	19059
Pasto	1236	7127	628	2	8993
Agricultura	1511	2034	8040	187	11772
Solo Exposto	1099	268	2354	13871	17592
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.12 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $3 \times 3$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13010	4181	2984	27	20202
Pasto	790	10061	622	0	11473
Agricultura	235	428	10300	41	11004
Solo Exposto	101	8	489	14139	14737
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.13 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $5 \times 5$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13549	3859	2229	2	19639
Pasto	492	10628	383	0	11503
Agricultura	50	185	11451	11	11697
Solo Exposto	45	6	332	14194	14577
$\Sigma$ Col.	14136	14678	14395	14207	57416



Tabela D.14 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $7 \times 7$ .

Cl./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13675	3745	1758	2	19180
Pasto	390	10720	282	0	11392
Agricultura	9	211	11798	8	12026
Solo Exposto	62	2	557	14197	14818
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.15 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $3 \times 3$ .

Cl./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	11948	3369	2417	150	17884
Pasto	1471	10722	2623	85	14901
Agricultura	621	560	9104	318	10603
Solo Exposto	96	27	251	13654	14028
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.16 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $5 \times 5$ .

Cl./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	12978	2833	2060	96	17967
Pasto	839	11612	2583	115	15149
Agricultura	266	205	9599	217	10287
Solo Exposto	53	28	153	13779	14013
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.17 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $7 \times 7$ .

Cl./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13323	2502	1924	91	17840
Pasto	601	11983	1770	127	14481
Agricultura	145	169	10485	220	11019
Solo Exposto	67	24	216	13769	14076
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.18 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $3 \times 3$ .

Cl./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13335	5846	3270	10	22461
Pasto	334	8004	207	0	8545
Agricultura	229	816	9801	8	10854
Solo Exposto	238	12	1117	14189	15556
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.19 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $5 \times 5$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13941	5616	2501	0	22058
Pasto	124	8666	45	0	8835
Agricultura	20	396	11065	0	11481
Solo Exposto	51	0	784	14207	15042
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.20 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $7 \times 7$ .

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	14082	5505	2066	0	21653
Pasto	44	8990	8	0	9042
Agricultura	0	183	11675	0	11858
Solo Exposto	10	0	646	14207	14863
$\Sigma$ Col.	14136	14678	14395	14207	57416

Tabela D.21 - Matriz de confusão referente à classificação obtida pelo método SVM+ICM.

Cla./Ref.	Floresta	Pasto	Agricultura	Solo Exposto	$\Sigma$ Lin.
Floresta	13708	4050	2933	69	20798
Pasto	392	10354	295	37	11029
Agricultura	29	275	11116	60	11473
Solo Exposto	7	0	60	14041	14116
$\Sigma$ Col.	14136	14678	14395	14207	57416

## APÊNDICE E - MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS NO ESTUDO DE CASO III

Neste apêndice são apresentadas as matrizes de confusão referente às classificações efetuadas no estudo de caso realizado na Seção 4.3. Tais matrizes foram construídas a partir das amostras de validação sumarizadas na Tabela 4.6.

Tabela E.1 - Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAO.

