



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELECOMUNICAÇÕES
CAMPUS DE FORTALEZA

Francisco Enilton Alves Nogueira

SEGMENTAÇÃO DE IMAGENS SAR UTILIZANDO SVM E LOG-CUMULANTES

Fortaleza - Ceará

2018

Francisco Enilton Alves Nogueira

SEGMENTAÇÃO DE IMAGENS SAR UTILIZANDO SVM E LOG-CUMULANTES

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Engenharia de Telecomunicações.

Área de concentração: Sistemas de Telecomunicações.

Orientador: Prof. Dr. Regis Cristiano Pinheiro Marques.

Coorientador: Prof. Dr. Ajalmar Rêgo da Rocha Neto.

Fortaleza
2018

N778s Nogueira, Francisco Enilton Alves.
SEGMENTAÇÃO DE IMAGENS SAR UTILIZANDO SVM E LOG-CUMULANTES / Francisco
Enilton Alves Nogueira. - 2018.
70 f. : il.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Engenharia de Telecomunicações,
Campus Fortaleza, 2018.
Orientação: Prof. Dr. Regis Cristiano Pinheiro Marques.
Coorientação: Prof. Dr. Ajalmar Rêgo da Rocha Neto.

1. Imagem SAR. 2. Log-cumulantes. 3. SVM. 4. Segmentação de imagem. 5. Speckle. I. Título.
CDD 621.382



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
TELECOMUNICAÇÕES

Francisco Enilton Alves Nogueira

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Telecomunicações, sendo aprovada pelo Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

Orientador: Prof. Dr. Regis Cristiano Pinheiro Marques
Instituto Federal do Ceará - IFCE

Prof. Dr. Ajalmar Rego da Rocha Neto
Instituto Federal do Ceará - IFCE

Prof. Dr. Auzuir Ripardo de Alexandria
Instituto Federal do Ceará - IFCE

Prof. Dr. Ricardo Holanda Nobre
Universidade Estadual do Ceará/UAB Centro de Ciências e Tecnologia - CCT

Dedico este trabalho à minha família.

Agradecimentos

Agradeço primeiramente a Deus pela oportunidade de viver.

Aos meus pais Francisco e Lucinete pelo carinho e por sempre estarem ao meu lado .

Ao prof. Dr. Regis Cristiano Pinheiro Marques por sua orientação e por todo o aprendizado que recebi ao longo do mestrado.

Ao prof. Dr. Ajalmar Rêgo da Rocha Neto por toda ajuda e conhecimento repassado ao longo do mestrado.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará e a todo o corpo docente do Programa de Pós-Graduação em Engenharia de Telecomunicações pelo ensino de qualidade que recebi.

Aos meus irmãos Eliano, Elio e Edna por sempre me incentivarem nos momentos difíceis e acreditarem no meu sucesso.

A meu tio Dr. Dijalma Hónorio e minha namorada Taiz Silva.

Aos meus colegas do mestrado, pela sua ajuda e estímulo para terminar este trabalho, em especial aos colegas Saulo Oliveira, Madson Dias, Alberth Florêncio, Felipe Moreira, Atila Maia e aos demais membros do Laboratório de Inteligencia Artificial (LIA).

“A mente que abre uma janela, jamais volta a seu tamanho original.”

Albert Einstein

Resumo

A busca por meios eficazes de observação da Terra têm motivado o desenvolvimento de tecnologias para sensoriamento remoto. Plataformas de aquisição de imagens multiespectrais e programas de processamento de imagens digitais possibilitam o gerenciamento ambiental, monitoração de territórios, levantamentos agrícolas e mapeamentos de uso e cobertura do solo. No processamento de imagens, a segmentação é uma tarefa que pode ser aplicada na solução de uma ampla classe de problemas em visão computacional. No entanto, não se trata de uma tarefa simples quando aplicada a imagens de Radar de Abertura Sintética (SAR) devido à presença do ruído *speckle*. Dada a importância das imagens SAR em problemas de sensoriamento remoto, esta dissertação apresenta um método para segmentação de imagens usando os parâmetros de rugosidade e escala estimados a partir de dados em amplitude modelados pela distribuição $\mathcal{G}_A^0$ como entrada para o classificador SVM. Para tanto, adotamos o método log-cumulantes para a estimação dos mapas de parâmetros. A avaliação de desempenho dos resultados foi realizada em termos das medidas de Erro de Segmentação (EoS) e de *Cross-Region Fitting* (CRF) para imagens SAR sintéticas e reais, respectivamente. O desempenho do método proposto é comparado com três outras abordagens propostas na literatura o *K-nearest neighbors* (KNN), *Naive Bayes* (BAYES), e um método iterativo baseado em SVM. Os resultados mostraram a capacidade do método proposto Sar Support Vector Machine (SARSVM) em segmentar imagens com diferentes níveis de contraste, uma vez que este obteve melhores valores de *EoS* e *CRF* em relação aos outros métodos.

Palavras-Chave: *Imagem SAR, Log-cumulantes, SVM, Segmentação de imagem, Speckle.*

Abstract

The search for effective ways of observing the Earth has motivated the development of technologies for remote sensing. Multispectral imaging platforms and digital imaging processing programs enable environmental management, land monitoring, agricultural surveys, and land cover mapping. Image processing segmentation is a task that can be applied in solving a wide class of computer vision problems. However, this is not a simple task when applied to Synthetic Aperture Radar (SAR) images due to the presence of *speckle* noise. Given the importance of SAR images in remote sensing problems, this dissertation presents a method for image segmentation using the roughness and scale parameters estimated from amplitude data, modeled by the distribution $\mathcal{G}_A^0$ as input to the SVM classifier. To do so, we adopted the log-cumulant method for parameter estimation. The performance evaluation of the results was performed in terms of Segmentation Error (EoS) and Cross-Region Fitting (CRF) measurements for synthetic and real SAR images, respectively. The performance of the proposed method is compared with three other approaches proposed in the literature such as the K-Nearest Neighbors (KNN), Naive Bayes (BAYES), and the SVM based method. The results showed the ability of the proposed Sar Support Vector Machine (SARSVM) method to segment images with different levels of contrast, since it obtained better values of *EoS* and *CRF* in relation to the other methods.

Keywords: *Image SAR, Log-cumulants, SVM, Image segmentation, Speckle.*

Conteúdo

Lista de Figuras

Lista de Tabelas

Lista de Símbolos

Lista de Abreviações

1	Introdução	18
1.1	Motivação	20
1.2	Objetivos	21
1.2.1	Objetivo Geral	21
1.2.2	Objetivos Específicos	21
1.3	Contribuições e Produção Científica	21
1.4	Organização da Dissertação	22
2	Fundamentos de Imagens SAR	23
2.1	Imagens SAR e a natureza do ruído <i>speckle</i>	23
2.1.1	Processamento <i>multilook</i> de imagens SAR	26
2.2	Modelos estatísticos para dados SAR	27
2.2.1	Modelo multiplicativo	27
2.3	Modelos para dados em amplitude	28
2.4	Modelo $\mathcal{G}$ -Amplitude Zero	29
2.5	Conclusão do capítulo	31

3	Método dos momentos e estimação de parâmetros via método de log-cumulantes	32
3.1	Estimação e interpretação dos parâmetros α e γ	32
3.2	Estimação de parâmetros via método de log-cumulantes	34
3.2.1	Método de Nicolas (2002) para a estimação de parâmetros via método log-cumulantes	35
3.2.2	Método de Rodrigues <i>et al.</i> (2016) para a estimação de parâmetros via método de log-cumulantes	37
3.2.3	Estimativa dos mapas de parâmetros para a distribuição $\mathcal{G}_A^0$	39
3.3	Conclusão do capítulo	40
4	Métodos para segmentação de Imagens SAR	41
4.1	Segmentação de imagens SAR	41
4.2	Máquinas de Vetores Suporte	42
4.3	Técnicas aplicadas ao processamento de imagens SAR	44
4.3.1	Método de Ping <i>et al.</i> (2009) para segmentação de imagens SAR	44
4.3.2	Método de Tripathi <i>et al.</i> (2015) para segmentação de imagens SAR	47
4.3.3	Método de Maiti e Kumar (2012) para segmentação de imagens SAR	47
4.3.4	Método proposto para segmentação de imagens SAR	48
4.4	Métricas para análise de dados SAR	50
4.5	Conclusão do capítulo	52
5	Experimentos e resultados	53
5.1	Segmentação de imagens sintéticas	53
5.1.1	Comparação das técnicas de segmentação em imagens sintéticas	54
5.2	Segmentação de imagens SAR reais	56
5.2.1	Descrição das imagens	56
5.3	Conclusão do capítulo	60

6	Conclusão e Trabalhos Futuros	61
6.1	Conclusões	61
6.2	Trabalhos futuros	62
	Referências	63

Lista de Figuras

1	Reflexão da energia emitida pelo sensor para diferentes graus de rugosidade da superfície (BOURGEAU CHAVEZ <i>et al.</i> , 2005).	25
2	Exemplos de dispersores em células de resolução com a respectiva soma dos sinais refletidos (MOREIRA <i>et al.</i> , 2013).	26
3	Imagem SAR com diferentes números de <i>looks</i> : da esquerda para a direita 1 <i>look</i> e 8 <i>looks</i> , respectivamente (MOREIRA <i>et al.</i> , 2013).	27
4	Distribuição $\mathcal{G}_A^0(z, \alpha, \gamma, L)$ para: (a) $L = 1$ e (b) $L = 8$. Distribuição para $\gamma = 1$ (linha contínuas) e $\gamma = 10$ (linha tracejada), com três diferentes padrões de rugosidade: homogêneo $\alpha = -12,5$ (azul), heterogêneo $\alpha = -4,5$ (verde) e extremamente heterogêneo $\alpha = -1,5$ (vermelho) (MARQUES, 2011).	33
5	Mapa de rugosidade obtido pelo método FMoLC para duas imagens simuladas em amplitude usando $\alpha = \{(-1,5; -8,0)\}$. (a) imagem SAR sintéticas, (b) mapas de rugosidade estimados e (c) histograma de rugosidade.	40
6	Imagem de tanque de guerra do conjunto de dados MSTAR.	44
7	Fluxograma do algoritmo (PING <i>et al.</i> , 2009)	45
8	Mapa de parâmetros de (a) rugosidade e (b) escala resultantes da estimativa de log-cumulantes.	49
9	Ilustração do processo de cálculo da medida de CRF, relacionando o resultado de segmentação com os dados de referência (MARQUES, 2011).	52
10	Resultados do experimento de Monte Carlo: (a) imagens artificialmente contaminadas por ruído <i>speckle</i> com $\alpha = -1,5; -8,0$, $\gamma = 0,5; 2,0$ e $L = 1,0$ <i>looks</i> e (b) resultados da segmentação.	54

11	Resultado de segmentação para uma imagem sintética: (a) verdade terrestre ou imagem de referência, (b) imagem simulada seguindo uma distribuição $\mathcal{G}_A^0$, (c) resultado do método SARSVM, (d) resultado do método KNN, (e) resultado do método BAYES, (f) resultado do método SVM.	54
12	Probabilidade acumulada de EoS para o experimento de Monte Carlo.	55
13	São Francisco: imagem em amplitude adquirida pelo sensor AIRSAR sobre a Baía de São Francisco com $L = 4$ looks (ESA, 2016).	57
14	Espanha: imagem em amplitude adquirida pela Envisat sobre a Galiza, Espanha, com $L = 8$ looks (ESA, 2016).	57
15	Óleo: imagem em amplitude e $L = 4$ looks, adquiridas pelo sensor RADARSAT. Esta imagem mostra um derrame de óleo. Cedido pelo professor Venerando Amaro, UFRN.	58
16	Tapajós: imagem em amplitude e $L = 3$ looks, adquirida pelo sensor JERS, mostrando áreas de desmatamento na Amazônia Brasileira. Cedido pelo INPE.	58
17	Da esquerda para a direita, os resultados de segmentação das imagens SAR. (a) São Francisco; (b) Espanha; (c) Óleo e (d) Tapajós para os métodos KNN, BAYES, SVM e SARSVM, respectivamente.	59

Lista de Tabelas

1	Bandas de frequência utilizadas nos sistemas SAR, com indicação de frequências e comprimentos de onda associados (MOREIRA <i>et al.</i> , 2013). . .	24
2	Valores médios de EoS para o experimento de Monte Carlo.	56
3	Valores médios de CRF e tempo computacional.	60

Lista de Símbolos

Z	Variável aleatória
K_α	Função de Bessel modificada de terceiro grau e ordem α
L	Número de visadas (<i>looks</i>)
N	Número de classes
X	Fasor complexo
$\mathcal{N}^{-1/2}$	distribuição da raiz quadrada da gaussiana inversa generalizada
Γ	Distribuição Gama
$\sqrt{\Gamma}$	Distribuição raiz quadrada de Gama
$\Gamma^{-1/2}$	Distribuição recíproca da raiz quadrada de Gama
$\mathcal{K}$	Distribuição $\mathcal{K}$
$\mathcal{K}_A$	Distribuição $\mathcal{K}$ -Amplitude
$\mathcal{G}$	Distribuição $\mathcal{G}$
$\mathcal{G}_A^0$	$\mathcal{G}$ -Amplitude Zero
α	Rugosidade dos dados SAR
γ	Escala de amplitude dos dados SAR
$\Gamma(\cdot)$	Função gama
$\hat{m}_r$	r-ésimo momento amostral não central
$\psi^0(\cdot)$	Funções digamma
$\psi^1(\cdot)$	Função trigamma
θ_1, θ_2	Vetores de parâmetros

d_{AG}	distância Aritmética-Geométrica entre duas variáveis aleatórias Z_1 e Z_2
Ω_b, Ω_f	Regiões de <i>background</i> e <i>foreground</i>
$f(X)$	Função de decisão
μ	média
σ	Desvio padrão
H	Entropia

Lista de Abreviações

SAR	Synthetic aperture radar (radar de abertura sintética)
fdp	Função densidade de probabilidade
fda	Função de distribuição acumulada
MO	Estimador por momentos amostrais
MV	Estimador de máxima verossimilhança
CRF	Ajuste cruzado de região (<i>Cross region fitting</i>)
MLC	Estimador de log-cumulantes
FMoLC	<i>Fast Method of Log-Cumulants</i>
EoS	Erro de segmentação
SVM	Maquina de vetor de suporte (<i>Support Vector Machine</i>)
KNN	<i>k-Nearest Neighbor</i>
SARSVM	SAR Support Vector Machine
TAE	Teoria de aprendizado estatístico
R_{emp}	Risco empírico
R_{est}	Risco estrutural
RNA	Redes Neurais Artificiais
IA	Inteligência Artificial

INTRODUÇÃO

O processamento de imagens de radar de abertura sintética (*Synthetic Aperture Radar*, SAR) é um tema muito importante em sensoriamento remoto ambiental. Os dados de diferentes sensores são comumente usados para obter informações da cobertura do solo. O sistema SAR é operável tanto no dia como na noite, e é capaz de fornecer imagens de alta resolução em todas as condições climáticas e para várias aplicações de sensoriamento remoto (DUTRA *et al.*, 2003). O sistema de imageamento SAR emprega iluminação coerente e, assim como laser, sonar e ultrassom, é afetado por um ruído com padrão granular denominado *speckle*.

Nos últimos anos o estudo e uso desse tipo de radar tem aumentado e muitas aplicações de interesse, tanto na área científica como civil, têm surgido. Estudos de imagens SAR possuem uma ampla gama de aplicações em sensoriamento remoto (FENG; CAO; PI, 2013). Para monitorar o crescimento urbano, observar desmatamento e manchas de óleo no mar faz-se necessário o monitoramento e observação do uso e cobertura da Terra (PARREIRA *et al.*, 2015).

O avanço da tecnologia SAR tem permitido o desenvolvimento de técnicas mais eficientes para o monitoramento e reconhecimento de informações provenientes de dados SAR. Dentre as técnicas que têm contribuído para tal avanço pode-se citar o uso das Máquinas de Vetores Suporte (*Support Vector Machine*, SVM) para o mapeamento do uso da terra na agricultura (ZOLFAGHARI *et al.*, 2013), mapeamento de águas da superfície terrestre (XU; SUI; XU, 2016), segmentação e identificação de manchas de óleo no mar (MARQUES; MEDEIROS; NOBRE, 2012), dentre outras. Devido ao vasto território a ser trabalhado, não é viável para os especialistas visitarem todos os lugares para recolhimento das amostras de áreas de interesse (FENG; CAO; PI, 2013). Com o avanço tecnológico supracitado, grandes áreas de terra ou mar podem ser verificadas pelos sensores ópticos e de radar. No entanto, estes produzem grande quantidade de informações que são impossíveis de serem analisadas manualmente (SKONIECZNY *et al.*, 2015).

Pensando nisto, algoritmos computacionais são desenvolvidos para processar esta grande quantidade de dados e extrair novas informações sobre o uso e a cobertura da Terra (LIU;

ZHANG; WANG, 2011). É comum que se busque, por meio de filtragem, realçar e destacar características de interesse nas imagens SAR, ao mesmo tempo que se tenta reduzir o efeito degradante do ruído *speckle* (LEE *et al.*, 2015; FROST *et al.*, 1982; WANG; AINSWORTH; LEE, 2017; MAHDAVI *et al.*, 2018; YAN *et al.*, 2016; DASARI; ANJANEYULU, 2017; MEDEIROS; MASCARENHAS; COSTA, 2003; LEE *et al.*, 2009; HUANG *et al.*, 2009; TORRES *et al.*, 2014; ARGENTI; BIANCHI; ALPARONE, 2006).

Contudo, a etapa de pré-processamento (ex. filtragem) frequentemente degrada detalhes da imagem, como também altera a estatística dos dados (MARQUES, 2011). Por essa razão, são propostas técnicas de análise e segmentação de imagens SAR, sem a necessidade de filtragem, que utilizam o conhecimento de modelos a priori atribuídos aos dados com ruído *speckle* (DUAN *et al.*, 2017; ZHENG *et al.*, 2015; ZHANG *et al.*, 2015; LIU *et al.*, 2016; SHANG *et al.*, 2016; TISON *et al.*, 2004; DENG; CLAUSI, 2005; HUANG; HUANG; LI, 2009; CARVALHO *et al.*, 2010).

Técnicas de reconhecimento de padrões têm sido comumente utilizadas na classificação de dados provenientes de sensoriamento remoto. A tarefa de reconhecimento de padrões está intimamente relacionada com a descoberta automática de regularidades em dados por meio do uso de algoritmos computacionais, utilizando essas regularidades na tomada de decisões (CHRISTOPHER, 2016). As Redes Neurais Artificiais (RNA's) tiveram um crescente interesse e têm sido usadas com bastante êxito no gerenciamento de informações do ambiente e em reconhecimento de padrões de imagens proveniente de Sensoriamento Remoto. Uma das características mais importantes das RNA's é sua capacidade de reconhecer padrões, até mesmo ao lidar com informações ruidosas ou incompletas. A área de conhecimento nomeada de inteligência artificial (IA), têm proporcionado o desenvolvimento de máquinas inteligentes para a realização dos mais variados tipos de tarefas por meio da criação e aprimoramento de métodos, técnicas e ferramentas (DUIN; TAX, 2005). As SVMs têm se mostrado como uma alternativa para a modelagem matemática de sistemas complexos. São técnicas com capacidade de resolução de problemas reais extremamente complexos (CHRISTOPHER, 2016). Dentre as técnicas de abordagens estatísticas mais utilizadas na literatura para processamentos de imagens SAR, tem-se: Máquinas de Vetores Suporte (SVM), K-Vizinhos mais próximos (KNN) e Máxima Verossimilhança (MV) (KOVÁCS, 2002).

O uso de modelos estatísticos para descrever dados SAR tem permitido o uso de um suporte matemático vasto e, conseqüentemente, o desenvolvimento de técnicas mais eficientes (MARQUES, 2011). Nas últimas décadas, distribuições derivadas dos modelos $\mathcal{K}$ (JAO, 1984) e $\mathcal{G}$ (FRERY *et al.*, 1997) têm sido propostas, apresentando resultados significativos.

A atribuição de modelos estatísticos aos dados SAR permite modelar as superfícies imageadas segundo os parâmetros distribucionais estimados. No uso da distribuição $\mathcal{G}$, por exemplo, os três parâmetros desta distribuição são associados, respectivamente, à rugosidade do terreno, escala de amplitude ou intensidade do sinal captado e o número de *looks*. A estimativa destes parâmetros fornece um vetor que pode ser usado para caracterizar diferentes regiões da imagem SAR. Neste trabalho, a estimativa é realizada *pixel a pixel*, gerando mapas de parâmetros com as mesmas dimensões da imagem.

Os métodos de estimação mais difundidos para derivar estimadores são o método dos momentos (MO) e o de máxima verossimilhança (MV) (LEHMANN, 2004). Contudo, Nicolas (2002) desenvolveu um método alternativo para estimar parâmetros de funções densidades de probabilidades, conhecido como método de log-cumulantes (MLC), apresentando melhores resultados e melhor custo computacional. Rodrigues *et al.* (2016) desenvolveram em seu trabalho uma abordagem rápida para o método de log-cumulante, denotada por (FMoLC), para estimar os parâmetros de rugosidade e escala das distribuições $\mathcal{G}_I^0$ e $\mathcal{G}_A^0$.

1.1 Motivação

A identificação dos tipos de uso da terra, por meio da segmentação de imagem, é uma área na qual a tecnologia de sensoriamento remoto desempenha um papel muito importante. As imagens obtidas do sensoriamento remoto refletem informações detalhadas da superfície da terra, de modo que é um desafio realizar uma segmentação exata das imagens de sensoriamento remoto.

O uso de imagens SAR é de extrema importância para o monitoramento da superfície terrestre. O sistema de imageamento desse tipo de radar é ativo e, portanto, não necessita de fontes externas de iluminação, o que permite sua operação vinte e quatro horas por dia. Essa característica é ideal para o monitoramento e vigilância territorial. Desse modo, investigar métodos de processamento de imagens de radar de abertura sintética que possam auxiliar no monitoramento, por exemplo, de oceanos e de áreas de proteção ambiental é uma tarefa importante e necessária.