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3574	1	352	14	723	1	354	5019
Telha.(Cer.)	0	3519	0	297	0	0	0	3816
V.Alta	108	3	5184	88	5	2	511	5901
Solo.Exp.	18	86	63	3662	2	0	217	4048
Telha.(Con.)	203	23	0	4	3497	0	0	3727
Veículos	0	0	0	0	0	157	0	157
V.Baixa	123	16	229	234	34	0	3037	3673
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.2 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3491	1	179	2	694	2	80	4449
Telha.(Cer.)	0	3529	1	131	0	0	0	3661
V.Alta	74	3	5372	47	4	2	516	6018
Solo.Exp.	18	84	42	3916	0	0	186	4246
Telha.(Con.)	252	15	1	8	3539	0	0	3815
Veículos	0	0	0	0	0	156	0	156
V.Baixa	191	16	233	195	24	0	3337	3996
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.3 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3609	0	115	2	651	16	60	4460
Telha.(Cer.)	0	3536	0	110	0	0	0	3646
V.Alta	44	1	5464	39	4	18	512	6082
Solo.Exp.	20	106	36	4017	0	0	120	4271
Telha.(Con.)	135	9	0	0	3546	6	0	3696
Veículos	0	0	0	0	0	130	0	103
V.Baixa	210	11	193	120	24	0	3521	4083
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.4 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3774	0	95	2	606	14	61	4562
Telha.(Cer.)	0	3526	0	111	0	0	0	3637
V.Alta	31	1	5506	32	4	26	458	6118
Solo.Exp.	15	110	31	4040	0	0	78	4274
Telha.(Con.)	123	0	0	0	3473	0	0	3596
Veículos	0	0	0	0	0	120	0	120
V.Baixa	233	11	176	114	28	0	3492	4054
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.5 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3497	1	172	4	687	1	114	4476
Telha.(Cer.)	0	3523	0	134	0	0	0	3657
V.Alta	72	4	5370	61	3	2	505	6017
Solo.Exp.	18	76	60	3880	0	0	202	4236
Telha.(Con.)	297	27	1	11	3536	0	0	3872
Veículos	0	0	0	0	0	157	0	157
V.Baixa	142	17	225	209	35	0	3298	3926
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.6 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3511	1	154	4	685	4	130	4489
Telha.(Cer.)	0	3517	0	143	0	0	0	3660
V.Alta	59	2	5404	54	4	8	489	6020
Solo.Exp.	18	92	41	3908	0	0	158	4217
Telha.(Con.)	172	11	0	5	3530	1	0	3719
Veículos	0	0	0	0	0	147	0	147
V.Baixa	266	25	229	185	42	0	3342	4089
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.7 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3516	0	160	5	729	2	135	4547
Telha.(Cer.)	0	3513	0	153	0	2	0	3668
V.Alta	60	1	5396	51	4	8	497	6017
Solo.Exp.	18	99	50	3922	0	0	128	4217
Telha.(Con.)	154	13	0	3	3478	6	0	3654
Veículos	0	0	0	0	0	142	0	142
V.Baixa	278	22	222	165	50	0	3359	4096
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.8 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $3 \times 3$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3719	0	205	14	682	18	248	4886
Telha.(Cer.)	0	3583	1	214	1	0	0	3799
V.Alta	51	3	5358	74	5	0	464	5955
Solo.Exp.	20	43	39	3839	0	0	192	4133
Telha.(Con.)	166	18	0	4	3563	1	0	3752
Veículos	0	0	0	0	0	141	0	141
V.Baixa	70	1	225	154	10	0	3215	3675
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.9 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $5 \times 5$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3792	1	81	12	648	82	154	4770
Telha.(Cer.)	0	3611	0	180	1	0	0	3792
V.Alta	11	4	5521	65	5	0	465	6071
Solo.Exp.	26	26	21	3913	1	0	160	4147
Telha.(Con.)	146	6	0	3	3600	2	0	3757
Veículos	0	0	0	0	0	75	0	75
V.Baixa	51	0	205	126	6	1	3340	3729
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.10 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAO e janela de contexto  $7 \times 7$ .

Cla./Ref.	Asfalto	Telha.(Cer.)	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Asfalto	3921	0	27	11	628	113	84	4784
Telha.(Cer.)	0	3625	0	140	0	0	0	3765
V.Alta	3	4	5607	69	3	0	514	6200
Solo.Exp.	30	19	15	3964	0	0	120	4148
Telha.(Con.)	37	0	0	0	3625	0	0	3662
Veículos	0	0	0	0	0	45	0	45
V.Baixa	35	0	179	115	5	2	3401	3737
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.11 - Matriz de confusão referente à classificação obtida pelo método SVM com estratégia OAA.