Ao longo das últimas décadas, o constante estudo dos sistemas SAR tem permitido o desenvolvimento de novos métodos para processamento e análise dos dados. É desejado que os algoritmos desenvolvidos sejam eficientes no tratamento de dados obtidos por diferentes sensores, em condições de imageamento diversas (ângulo de incidência, polarização, banda de frequência). A segmentação e classificação correta de alvos e regiões de interesse têm

particular importância, uma vez que estas tarefas são essenciais para aplicações com dados SAR (MARQUES, 2011).

Relacionado às metodologias de monitoramento, o uso de classificadores para a segmentação de imagens SAR são frequentemente adotados. Estas técnicas são fundamentadas a partir de conceitos de Reconhecimento de Padrões, cujo objetivo é identificar e separar objetos em imagens digitais.

1.2 Objetivos

1.2.1 Objetivo Geral

Este trabalho tem como objetivo propor, implementar e avaliar um algoritmo SVM para segmentação de imagens SAR em amplitude, modeladas seguindo a $\mathcal{G}_A^0$, utilizando o método rápido de log-cumulantes (FMoLC) para estimação de parâmetros.

1.2.2 Objetivos Específicos

Dentre os objetivos específicos a serem atingidos nesta dissertação estão:

- Apresentar a natureza da aquisição e geração das imagens SAR, bem como o modelo de degradação do ruído *speckle* e suas distribuições estatísticas;
- Propor a combinação de parâmetros distribucionais e métodos de SVM, permitindo então a segmentação de imagens SAR por meio da informação de seus modelos estatísticos;
- Implementar técnicas de segmentação disponíveis na literatura, com o objetivo de avaliar comparativamente o método proposto;
- Implementar e disponibilizar o conjunto de métodos anteriormente citados para a comunidade científica.

1.3 Contribuições e Produção Científica

As contribuições desta dissertação são as seguintes:

- proposta de um método de segmentação de imagens SAR por meio do algoritmo SVM;

- Uso da técnica de log-cumulantes para extração de características em imagens SAR;
- uso das medidas de rugosidade e escala como entrada para algoritmos de segmentação.

Os seguintes artigos são frutos desta pesquisa:

- NOGUEIRA, F. E. A.; MARQUES, R. C. P. **Segmentation of SAR images based on the SVM classifier and on the estimation of log-cumulant**. In: Multimedia Tools and Applications. Submetido.
- NOGUEIRA, F. E. A.; MARQUES, R. C. P. **An Unsupervised Segmentation Method for Target Detection in SAR Images Based on Log-Cumulants Estimation**. A ser submetido em 2018.

1.4 Organização da Dissertação

O restante desta dissertação está organizado da seguinte forma:

Capítulo 2: contextualização dos fundamentos das imagens SAR, da geração do ruído *speckle* e do processamento *multilook* comumente utilizado na redução de ruído. É realizada uma abordagem de como os diferentes tipos de terreno podem afetar na geração das imagens SAR. Ainda são descritos os modelos estatísticos atribuídos aos dados SAR em amplitude, a modelagem dos dados em amplitude, além de uma revisão do modelo $\mathcal{G}$ - Amplitude Zero.

Capítulo 3: apresenta a estimativa dos mapas de parâmetros da distribuição $\mathcal{G}_A^0$ por meio do método dos momentos, como também apresenta duas técnicas de estimação de parâmetros através do método de log-cumulantes.

Capítulo 4: apresentação do algoritmo SVM, apresentação do método proposto nesta dissertação bem como de alguns métodos encontrados na literatura, além de um conjunto de métricas para avaliação de resultados com base em distâncias estocásticas.

Capítulo 5: apresentação dos resultados obtidos na segmentação de imagens SAR sintéticas e reais e avaliação dos resultados por meio das medidas estocásticas.

Capítulo 6: conclusões do trabalho destacando suas contribuições, bem como perspectivas de trabalhos futuros.

FUNDAMENTOS DE IMAGENS SAR

Este capítulo apresenta os fundamentos de imagens de radar de abertura sintética, a geração do ruído *speckle* e o processamento *multilooks* comumente utilizados para redução do ruído. Como também são descritos os modelos estatísticos atribuídos aos dados SAR em amplitude e o modelo $\mathcal{G}$ - Amplitude zero ($\mathcal{G}_A^0$), proposto por Frery *et al.* (1997).

2.1 Imagens SAR e a natureza do ruído *speckle*

Os sistemas imageadores que utilizam SAR atuam, em grande parte, na faixa de microondas, o que o faz uma importante ferramenta na análise de áreas do solo, sobressaindo-se às imagens óticas no que diz respeito à independência da luz solar, fatores climáticos, nuvens, entre outros. Além de permitir uma penetração mais acentuada da cobertura vegetal, dependendo da banda de frequência utilizada (CARVALHO; FERNANDES, 2015). Desse modo, como afirmam Moreira *et al.* (2013), o sistema SAR se mostra útil e confiável no monitoramento de processos dinâmicos na superfície da Terra de forma contínua e global.

O radar de abertura sintética pode gerar imagens com maior resolução que os radares ópticos, este processo é realizado através do efeito Doppler, que simula uma antena virtual longa, através do deslocamento de uma antena fisicamente curta, ao longo da direção de voo da plataforma. As posições sucessivas da antena são tratadas eletronicamente como se fossem elementos de uma única antena longa, assim derivando o termo abertura sintética (TEIXEIRA *et al.*, 2011). Os sistemas SAR transmitem pulsos eletromagnéticos (ondas eletromagnéticas) com alta potência e recebem os ecos do sinal retrodifundido (retroespalhamento) de forma sequencial (MOREIRA *et al.*, 2013). Assim, uma imagem é gerada a partir do retorno captado ou sinal retroespalhado.

Para o processo de geração de imagens SAR o radar de abertura sintética emite ondas eletromagnéticas que incidem na superfície imageada, e a geração das imagens depende da posterior captação da radiação refletida (retroespalhamento). Alguns aspectos influenciam este processo, como banda de frequência e comprimento da onda eletromagnética (HORTA,

2009). O comprimento da onda eletromagnética influencia na capacidade de penetração das microondas e na interação destas ondas com a superfície imageada, podendo ocorrer uma maior ou menor penetração (MARQUES, 2011). Uma maior penetração dos pulsos eletromagnéticos ocorre em sistemas SAR que utilizam comprimentos de onda mais longos (MOREIRA *et al.*, 2013). As bandas de frequência comumente utilizadas nos sistemas SAR assim como as frequências e comprimento de onda associados são apresentados na Tabela 1.

Tabela 1: Bandas de frequência utilizadas nos sistemas SAR, com indicação de frequências e comprimentos de onda associados (MOREIRA *et al.*, 2013).

Banda	<i>Ka</i>	<i>Ku</i>	<i>X</i>	<i>C</i>	<i>S</i>	<i>L</i>	<i>P</i>
Frequência (GHz)	40-25	17,6-12	12-7,5	7,5-3,75	3,75-2	2-1	0,5-0,25
Comp. de onda (cm)	0,75-1,2	1,7-2,5	2,5-4	4-8	8-15	15-30	60-120

O sinal de retorno ou retroespalhado depende da rugosidade da superfície imageada (LEE; POTTIER, 2009). Segundo BOURGEAU CHAVEZ *et al.* (2005), para o monitoramento de zonas úmidas, as características envolvidas no processo de imageamento podem ser agrupadas em três tipos: estrutura da vegetação, rugosidade superficial do terreno e a presença ou ausência de água. Em zonas úmidas com diferentes tipos estruturais de vegetação, o espalhamento do sinal de radar é afetado diferentemente. Para as áreas com floresta arbustiva, existem duas camadas de vegetação que devem ser consideradas: o dossel, que consiste de pequenos galhos e folhagem; e o tronco que consiste de galhos maiores e o tronco propriamente dito. A radiação de micro-ondas quando entra em contato com estas características possui dois tipos distintos de interação: o espalhamento direto e a absorção ou atenuação da energia (MARTINIS; KUENZER; TWELE, 2015).

A rugosidade superficial do terreno é outro fator importante no retorno do sinal. Quando esta aumenta, também aumenta o coeficiente de retroespalhamento. Quando uma superfície rugosa está úmida, o retorno do sinal é maior do que quando a superfície está seca. Quando a superfície está inundada, a rugosidade superficial é eliminada e a energia é espalhada na direção oposta ao sensor (TINER; LANG; KLEMAS, 2015). Marques (2011), retrata que superfícies lisas (como lagos e rios) não geram retorno, pois toda radiação incidente é refletida na direção oposta a antena, o que resulta na formação de regiões escuras na imagem. Por outro lado, superfícies extremamente rugosas (como áreas urbanas) podem apresentar pontos de alto retroespalhamento formando regiões mais claras na imagem. É apresentado na Figura 1 o efeito do retroespalhamento do sinal em diferentes tipos de superfícies.

A qualidade radiométrica das imagens de radar é afetada por um parâmetro instrumental que diz respeito à coerência de onda. Luz coerente é aquela formada por ondas de mesma




Figura 1: Reflexão da energia emitida pelo sensor para diferentes graus de rugosidade da superfície (BOURGEAU CHAVEZ *et al.*, 2005).

frequência, fase e direção, característica existente nos sistemas SAR. Devido a essa propriedade, um tipo de ruído denominado *speckle* está sempre associado aos sensores de radar. O *speckle* é um ruído multiplicativo que é proporcional à intensidade do sinal recebido. Este efeito provoca uma variação nas intensidades dos *pixels* causando na imagem um padrão granular (LEE; POTTIER, 2009).

O sinal retornado dentro de uma célula de resolução forma a intensidade de cada *pixel* da imagem SAR. Este sinal consiste em ondas refletidas de vários refletos elementares (RODRIGUES, 2017). São apresentados na Figura 2, dois exemplos de duas células de resolução distintas. Observe que o fasor vermelho representa a soma (vetor resultante) dos sinais refletidos dentro de cada célula (fasores em azul). O comportamento aleatório dos fasores refletidos faz com que o fasor resultante tenha em sua formação a presença do *speckle*.

O vetor resultante ou fasor, como mostrado na Figura 2, é a representação de número complexo dado por:

$$S = Re(S) + jIm(S), \quad (2.1)$$

em que Re é a parte real de S , Im a parte imaginária e $j = \sqrt{-1}$. Em geral, é de interesse




Figura 2: Exemplos de dispersores em células de resolução com a respectiva soma dos sinais refletidos (MOREIRA *et al.*, 2013).

trabalhar com a amplitude (A) do vetor S , que é dada por:

$$A = \sqrt{\text{Re}(S)^2 + \text{Im}(S)^2}, \quad (2.2)$$

é possível também utilizar a intensidade (I) do vetor S , que é definida como $I = A^2$, ou seja, $I = \text{Re}(S)^2 + \text{Im}(S)^2$.

2.1.1 Processamento *multilook* de imagens SAR

Um método bastante utilizado em imagens SAR para reduzir o ruído *speckle* é o processamento de múltiplas visadas (*multilook*) (RODRIGUES, 2017). O processamento *multilook* refere-se à divisão do feixe do radar em vários subfeixes mais estreitos. Onde cada subfeixe fornece uma visada independente. Cada um destes *looks* é também sujeito ao *speckle*. O *speckle* é reduzido somando e fazendo a média dos vários *pixels* do *multilook* (HAYAKAWA *et al.*, 2017). Usualmente é atribuído L como o número de *looks* e as imagens com $L > 1$ são conhecidas por imagens de múltiplas visadas. No caso de $L = 1$, a imagem é denominada de visada única ou *single look*. São mostradas na Figura 3, duas imagens SAR reais da mesma região, mas com diferentes números de *looks*.

O processamento *multilooks* de imagens SAR não reduz somente o desvio padrão do ruído *speckle* mais também da informação de intensidade dos *pixels* (LI; YANG; XIONG,




Figura 3: Imagem SAR com diferentes números de *looks*: da esquerda para a direita 1 *look* e 8 *looks*, respectivamente (MOREIRA *et al.*, 2013).

2015). A imagem SAR resultante de um processamento *multilook* é supostamente mais fácil de ser processada por técnicas clássicas de segmentação e classificação. Contudo, nem sempre isso é possível por conta da redução da informação de intensidade dos *pixels* causada pelo processamento *multilook* (RODRIGUES, 2017).

2.2 Modelos estatísticos para dados SAR

2.2.1 Modelo multiplicativo

De acordo com Gao, Qin e Zhou (2013), a aquisição da primeira imagem SAR nos EUA na década de 1970 impulsionou o desenvolvimento de técnicas de modelagem estatística para dados SAR. Frery *et al.* (1997) afirmam que o uso de modelos estatísticos são essenciais para a modelagem destes dados. Neste contexto, o trabalho proposto por Arsenault e April (1976) foi um dos pioneiros na utilização de modelos estatísticos para análise de dados SAR.

Segundo Goodman (1963), o modelo multiplicativo pode ser usado para descrever dados SAR, a fim de lidar com ruído *speckle*. A utilização deste modelo tem conduzido várias técnicas ao sucesso em processamento e análise de imagens.

Seguindo o modelo proposto por Goodman (1963), a intensidade observada em cada *pixel* é o resultado de uma variável $Z : \Omega \rightarrow \mathbb{R}_+$ que, por sua vez, é o produto de duas variáveis aleatórias independentes: $X : \Omega \rightarrow \mathbb{R}_+$, que caracteriza a intensidade do retroespalhamento do terreno (*backscatter*); e $Y : \Omega \rightarrow \mathbb{R}_+$, que define a intensidade do ruído *speckle*.

$$Z = X \cdot Y. \quad (2.3)$$

Algumas propriedades multiplicativas entre variáveis aleatórias são abordadas nos estudos

de Lomnicki (1967). Dentre os modelos conhecidos na literatura, merecem destaque as distribuições $\mathcal{G}_I^0$ e $\mathcal{G}_A^0$ apresentadas em Frery *et al.* (1997).

À variável X , são atribuídos os diferentes níveis de reflectância e homogeneidade da superfície imageada, que variam de acordo com o tipo de terreno (urbano, floresta, pasto, rios, lagos, etc.). O retroespalhamento X não é associado a um fasor, e, assim, o retorno do sistema SAR pode ser processado em amplitude (MARQUES, 2011), como:

$$Z_A = X \cdot ||Y||, \quad (2.4)$$

ou em intensidade, como:

$$Z_I = X \cdot ||Y||^2. \quad (2.5)$$

O retorno pode ser ainda resultado da média de L observações de uma mesma cena, procedimento chamado de múltiplas visadas (*multilook*) (MARQUES, 2011). Neste caso, o retorno do sistema pode ser expresso como:

$$Z = X \frac{1}{L} \sum_{k=1}^L Y_k. \quad (2.6)$$

Este processo visa reduzir a influência do *speckle*, ao custo de reduzir também a resolução espacial da imagem. O modelo estatístico atribuído ao retorno Z depende diretamente do modo como os dados SAR são processados, em amplitude ou intensidade, do número L de visadas (*looks*), e do modelo atribuído à variável X . As distribuições associadas a X e Y podem variar conforme a região alvo e, também, em função do tipo de detecção, seja linear ou quadrática, produzindo diferentes distribuições para cada dado observado Z .

2.3 Modelos para dados em amplitude

Para modelar a amplitude dos dados no caso *multilook*, Y seguindo uma distribuição raiz quadrada de Gama, cuja função densidade de probabilidade é dada por:

$$f_{\sqrt{\Gamma}}(y, \lambda, \beta) = \frac{2\beta^\lambda}{\Gamma(\lambda)} y^{\lambda-1} \exp(-\beta y^2), \quad (2.7)$$

$$y, \lambda, \beta > 0.$$

em que λ e β são parâmetros distribucionais. Para imagem SAR tem-se $\lambda = L$ e $\beta = L$.

Comumente duas situações são consideradas para o retroespalhamento. Na primeira, em regiões heterogêneas, X segue uma distribuição raiz quadrada de Gama ($\sqrt{\Gamma}$). Na segunda, em regiões homogêneas, X converge em probabilidade para uma constante $\beta^{1/2}$ (MARQUES, 2011). A partir das duas situações estabelecidas, dois modelos são conhecidos para dados em amplitude e L looks, que são os seguintes:

- **Raiz quadrada de Gama($\sqrt{\Gamma}$)**. Modelo utilizado quando o retroespalhamento é homogêneo, com isso, o retorno SAR segue uma distribuição $\sqrt{\Gamma}$, e sua função densidade de probabilidade (fdp) é expressa como:

$$f_{\sqrt{\Gamma}}(z, L/\beta, L) = \frac{2L^L}{\beta^L \Gamma(L)} z^{2L-1} \exp(Lz^2/\beta), \quad (2.8)$$

$$z, \beta > 0, L \geq 1,$$

com momentos não centrais de ordem r

$$E_{\sqrt{\Gamma}}(Z^r) = \frac{\Gamma(L+r/2)}{(L/\beta)^{L/2} \Gamma(L)}. \quad (2.9)$$

- $\mathcal{K}$ – **Amplitude($\mathcal{K}_A$)**. Modelo utilizado quando se observa regiões heterogêneas, sua função densidade de probabilidade é dada por:

$$f_{\mathcal{K}_A}(z, \alpha, \lambda, L) = \frac{4\lambda n z}{\Gamma(\alpha) \Gamma(L)} (\lambda L z^2)^{(a+L)/2-1} K_{\alpha-L}(2z\sqrt{\lambda L}), \quad (2.10)$$

$$\alpha, \lambda, z > 0, L \geq 1,$$

com momentos não centrais de ordem r

$$E_{\mathcal{K}_A}(Z^r) = (L\lambda)^{-r/2} \frac{\Gamma(L+r/2) \Gamma(\alpha+r/2)}{\Gamma(\alpha) \Gamma(L)}. \quad (2.11)$$

2.4 Modelo $\mathcal{G}$ -Amplitude Zero

Esta seção apresenta uma breve descrição da distribuição $\mathcal{G}$ -Amplitude Zero proposto por Frery *et al.* (1997). O modelo $\mathcal{G}_A$ tem sua função densidade de probabilidade dada por:

$$f_{\mathcal{G}_A}(z, \alpha, \gamma, \lambda, L) = \frac{2L^L(\lambda/\gamma)^{\alpha/2}}{\Gamma(L)K_\alpha(2\sqrt{\lambda\gamma})} z^{2L-1} \times \left(\frac{\gamma + Lz^2}{\lambda}\right)^{(\alpha-L)/2} \times K_{\alpha-L}\left(\sqrt{\lambda(\gamma + Lz^2)}\right). \quad (2.12)$$

Com λ tendendo a zero, a distribuição $\mathcal{G}_A$ é chamada de $\mathcal{G}$ -Amplitude Zero e tem função densidade de probabilidade dada por:

$$f_{\mathcal{G}_A^0}(z, \alpha, \gamma, L) = \frac{2L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} \frac{z^{2L-1}}{(\gamma + Lz^2)^{L-\alpha}}, \quad (2.13)$$

$$-\alpha, \gamma, z > 0, L \geq 1,$$

e momentos não centrais de ordem r , para $\gamma > 0$ e $L \geq 1$

$$E_{\mathcal{G}_A^0}(Z^r) = \begin{cases} \left(\frac{\gamma}{L}\right)^{r/2} \frac{\Gamma(-\alpha - r/2) \Gamma(L + r/2)}{\Gamma(-\alpha) \Gamma(L)}, & \alpha < -r/2 \\ \infty, & \text{caso contrário} \end{cases} \quad (2.14)$$

A grande vantagem em utilizar a distribuição $\mathcal{G}_A^0$ é a flexibilidade da mesma descrever regiões homogêneas, heterogêneas, e, segundo Allende *et al.* (2006), regiões extremamente heterogêneas em imagens SAR. Um aspecto importante desta distribuição é que o parâmetro α tem interpretação física de rugosidade, podendo assim ser utilizado como uma medida de textura (FRERY *et al.*, 1997).

O modelo $\mathcal{G}_A^0$ tem sua função de distribuição acumulada (fda) dada por:

$$F_{\mathcal{G}_A^0}(z) = (\Upsilon_{2L}, -2\alpha) \left(\frac{-\alpha z^2}{\gamma} \right), \quad (2.15)$$

em que $\Upsilon_{2L}, -2\alpha$ é a sua função densidade de probabilidade da distribuição F-Snedecor com graus de liberdade $2L$ e -2α .

A função de distribuição acumulada expressa na Equação (2.15) apresenta solução numérica, bem como sua inversa ($F_{\mathcal{G}_A^0}^{-1}(z)$). Usando a transformada inversa Frery, Cribari-Neto e Souza (2004) fornecem um algoritmo para gerar amostras aleatórias através da identidade:

$$Z = \sqrt{-\frac{\gamma}{\alpha} \Upsilon_{2L, -2\alpha}^{-1}(U)}, \quad (2.16)$$

em que U é uma variável aleatória uniformemente distribuída no intervalo $(0,1)$.

2.5 Conclusão do capítulo

Neste capítulo foram contextualizados a geração de imagens SAR, geração do ruído *speckle* bem como o efeito que o mesmo tem sobre as imagens. Também foram analisados como o nível de rugosidade em diferentes tipos de terrenos afeta o retroespalhamento do sinal de retorno e, por consequência, a qualidade das imagens. Também revisamos os modelos para dados SAR em amplitude, seus momentos estatísticos e parâmetros distribucionais. Destacamos a distribuição $\mathcal{G}_A^0$, devido à sua capacidade de modelar dados homogêneos, heterogêneos e extremamente heterogêneos. Também foi apresentada a geração de amostras aleatórias, seguindo este modelo, pois é extremamente útil para geração de imagens sintéticas e realização de experimentos. O próximo capítulo mostra a estimativa dos mapas de parâmetros da distribuição $\mathcal{G}_A^0$, e são apresentados os métodos de log-cumulantes, o método original (MLC) proposto por Nicolas (2002) e o método *Fast Method of Log-Cumulants* (FMoLC) proposto por Rodrigues *et al.* (2016).