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3462	0	269	1	781	0	143	4656
Asfalto	0	3471	0	173	2	3	0	3649
V.Alta	281	25	5338	127	139	5	666	6581
Solo.Exp.	78	142	66	3829	12	0	265	4392
Telha.(Con.)	154	6	0	0	3321	0	0	3481
Veículos	0	0	0	0	0	152	0	152
V.Baixa	51	4	155	169	6	0	3045	3430
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.12 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $3 \times 3$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3241	0	90	0	517	0	46	3894
Asfalto	1	3479	0	124	0	0	0	3604
V.Alta	83	20	5636	142	19	0	749	6649
Solo.Exp.	12	87	18	3836	3	0	197	4153
Telha.(Con.)	648	61	4	121	3710	0	45	4589
Veículos	11	1	3	8	12	160	18	213
V.Baixa	30	0	77	68	0	0	3064	3239
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.13 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $5 \times 5$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3568	0	33	1	504	21	11	4138
Asfalto	0	3559	0	106	1	0	0	3666
V.Alta	28	14	5718	156	24	1	730	6671
Solo.Exp.	51	73	18	3958	15	0	173	4288
Telha.(Con.)	289	2	0	44	3706	0	9	4050
Veículos	21	0	0	0	11	138	0	170
V.Baixa	69	0	59	34	0	0	3196	3358
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.14 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Repulsivo, estratégia OAA e janela de contexto  $7 \times 7$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3859	5	97	9	684	88	92	4834
Asfalto	0	3573	0	101	6	0	0	3680
V.Alta	47	6	5678	181	3	0	639	6554
Solo.Exp.	22	64	21	3961	21	0	166	4255
Telha.(Con.)	70	0	0	20	3545	0	0	3635
Veículos	0	0	0	0	2	72	0	74
V.Baixa	28	0	32	27	0	0	3222	3309
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.15 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $3 \times 3$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	2844	0	125	1	378	0	75	3423
Asfalto	1	3465	3	140	0	0	0	3609
V.Alta	100	16	5571	121	7	0	547	6362
Solo.Exp.	6	86	41	3715	1	0	109	4028
Telha.(Con.)	1090	78	40	203	3756	0	109	5276
Veículos	38	3	23	26	59	160	36	345
V.Baixa	37	0	105	83	0	0	3073	3298
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.16 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $5 \times 5$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	2795	0	74	1	314	0	46	3230
Asfalto	1	3478	3	110	0	0	0	3592
V.Alta	58	9	5639	109	5	1	523	6344
Solo.Exp.	4	80	34	3777	2	0	145	4042
Telha.(Con.)	1168	61	77	155	3787	0	164	5412
Veículos	69	20	36	32	112	150	54	473
V.Baixa	31	0	65	65	0	0	3087	3248
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.17 - Matriz de confusão referente à classificação obtida pelo método CaSVM, com submodelo Translativo, estratégia OAA e janela de contexto  $7 \times 7$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	2738	0	65	1	418	1	51	3274
Asfalto	1	3498	3	101	0	5	0	3608
V.Alta	50	9	5778	127	5	5	436	6410
Solo.Exp.	4	72	30	3798	1	0	132	4037
Telha.(Con.)	1132	48	73	201	3746	21	155	5366
Veículos	77	21	30	26	101	128	39	422
V.Baixa	24	0	49	35	0	0	3116	3224
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.18 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $3 \times 3$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3619	0	129	0	749	27	56	4580
Asfalto	0	3511	2	128	0	0	0	3641
V.Alta	160	13	5529	109	114	0	686	6611
Solo.Exp.	68	121	52	3947	7	0	206	4401
Telha.(Con.)	151	2	0	0	3389	0	0	3542
Veículos	0	0	0	0	0	133	0	133
V.Baixa	28	1	116	115	2	0	3171	3433
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.19 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $5 \times 5$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3773	0	41	0	708	88	25	4635
Asfalto	0	3551	1	108	1	0	0	3661
V.Alta	43	10	5662	100	93	0	689	6597
Solo.Exp.	82	87	42	3996	9	0	174	4390
Telha.(Con.)	99	0	0	0	3450	0	0	3549
Veículos	0	0	0	0	0	71	0	71
V.Baixa	29	0	82	95	0	1	3231	3438
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.20 - Matriz de confusão referente à classificação obtida pelo método SVM+Moda, com estratégia OAA e janela de contexto  $7 \times 7$ .

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3887	0	21	0	706	114	11	4739
Asfalto	0	3577	0	94	2	0	0	3673
V.Alta	15	4	5722	94	69	0	667	6571
Solo.Exp.	87	67	34	4032	7	0	161	4388
Telha.(Con.)	13	0	0	0	3477	0	0	3490
Veículos	0	0	0	0	0	44	0	44
V.Baixa	24	0	51	79	0	2	3280	3436
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341

Tabela E.21 - Matriz de confusão referente à classificação obtida pelo método SVM+ICM.

Cla./Ref.	Telha.(Cer.)	Asfalto	V.Alta	Solo.Exp.	Telha.(Con.)	Veículos	V.Baixa	$\Sigma$ Lin.
Telha.(Cer.)	3731	0	74	10	629	5	71	4520
Asfalto	0	3499	1	135	0	0	0	3635
V.Alta	75	8	5638	173	5	0	694	6593
Solo.Exp.	31	107	22	3905	3	0	204	4272
Telha.(Con.)	166	34	0	0	3621	0	0	3821
Veículos	0	0	0	0	0	155	0	155
V.Baixa	23	0	93	76	3	0	3150	3345
$\Sigma$ Col.	4026	3648	5828	4299	4261	160	4119	26341



## **PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE**

### **Teses e Dissertações (TDI)**

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

### **Manuais Técnicos (MAN)**

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

### **Notas Técnico-Científicas (NTC)**

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

### **Relatórios de Pesquisa (RPQ)**

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

### **Propostas e Relatórios de Projetos (PRP)**

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

### **Publicações Didáticas (PUD)**

Incluem apostilas, notas de aula e manuais didáticos.

### **Publicações Seriadas**

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o International Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

### **Programas de Computador (PDC)**

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

### **Pré-publicações (PRE)**

Todos os artigos publicados em periódicos, anais e como capítulos de livros.