MÉTODO DOS MOMENTOS E ESTIMAÇÃO DE PARÂMETROS VIA MÉTODO DE LOG-CUMULANTES

Este capítulo apresenta algumas ferramentas para análise estatística de dados SAR, no qual a primeira seção discute a estimativa de parâmetros da distribuição, por meio do método dos momentos. Em seguida, serão apresentados dois métodos de estimação de parâmetros via método de log-cumulantes. Por fim, a obtenção dos mapas de parâmetros para imagens SAR por meio do método de log-cumulantes.


3.1 Estimação e interpretação dos parâmetros α e γ

Os parâmetros α e γ são interpretados, respectivamente, em termos de rugosidade e escala de amplitude dos dados SAR (DUAN *et al.*, 2018; GAMBINI *et al.*, 2006). É mostrada na Figura 4, a influência destes parâmetros para o comportamento da distribuição $\mathcal{G}_A^0$. Valores de rugosidade α próximos a zero ajustam dados de regiões heterogêneas, como florestas. À medida que os valores de α se tornam extremamente baixos ($\alpha \rightarrow -\infty$), mais homogêneas são as regiões, como as regiões de pasto. O parâmetro de escala γ é proporcional à amplitude de Z . É possível associar os valores de rugosidade ao espalhamento da distribuição, que também é influenciado pelo número de *looks*. Já o parâmetro de escala γ modifica, principalmente a média da distribuição, como visto na Figura 4 (MARQUES, 2011).

A estimativa dos parâmetros $\mathcal{G}_A^0$ foi amplamente discutida na literatura, dentre eles: o método dos momentos amostrais (MO) (FRERY *et al.*, 1997; MEJAIL *et al.*, 2003; GAMBINI *et al.*, 2008), máxima verossimilhança (MV) (FRERY; CRIBARI-NETO; SOUZA, 2004), estimadores robustos (BUSTOS; LUCINI; FRERY, 2002; ALLENDE *et al.*, 2006) e método de log-cumulantes (MLC) (NICOLAS, 2002). Em geral, as técnicas de estimativa acima mencionadas apresentam limitações semelhantes porque soluções analíticas não são alcançadas



(a)



(b)

Figura 4: Distribuição $\mathcal{G}_A^0(z, \alpha, \gamma, L)$ para: (a) $L = 1$ e (b) $L = 8$. Distribuição para $\gamma = 1$ (linha contínuas) e $\gamma = 10$ (linha tracejada), com três diferentes padrões de rugosidade: homogêneo $\alpha = -12,5$ (azul), heterogêneo $\alpha = -4,5$ (verde) e extremamente heterogêneo $\alpha = -1,5$ (vermelho) (MARQUES, 2011).

e problemas numéricos podem surgir.

O método de estimação por máxima verossimilhança é consistente e apresenta estimadores eficientes. No entanto, como observado por Mejail *et al.* (2003), leva a problemas numéricos sempre que a estimativa é realizada em pequenas amostras sobre áreas homogêneas. Além disso, o tempo de computação necessário para realizar a estimativa de parâmetros é outro problema relevante (CHITROUB; HOUACINE; SANSAL, 2002). Em relação ao método dos momentos, este pode ser aplicado com facilidade e sucesso para estimar os parâmetros de distribuição $\mathcal{G}_A^0$ (GAO, 2010) dado que, em geral, são consistentes e numericamente eficientes (SEN; SINGER; LIMA, 2010).

No processo de estimação dos parâmetros em imagens SAR devemos considerar a utilização de pequenas amostras, pois, o uso de grandes amostras obtidas com grandes janelas normalmente causa desfocagem nos dados resultantes (MEJAIL *et al.*, 2003). O trabalho de Marques (2011) utiliza o método de momentos amostrais (MO) para estimação de parâmetros. Fazendo $r = 1$ e $r = 1/2$ na Equação (2.14), o sistema obtido pode ser reduzido para se obter a estimativa de α , por meio da solução numérica do seguinte problema:

$$\frac{\Gamma^2(-\hat{\alpha} - 1/4)}{\Gamma(-\hat{\alpha})\Gamma(-\hat{\alpha} - 1/2)} - \frac{\hat{m}_{1/2}^2}{\hat{m}_1} \frac{\Gamma(L)\Gamma(L + 1/2)}{\Gamma^2(L + 1/4)} = 0, \quad (3.1)$$

sendo $\hat{m}_1$ e $\hat{m}_{1/2}$ os momentos amostrais estimados de ordem 1 e 1/2, respectivamente.

As estimativas de $\hat{m}_1$ e $\hat{m}_{1/2}$ são realizadas em uma janela 3 x 3 centrada em cada pixel z da imagem. Uma estimativa $\hat{\alpha}$ é obtida solucionando-se a Equação (3.1) e uma estimativa $\hat{\gamma}$ é obtida da substituição de $\hat{\alpha}$ na Equação (2.14), levando à dois mapas de parâmetros estimados, $\hat{\alpha}$ e $\hat{\gamma}$.

3.2 Estimação de parâmetros via método de log-cumulantes

Nesta seção são apresentadas duas ferramentas para a estimação de parâmetros da distribuição $\mathcal{G}_A^0$ via método de log-cumulantes. A primeira seção apresenta o método MLC e na seção seguinte é destacada uma abordagem rápida do método de log-cumulantes (FMoLC).

3.2.1 Método de Nicolas (2002) para a estimação de parâmetros via método log-cumulantes

O método de log-cumulantes (MLC) é uma técnica de estimação de parâmetros desenvolvida para funções de densidade de probabilidade definida em $\mathbb{R}^+$, com base na transformação integral de Mellin (CHENG *et al.*, 2013; GAO; QIN; ZHOU, 2013; NICOLAS, 2002; TISON *et al.*, 2004) e é adequado para distribuições definidas como produtos de variáveis aleatórias (MOSER; ZERUBIA, 2011). Este é um caso frequente em aplicações de processamento de sinal, incluindo sinais coletados por sistemas de aquisição ativos, como radar e sonar em sensoriamento remoto (VILLANO *et al.*, 2018) e ultrassom em imagens médicas (ISONO; HIRATA; HACHIYA, 2015).

Segundo Krylov *et al.* (2013) o MLC tem sido utilizado com resultados satisfatórios em processamentos de imagens SAR, especialmente para pequenas amostras tornando-o adequado em várias aplicações. Pesquisadores têm utilizado os parâmetros estimados pelo método de log-cumulantes como entradas, por exemplo, para métodos de classificação de imagens SAR (SINGH; DATCU, 2013) e detecção de mudanças em imagens SAR multitemporais (BUJOR *et al.*, 2004).

Seja Z uma variável aleatória contínua com função densidade de probabilidade $f_Z(z, \theta)$ definida em $\mathbb{R}^+$. O método de log-cumulantes é baseado na transformada de Mellin de $f_Z(z, \theta)$, dada por:

$$\phi_Z(s) = \int_0^\infty u^{s-1} f_Z(u, \theta) du = E[Z^{s-1}], \quad (3.2)$$

em que s é um número complexo com norma unitária (NICOLAS, 2002).

Os log-momentos e log-cumulantes de ordem ν são fatores importantes na construção do método log-cumulantes. Expressões analíticas para os log-momentos e log-cumulantes de ordem ν são obtidas por derivações de $\phi_Z(s)$ e baseadas no logaritmo natural de $\phi_Z(s)$, respectivamente, avaliadas em $s = 1$ (NICOLAS, 2002; CHENG *et al.*, 2013):

• Log-momentos:

$$\tilde{m}_\nu = \left. \frac{d^\nu \phi_Z(s)}{ds^\nu} \right|_{s=1}, \nu \in \mathbb{N}. \quad (3.3)$$

- Log-cumulantes:

$$\tilde{k}_v = \left. \frac{d^v \Psi_z(s)}{d s^v} \right|_{s=1}, v \in \mathbb{N}. \quad (3.4)$$

com $\tilde{k}(s) = \ln(\phi_z(s))$.

O vetor de parâmetros θ , para um $\theta = (\alpha, \gamma)$, pode ser estimado pela fórmula de *Faà di Brunno*'s que baseia-se na relação entre os log-momentos e log-cumulantes (DENG *et al.*, 2017) e é dada por:

$$\tilde{k}_v = \tilde{m}_v - \sum_{i=1}^{v-1} \binom{v-1}{i-1} \tilde{k}_i \tilde{m}_{v-i}. \quad (3.5)$$

Como exemplo, é destacado os log-momentos e log-cumulantes de ordem 1 e 2 como tendo a seguinte relação:

$$\begin{cases} \tilde{k}_1 = \tilde{m}_1 \\ \tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2 \end{cases} \quad (3.6)$$

Em geral, $\tilde{k}_v$ é função do vetor de parâmetros θ e a estimação de θ é feita substituindo $\tilde{m}_v$ pelo correspondente log-momento amostral, que é dado por (NICOLAS, 2002):

$$\hat{m}_v = \frac{1}{L} \sum_{i=1}^n \ln z_i^v, \quad (3.7)$$

em que z_i , $i \in \{1, 2, \dots, L\}$, é uma amostra da variável aleatória Z .

A função $\phi_Z(s)$ da distribuição $\mathcal{G}_A^0$ pode ser obtida aplicando a Equação (3.2), e utilizando a Equação (2.14) para obter $E[Z^{s-1}]$, e portanto,

$$\phi_{\mathcal{G}_A^0}(s) = \left(\frac{\gamma}{L}\right)^{\frac{s-1}{2}} \frac{\Gamma(\frac{1-s}{2} - \alpha) \Gamma(L + \frac{s-1}{2})}{\Gamma(-\alpha) \Gamma(L)}, \quad (3.8)$$

com $\alpha < \frac{1-s}{2}$. A partir da Equação (3.4) obtém-se o seguinte sistema de equações (CUI; SCHWARZ; DATCU, 2014):

$$\begin{cases} 2\tilde{k}_1 = \log\left(\frac{\gamma}{L}\right) + \psi^0(L) - \psi^0(-\hat{\alpha}) \\ 4\tilde{k}_2 = \psi^1(L) - \psi^1(-\hat{\alpha}), \end{cases} \quad (3.9)$$

com $\psi^0(\cdot)$ e $\psi^1(\cdot)$ sendo as funções digamma e trigamma, respectivamente.

As funções $\psi^0(\cdot)$ e $\psi^1(\cdot)$ não admitem inversa, logo a solução do sistema na Equação (3.9) não pode ser obtida explicitamente e portanto, procedimentos numéricos são necessários. Contudo, estes procedimentos são computacionalmente lentos. Na próxima seção é apresentada uma proposta rápida do método de log-cumulantes proposta por Rodrigues *et al.* (2016), em que os autores utilizam propriedades da função gama para sugerir uma mudança analítica que reduz o custo computacional do método de log-cumulantes.

3.2.2 Método de Rodrigues *et al.* (2016) para a estimação de parâmetros via método de log-cumulantes

Nesse estudo, os autores propõem uma abordagem rápida do método MLC para a estimação dos parâmetros de rugosidade (α) e escala (γ) da distribuição $\mathcal{G}_A^0$ por meio da solução do sistema descrito na Equação (3.9).

Inicialmente os autores consideraram que $\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2$. Com isso, a única variável (incógnita) na segunda equação do sistema descrito na Equação (3.9) é o parâmetro de rugosidade (α) com um argumento da função trigama $4(\tilde{m}_2 - \tilde{m}_1^2) = \psi^1(L) - \psi^1(-\alpha)$. Para solucionar o sistema o método consiste de duas etapas, primeiro encontra-se um estimador ($\hat{\alpha}$) para o parâmetro de rugosidade (α) considerando a identidade $4(\tilde{m}_2 - \tilde{m}_1^2) = \psi^1(L) - \psi^1(-\alpha)$. Em seguida, é feita a substituição de α por $\hat{\alpha}$ na primeira equação do sistema descrito na Equação (3.9), resultando assim em estimadores para o parâmetro de escala (γ) (RODRIGUES *et al.*, 2016).

Para a obtenção dos estimadores de rugosidade são utilizadas duas identidades, sendo a primeira a função poligama (BLANCHARD; BRÜNING, 2015):

$$\psi^n(w) = \frac{d^{n+1} \ln(\Gamma(w))}{dw^{n+1}}, \quad (3.10)$$

em que $n \in \mathbb{N}^*$ e $w > 0$.

A segunda é a representação alternativa da função gama (BEYER, 2018):

$$\Gamma(w) = \frac{1}{w e^{tw} \prod_{k=1}^{\infty} \left(1 + \frac{w}{k}\right) e^{-\frac{w}{k}}}, \quad (3.11)$$

em que $t = 0,5772156649\dots$ é a constante de Euler-Macheroni. Aplicando o logaritmo natural na Equação (3.11), obtém-se:

$$\ln(\Gamma(w)) = -\ln(w) - tw - \sum_{k=1}^{\infty} \left[\ln\left(1 + \frac{w}{k}\right) - \frac{w}{k} \right]. \quad (3.12)$$

Utilizando a Equação (3.10) o termo $\psi^1(-\alpha)$ pode ser reescrito como:

$$\psi^1(-\alpha) = \frac{d^2 \ln(\Gamma(-\alpha))}{d(-\alpha)^2}. \quad (3.13)$$

Desenvolvendo as derivadas parciais do lado direito da Equação (3.13), em que $\ln(\Gamma(-\alpha))$ pode ser obtido substituindo w por $-\alpha$ na Equação (3.12), tem-se:

$$\psi^1(-\alpha) = \sum_{k=0}^{\infty} \frac{1}{(k-\alpha)^2}, \quad (3.14)$$

ou ainda:

$$\psi^1(-\alpha) = \frac{1}{(-\alpha)^2} + \sum_{k=1}^{\infty} \frac{1}{(k-\alpha)^2}. \quad (3.15)$$

Os autores destacam que apenas o segundo termo da soma infinita da Equação (3.15) é considerado como uma aproximação para $\psi^1(-\alpha)$, ou seja:

$$\psi^1(-\alpha) = \frac{1}{\alpha^2} + O\left(\frac{1}{-\alpha}\right), \quad (3.16)$$

$\alpha > 0.$

Por tanto, para encontrar o estimador para os parâmetros de rugosidade e escala da distribuição $\mathcal{G}_A^0$, inicialmente o termo $\psi^1(-\alpha)$ é substituído em $4(\tilde{m}_2 - \tilde{m}_1^2) = \psi^1(L) - \psi^1(-\alpha)$ pela aproximação dada na Equação (3.16), de modo que:

$$\hat{\alpha} = \begin{cases} -\left| \sqrt{\frac{1}{\psi^1(L) - 4\tilde{k}_2}} \right|, & \psi^1(L) - \tilde{k}_2 < 0 \\ -\sqrt{\frac{1}{\psi^1(L) - 4\tilde{k}_2}}, & \psi^1(L) - \tilde{k}_2 > 0 \end{cases}, \quad (3.17)$$

em que $|\cdot|$ corresponde ao operador norma. Finalmente, o estimador para γ é obtido substituindo α na primeira expressão da Equação (3.9) por seu estimador $\hat{\alpha}$, proposto na Equação (3.17). Assim, o estimador para o parâmetro γ é dado por:

$$\hat{\gamma} = \exp[2\tilde{k}_1 - \psi^0(L) + \psi^0(-\hat{\alpha})]L. \quad (3.18)$$

3.2.3 Estimativa dos mapas de parâmetros para a distribuição $\mathcal{G}_A^0$

A estimação dos mapas de parâmetros para a distribuição $\mathcal{G}_A^0$ é realizada pelo método FMoLC, que é uma alternativa às abordagens clássica de máxima verossimilhança (MV) e método dos momentos amostrais (MO) (RODRIGUES *et al.*, 2016). As características particulares dos parâmetros da distribuição α (rugosidade) e γ (escala) são relevantes para caracterizar dados de SAR com diferentes naturezas de retroespalhamento, conforme relatado em Gambini *et al.* (2008). A estimativa desses parâmetros pode ser realizada pelo método MO ou MV. No entanto, a capacidade do método log-cummulantes (FMoLC) é destacado no trabalho de Rodrigues *et al.* (2016), em que os autores confirmam que o FMoLC gera estimadores fortemente consistentes, incluindo situações em que o MO falhou. Além disso, o FMoLC é computacionalmente mais rápido que o MLC.

Nesta dissertação, o principal aspecto para a escolha do FMoLC é que o histograma dos parâmetros estimados de rugosidade pode ser um indicativo do número de regiões presentes nas imagens, como visto na Figura 5. São exibidas na Figura 5(a) duas imagens SAR sintéticas; os resultados dos mapas de parâmetros estimados pode ser visto na Figura 5(b); e, por fim, o histograma de rugosidade pode ser visto na Figura 5(c). A hipótese apresentada nesta dissertação é que essa capacidade aprimore o desempenho da segmentação do método SVM. A estimativa dos mapas de parâmetros via FMoLC é obtida resolvendo as Equações (3.17) e (3.18), sendo que amostra considerada para cada estimativa é uma janela de 7x7 centralizada em cada *pixel*.




Figura 5: Mapa de rugosidade obtido pelo método FMoLC para duas imagens simuladas em amplitude usando $\alpha = \{(-1,5; -8,0)\}$. (a) imagem SAR sintéticas, (b) mapas de rugosidade estimados e (c) histograma de rugosidade.

3.3 Conclusão do capítulo

Neste capítulo são apresentadas as estimativas dos mapas de parâmetros da distribuição, por meio do método dos momentos. Em seguida é discutido o método de log-cumulantes (MLC) proposto por Nicolas (2002) e uma abordagem rápida *Fast Method of Log-Cumulants* (FMoLC) proposto por Rodrigues *et al.* (2016). Por fim, é apresentado a estimativa dos mapas de parâmetros pelo método FMoLC abordada nesta dissertação.

MÉTODOS PARA SEGMENTAÇÃO DE IMAGENS SAR

Este capítulo apresenta técnicas para segmentação de imagens SAR, no qual é abordado o algoritmo SVM, em seguida são apresentados três algoritmos encontrados na literatura para segmentação de imagens SAR, e que são adotados nesta dissertação para comparação de resultados. Também é discutida a técnica SVM proposta nesta dissertação com base nos parâmetros da distribuição $\mathcal{G}_A^0$ para segmentação de imagens SAR. Na última seção é apresentado um conjunto de métricas para avaliar, com base em distâncias estocásticas, o nível de contraste de uma imagem e o ajuste estatístico entre regiões de duas imagens (referência e segmentada).

4.1 Segmentação de imagens SAR

A segmentação de imagens consiste no processo de agrupamento de *pixels* que possuem características semelhantes. De acordo com Gao (2010), trata-se da decomposição de uma imagem em regiões discretas, contíguas e que não se interceptam, constituindo, semanticamente, segmentos significativos. A segmentação de imagens é uma das tarefas mais relevantes no processamento de imagens digitais pois é amplamente utilizada em diferentes campos de pesquisa, tais como aplicações em imagens SAR, visão computacional e processamento de imagens médicas, dentre outras (LIMA, 2016).

O processo pode ocorrer de forma manual ou automática. A forma manual nada mais é do que estabelecer sobre a imagem os polígonos que representam regiões homogêneas. Como é comum nesses casos, diferentes intérpretes podem gerar produtos diferentes a partir de uma mesma imagem. O processo automático, por considerar dados de natureza quantitativa, produz resultados bons em uma fração do tempo muito menor do que seria dispendido no caso da segmentação manual (LIMA, 2016). Em virtude desses aspectos, tal método é mais utilizado em processamento de imagens.

No entanto, a presença do ruído *speckle* em imagens SAR é um fator que tem grande interferência na segmentação das imagens. Uma vez que a distribuição de intensidade de *pixels*, em geral, não é bi-modal ou multimodal, técnicas de pré-processamento são comumente utilizadas com o intuito de reduzir a interferência do ruído, com tudo, algumas dessas técnicas como a filtragem degradam as características da imagem. Com isto, a escolha de uma distribuição de probabilidade apropriada para descrever dados SAR é fundamental na segmentação de imagens. Pensando nisto, adotamos a distribuição de probabilidade $\mathcal{G}_A^0$ proposta por Frery *et al.* (1997), e para estimar os parâmetros desta distribuição utilizamos o método rápido de FMoLC proposto por Rodrigues *et al.* (2016).

4.2 Máquinas de Vetores Suporte

As Máquinas de Vetores Suporte (*Support Vector Machines, SVM*) são classificadores de aprendizado supervisionado que analisam os dados e reconhece padrões, adquirindo, com o aprendizado na etapa de treinamento, a capacidade de generalização (HAYKIN, 2000).

SVMs têm recebido bastante atenção da comunidade de Aprendizagem de Máquinas. Segundo ROCHA NETO (2011), uma das justificativas para a difusão do uso de classificadores SVM pode estar em sua teoria matemática bem fundamentada. O SVM é embasado pela Teoria de Aprendizado Estatístico (TAE), desenvolvida por Vapnik (1998), que visa a minimização do erro empírico e estrutural e estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização.

As SVMs buscam minimizar o erro com relação ao conjunto de treinamento (risco empírico, R_{emp}), assim como o erro com relação ao conjunto de teste (risco estrutural, R_{est}) visando obter um equilíbrio entre esses erros, minimizando o excesso de ajustes com respeito às amostras de treinamento (*overfitting*) e aumentando consequentemente a capacidade de generalização. Na tarefa de classificação, cada padrão do conjunto de treinamento pode ser visto como um ponto $\mathbf{x}_i$ num espaço $\mathbb{R}^p$. O aprendizado consiste em dividir os elementos positivos dos negativos neste espaço euclidiano.

Considere um conjunto de dados de treinamento $\{\mathbf{x}_i, y_i\}_{i=1}^l$ onde $\mathbf{x}_i \in \mathbb{R}^p$ é um vetor de entrada e $y_i \in \{-1, +1\}$ são os rótulos das classes correspondentes. Para classificação de margem flexível, o problema primal SVM (VAPNIK, 1998) é definido como

$$\begin{aligned}
\min_{\mathbf{w}, b, \xi} \left\{ \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i \right\}, \\
y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \\
\xi_i \geq 0.
\end{aligned} \tag{4.1}$$

em que C é um parâmetro que permite algum grau de erro de classificação, e que $\{\xi_i\}_{i=1}^l$ é o conjunto de variáveis de folga, b é o viés e C é um parâmetro de custo que controla o compromisso entre erros de classificação e a complexidade do modelo. A solução do problema descrito na Equação (4.1) é o ponto de sela da seguinte função Lagrangeana:

$$L(\mathbf{w}, b, \xi_i, \alpha_i, \beta_i) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l [\alpha_i (y_i(\mathbf{x}_i^T \mathbf{w} + b) - 1 + \xi_i) + \sum_{i=1}^n \beta_i \xi_i], \tag{4.2}$$

em que $\{\alpha_i\}_{i=1}^l$ e $\{\beta_i\}_{i=1}^l$ são multiplicadores de Lagrange. Para resolver este problema a Equação (4.2) deve ser minimizado em relação a $\mathbf{w}$, b e ξ_i , bem como maximizada em relação a α_i e β_i (multiplicadores de Lagrange). Logo para encontrar a solução do problema da Equação (4.2), é necessário calcular as seguintes diferenciações:

$$\frac{\partial L(\mathbf{w}, b, \xi_i, \alpha_i, \beta_i)}{\partial \mathbf{w}} = \mathbf{0}, \quad \frac{\partial L(\mathbf{w}, b, \xi_i, \alpha_i, \beta_i)}{\partial b} = 0 \quad \text{e} \quad \frac{\partial L(\mathbf{w}, b, \xi_i, \alpha_i, \beta_i)}{\partial \xi_i} = 0,$$

resultando em

$$\mathbf{w} = \sum_{i=1}^l \alpha_i y_i \mathbf{x}_i, \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad \text{e} \quad C = \alpha_i + \beta_i,$$

respectivamente. Então, introduzindo estas expressões na Equação (4.2), o problema de otimização dual do SVM também pode ser apresentado como:

$$\begin{aligned}
\max_{\alpha} \left\{ \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right\}, \\
\sum_{i=1}^l \alpha_i y_i = 0, \\
0 \leq \alpha_i \leq C.
\end{aligned} \tag{4.3}$$

em que $\{\alpha_i\}_{i=1}^l$ é o conjunto de multiplicadores de Lagrange. Depois de resolver o problema e ter os multiplicadores de Lagrange e o viés por otimização mínima sequencial (Sequential Minimal Optimization, SMO) (PLATT, 1999), Kernel Adatron (KA) (ANLAUF; BIEHL, 1989) ou métodos clássicos de otimização matemática (QP) (BHATTI, 2012), a saída pode

ser calculada com base na função de decisão:

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^l \alpha_i y_i \mathbf{x}^T \mathbf{x}_i + b \right), \quad (4.4)$$

em que valores positivos são associados a padrões pertencente à classe $y_i = +1$, enquanto valores negativos são associados a padrões pertencentes à classe $y_i = -1$. Vale ressaltar que o produto interno $\mathbf{x}^T \mathbf{x}_i$ pode ser substituído aqui e na Equação (4.3) por uma função de Kernel $k(\mathbf{x}, \mathbf{x}_i)$.

Assim é possível usar o *truque do kernel* para gerar versões não lineares do classificador SVM linear padrão. Uma função simétrica $k(\mathbf{x}, \mathbf{x}_i)$ é um Kernel se satisfazer a condição *Mecer*, ou seja, a função $K(\cdot, \cdot)$ é definida (semi) positiva. Neste caso, existe um mapeamento $\phi(\cdot)$ tal que é possível escrever $K(\mathbf{x}, \mathbf{x}_i) = \phi(\mathbf{x}) \cdot \phi(\mathbf{x}_i)$. O kernel representa um produto interno no espaço de características no qual os vetores originais são mapeados (HAYKIN, 2001).

4.3 Técnicas aplicadas ao processamento de imagens SAR

4.3.1 Método de Ping *et al.* (2009) para segmentação de imagens SAR

Ping *et al.* (2009) abordam em seu trabalho um algoritmo iterativo baseado em SVM para segmentação de imagens SAR no conjunto de dados MSTAR para o reconhecimento de alvos militares (veículos blindados: BMP-2, BRDM-2, BTR-60 e BTR-70; tanque: T-62, T-72; lança-foguetes: 2S1 unidade de defesa aérea: ZSU-234; caminhão: ZIL-131; bulldozer: D7). É demonstrado na Figura 6 um exemplo das imagens utilizadas pelos autores.




Figura 6: Imagem de tanque de guerra do conjunto de dados MSTAR.

Os autores consideram a segmentação como uma classificação de *pixels*. Os *pixels* da imagem segmentada anterior são considerados como amostras de treinamento para o SVM, que é usado para re-segmentar a imagem. Essas iterações são repetidas até a convergência, que é determinada pela verificação da alteração relativa da entropia entre duas imagens segmentadas consecutivas. A Figura 7 mostra o fluxograma que resume o algoritmo proposto pelos autores.




Figura 7: Fluxograma do algoritmo (PING *et al.*, 2009)

- Passo 1: Segmentação inicial

O processo é iniciado realizando-se uma segmentação por meio de limiar para identificar os rótulos das classes. Considerando o fato de que os pontos-alvo são mais brilhantes, enquanto os pontos de sombra são mais escuros, os limites do objeto e da sombra são definidos por meio do cálculo da média e da variância da imagem (*img*) e do fundo (*back*), respectivamente: v_{img} , σ_{img}^2 , v_{back} , σ_{back}^2 . Os limites são:

$$TH_{tar} = v_{img} + 1,2\sigma_{img}^2 \quad (4.5)$$

$$TH_{shard} = v_{back} - 1,2\sigma_{back}^2 \quad (4.6)$$

TH_{tar} e TH_{shard} são o limiar de segmentação da área alvo e área de sombra, respectivamente.

Suponha que o rótulo x_i após segmentação se refira ao *pixel* y_i na imagem, a segmentação inicial pode ser descrita como:

$$x_i = \begin{cases} 1 & (\text{Sombra}) & y_i \leq TH_{shard} \\ 2 & (\text{Fundo}) & TH_{shard} < y_i \leq TH_{tar} \\ 3 & (\text{Objeto}) & y_i > TH_{tar} \end{cases} \quad (4.7)$$

Devido à influência do ruído *speckle*, podem existir pseudo-alvos e pontos de pseudo-sombra na imagem segmentada. Utiliza-se o processo de filtragem por meio do filtro de contagem, selecionando a maior região conectada, de modo a garantir a qualidade das amostras de treinamento e o desempenho do classificador obtido por essas amostras.

- Passo 2: Extração de características

A extração de características de amostras de treinamento, não apenas usa o valor de cinza dos *pixels* como valor de entrada do treinamento, mas também considera a correlação entre os *pixels*. Como resultado, utiliza-se uma janela deslizante 3x3 para tratar o valor cinza de cada *pixel* e seus 8 *pixels* vizinhos como vetores de características de dimensão 9x1.

- Passo 3: Treinamento

Utiliza os vetores de características e seus correspondentes rótulos de classe, adquiridos nas etapas (1) e (2), como amostras para treinar o SVM.

- Passo 4: Classificação

Utiliza-se a imagem original para realizar a classificação e obter a imagem segmentada que contém objeto, sombra e fundo.

- Passo 5: Pós-processamento de segmentação

Afim de eliminar possíveis *pixels* mal segmentados e garantir melhores amostras de treinamento nas próximas iterações utiliza-se novamente o filtro de contagem.

- Passo 6: Iteração

O processo de iteração utiliza as imagens segmentadas pelo SVM para extração de novas amostras. Em seguida, as novas amostras são utilizadas para treinar novamente o classificador. Em seguida, utiliza-se a imagem original para o novo classificador SVM para obter um novo resultado de segmentação. Como critério de parada para esta iteração os autores utilizaram a diferença de entropia de duas imagens segmentadas. A entropia da imagem é definida como:

$$H = P_1 \times \ln(1/P_1) + P_2 \times \ln(1/P_2) \quad (4.8)$$

em que P_1 é a relação entre o número de pontos de sombra e o número total de *pixels* na imagem, e P_2 denota a razão entre o número de pontos do objeto e o número total de *pixels* da imagem. O processo de iteração se encerra quando é atingida a condição $|H_n - H_{n-1}| < \beta$. Para $\beta = 0,004$.

4.3.2 Método de Tripathi *et al.* (2015) para segmentação de imagens SAR

Tripathi *et al.* (2015) propõem em seu trabalho uma abordagem probabilística para classificação de imagem baseada no classificador de Bayes para imagens SAR. Os autores utilizam classificação para imagens com diferentes polarizações HH, HV e VV. Este método determina a atribuição de classe a um *pixel* específico com base na média, variância e correlação do valor do *pixel* no conjunto de dados de treinamento que está sendo fornecido (PRADHAN; GHOSE; JEYARAM, 2010).

A abordagem Bayesiana é uma maneira particular de formular e lidar com problemas de decisão estatística. A função de decisão de Bayes é dada como (RUIZ *et al.*, 2014; SAMSÓ *et al.*, 2002):

$$p(c|x = v) = \frac{p(x = v|c) * p(c)}{p(x = v)} \quad (4.9)$$

onde μ_c é a média de uma determinada classe, σ_c é a variância de uma dada classe e v é a matriz de uma dada classe.

4.3.3 Método de Maiti e Kumar (2012) para segmentação de imagens SAR

Maiti e Kumar (2012) abordam em seu trabalho a segmentação de imagens SAR para detecção de áreas florestais com base no algoritmo KNN (k-Nearest Neighbor) usando como métrica a distância euclidiana. Os autores adotam como pré-processamento o processo de filtragem da imagem através do filtro de Frost com janela 5x5 na tentativa de reduzir a influência do ruído *speckle*.

O algoritmo dos k -vizinhos mais próximos é um método não paramétrico utilizado para classificação e regressão (BIAU; DEVROYE, 2015). Dado um conjunto de dados $\mathcal{D} = \{(\mathbf{x}_n, y_n)\}_{n=1}^N$, em que $\mathbf{x}_n \in \mathbb{R}^D$ é um vetor de características e $y_n \in \mathbb{N}$ é seu respectivo rótulo;

uma métrica de similaridade $\delta(\mathbf{x}_i, \mathbf{x}_j)$ entre dois pontos $\mathbf{x}_i$ e $\mathbf{x}_j$; e um tamanho de vizinhança¹ $k \in \mathbb{N}^*$. O classificador baseado na regra dos k -vizinhos mais próximos determina uma aproximação y do rótulo de um vetor de características $\mathbf{x}$, não utilizado na etapa de treinamento, através da classe majoritária do subconjunto $\mathcal{N} \subseteq \mathcal{D}$ dos k padrões mais similares a $\mathbf{x}$.

De maneira mais específica, o classificador KNN realiza os seguintes passos:

1. Criação do conjunto $\mathcal{N} = \{(\mathbf{x}_{n_k}, y_{n_k})\}_{k=1}^K \subseteq \mathcal{D}$ dos k vizinhos mais próximos a $\mathbf{x}$, tal que, para qualquer par ordenado $(\mathbf{x}_n, y_n) \in \mathcal{D} \setminus \mathcal{N}$:

$$\delta(\mathbf{x}, \mathbf{x}_{n_i}) \leq \delta(\mathbf{x}, \mathbf{x}_n), \quad \forall i \in \{1, \dots, K\}, \quad (4.10)$$

2. Estimação da moda entre os rótulos dos elementos pertencentes a $\mathcal{N}$:

$$y = \arg \max_{y \in \mathbb{R}^S} \sum_{k=1}^K \mathbf{1}_y(\mathbf{x}_{n_k}, y_{n_k}) \quad (4.11)$$

em que $\mathbf{1}_y(\cdot)$ é uma função indicadora, definida por

$$\mathbf{1}_y(y_n) = \begin{cases} 1, & \text{se } y_n = y, \\ 0, & \text{se } y_n \neq y. \end{cases} \quad (4.12)$$

4.3.4 Método proposto para segmentação de imagens SAR

Nesta seção é apresentada uma abordagem para segmentação de imagens SAR, que constitui o resultado dos estudos sobre a combinação da técnica SVM e a estatística presente nos dados com ruído *speckle*. Estes estudos se concentram no modelo de distribuição $\mathcal{G}_A^0$ adotado para modelagem dos dados em regiões homogêneas, heterogêneas e extremamente heterogêneas de uma imagem SAR, em amplitude.

A proposta inicial deste estudo se fundamenta na técnica de log-cumulantes proposta por Rodrigues *et al.* (2016) em que os autores propõem uma abordagem rápida do método MLC para a estimação dos parâmetros de rugosidade (α) e escala (γ) da distribuição $\mathcal{G}_A^0$ por meio da solução do sistema descrito na Equação (3.9).

Fornecidos os parâmetros L (número de looks) e N (número de classes a serem segmentadas), o primeiro passo do algoritmo é estimar os mapas de parâmetros de rugosidade (α) e escala (γ). Os mapas são estimados usando o método rápido de log-cumulantes,

¹Note que k é usualmente um valor ímpar, para prever situações de empate.

considerando uma amostra 7×7 no entorno de cada *pixel*. Um exemplo dos mapas de parâmetros é mostrado na Figura 8. Assim, cada *pixel* é então representado por um vetor de duas características (rugosidade e escala). Estas são as características usadas no treinamento do classificador SVM e posterior classificação. Desta forma o processo não depende, diretamente, dos valores dos *pixels* e portanto não sofre influência do ruído *speckle*.

No passo seguinte, o treinamento, uma amostra retangular de cada região é delimitada. O tamanho, posição e precisão da amostra variam em cada teste, porém estas não tem passado de 30% do total de pontos da imagem, nos experimentos com imagens reais. A última etapa consiste da segmentação, que é obtida submetendo-se toda imagem ao classificador treinado.




Figura 8: Mapa de parâmetros de (a) rugosidade e (b) escala resultantes da estimativa de log-cumulantes.

Algoritmo 1 SARSVM

Entrada:

- 1: L = número de looks
- 2: N = número de classes

Saída:

- 3: Compor o conjunto de dados para teste (α e γ) de acordo com a Equação: 3.9
 - 4: **for** $i = 1 : N$
 - 5: Selecionar de forma manual amostras das regiões para composição do conjunto de dados de treinamento
 - 6: **end for**
 - 7: Executar a etapa de treinamento para o classificador SVM
 - 8: Segmentar as imagens de acordo com os modelos criados
-

Nesta proposta, foi utilizada a função de kernel de base radial (RBF), por ser vastamente referenciada em trabalhos de segmentação de dados de sensoriamento remoto utilizando

SVM (PETROPOULOS; ARVANITIS; SIGRIMIS, 2012). Vale ressaltar que o SVM é um classificador binário e por se tratar de um problema multiclases, uma vez que se pretende classificar imagens em até três classes, adotou-se a metodologia de classificação ‘um contra todos’. As classes estipuladas de interesse são, por exemplo, nomeadamente: água, área urbana e vegetação. Sendo assim, ao se utilizar esta metodologia de ‘um contra todos’, foram treinados SVM especializados em cada classe, ou seja, um SVM que separa água das demais classes, área urbana das demais classes e assim por diante. Ao final da classificação de cada SVM, os resultados são agrupados e têm-se todas as classes classificadas.

4.4 Métricas para análise de dados SAR

Esta seção apresenta uma metodologia para análise de dados SAR com base nos estudos de distâncias estocásticas de Frery, Nascimento e Cintra (2010) e Nascimento, Cintra e Frery (2010). O objetivo é fornecer métricas para avaliar quantitativamente os resultados experimentais.

Distâncias estocásticas são utilizadas para comparar e analisar distribuições de probabilidade definidas no mesmo espaço de probabilidades e mesmo suporte. Em outras palavras, as distâncias estocásticas são úteis para investigar se duas amostras aleatórias podem ser consideradas realizações de uma mesma distribuição de probabilidade. Em Nascimento, Cintra e Frery (2010) é apresentada uma relação de distâncias estocásticas, dentre as quais se encontra a distância aritmética-geométrica, adotada neste trabalho.

Sejam Z_1 e Z_2 variáveis aleatórias contínuas definidas no mesmo espaço de probabilidades, com funções densidades de probabilidade $f_{Z_1}(z; \theta_1)$ e $f_{Z_2}(z; \theta_2)$, respectivamente, em que θ_1 e θ_2 são vetores de parâmetros. Assumindo que ambas as densidades compartilham um suporte comum, a distância estocástica aritmética-geométrica entre $f_{Z_1}(z_1; \theta_1)$ e $f_{Z_2}(z_2; \theta_2)$ é dada por (NASCIMENTO; CINTRA; FRERY, 2010):

$$d_{AG}(Z_1, Z_2) = \frac{1}{2} \int (f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)) \times \log\left(\frac{(f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2))}{\sqrt{(f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2))}}\right) dz. \quad (4.13)$$

Em geral, a integral na Equação (4.13) não apresenta solução analítica e, portanto, deve ser solucionada numericamente. Considere que a imagem seja dividida em duas regiões de “referência”, *background* (Ω_b^r) e *foreground* (Ω_f^r) e que sejam estimados os vetores de parâmetros destas duas regiões, $\hat{\theta}_b^r$ e $\hat{\theta}_f^r$. Estes podem ser estimados a partir do conhecimento

da verdade terrestre ou de amostras das regiões em análise. O resultado da segmentação de uma imagem SAR divide esta imagem em duas novas regiões, *background* (Ω_b^s) e *foreground* (Ω_f^s), nas quais são estimados novos vetores de parâmetros, $\hat{\theta}_b^s$ e $\hat{\theta}_f^s$.

Neste trabalho a distância estocástica aritmética-geométrica é utilizada para fornecer medidas que avaliam quantitativamente resultados experimentais de segmentação. Em particular, dentre as medidas de avaliação de resultados, utilizamos a medida propostas por Marques, Medeiros e Nobre (2012), a qual foi desenvolvida a partir da distância estocástica aritmética-geométrica. A medida de avaliação, denominada Ajuste Cruzado de Região (CRF - do inglês Cross Region Fiting), indica a habilidade do método em particionar (segmentar) corretamente as regiões de uma imagem, combinando as medidas de distância estocástica e dificuldade de segmentação de uma imagem SAR (MARQUES; MEDEIROS; NOBRE, 2012):

$$CRF = \frac{1}{1 + \sqrt{DoS|d_{AG}(Z_f^r, Z_b^s) - d_{AG}((Z_f^s, Z_b^r))|}}, \quad (4.14)$$

em que DoS é dado por:

$$DoS = \frac{1}{d_{AG}(Z_1, Z_2)}. \quad (4.15)$$

De acordo com a definição de CRF, a sua obtenção leva em consideração duas imagens, sendo elas a imagem a ser segmentada (imagem de referência) e a imagem segmentada propriamente dita. Assim, os índices r , s , b e f presentes na Equação (4.14) indicam respectivamente imagem de referência, segmentada, *background* e *foreground*. Mais detalhes sobre a medida do CRF se encontram em Marques, Medeiros e Nobre (2012).

É demonstrado na Figura 9 como as distâncias são computadas, de modo a relacionar o resultado de segmentação obtido com os dados de referência. O cálculo cruzado das distâncias permite que a medida seja sensível aos erros de segmentação do *background*. Por outro lado, o termo DoS normaliza a medida e pondera o resultado proporcionalmente à dificuldade do teste.

O CRF pode ser usado na avaliação da segmentação de imagens reais e sintéticas. E no caso das sintéticas, onde a verdade terrestre é conhecida, pode-se usar também o Erro de Segmentação (EoS) que dado por:

$$EoS = \frac{\#(A)}{\#(Imagem)}. \quad (4.16)$$

em que $\#(A)$ e $\#(Imagem)$ representam o número de *pixels* não observados e o número total de *pixels* da imagem, respectivamente.




Figura 9: Ilustração do processo de cálculo da medida de CRF, relacionando o resultado de segmentação com os dados de referência (MARQUES, 2011).

4.5 Conclusão do capítulo

Neste capítulo foi abordado o algoritmo SVM como também algumas aplicações encontradas na literatura para segmentação de imagens SAR. Em seguida é demonstrada o método SVM proposto com base na distribuição $\mathcal{G}_A^0$ para segmentação de imagens SAR.

A última seção apresentou um conjunto de métricas derivadas de distâncias estocásticas para auxiliar na análise de dados SAR e dos resultados de técnicas de processamento. Estas métricas devem quantificar a dificuldade de segmentação entre duas regiões de uma imagem e o ajuste entre os dados.

O próximo capítulo apresenta os resultados experimentais deste trabalho, além de uma análise comparativa entre o método proposto e outros existentes na literatura. O método proposto é aplicado a imagens sintéticas e reais, e a avaliação dos resultados considera uma metodologia abordada em Marques, Medeiros e Nobre (2012) baseada em distâncias estocásticas.

EXPERIMENTOS E RESULTADOS

Este capítulo apresenta os resultados obtidos na segmentação de imagens SAR pelos métodos descritos no Capítulo 4. Os experimentos de segmentação de imagens sintéticas e reais estão divididos em duas seções principais. O método proposto na Seção 4.3.4, Sar Support Vector Machine, para segmentação de imagens SAR aqui nomeado de SARSVM.

O método SARSVM é inicialmente avaliado por meio de um experimento de Monte Carlo. São realizados ainda testes comparativos entre o método proposto e outras três técnicas existentes na literatura, aqui nomeada como: K-nearest neighbors (KNN) proposto por Maiti e Kumar (2012), Naive bayes (BAYES) proposto por Tripathi *et al.* (2015) que avalia o pixel de acordo com sua média e variância para uma determinada classe, e um método iterativo baseado em SVM proposto por Ping *et al.* (2009). Os métodos estudados, bem como a técnica proposta, foram implementados utilizando o MatLab R2013a, usando computador pessoal com um Intel core i7 de 2 GHz com 6 Gb de RAM.

5.1 Segmentação de imagens sintéticas

Os experimentos de segmentação com imagens SAR sintéticas foram conduzidos com dados em amplitude com duas regiões de diferentes padrões, parâmetros de rugosidade e número de *looks*. Para avaliar o desempenho dos algoritmos em imagens sintéticas, é calculado a medida de erro de segmentação (EoS), que avalia a precisão dos algoritmos por meio da taxa de *pixel* mal segmentando. É realizado um experimento de Monte Carlo, que consiste na simulação exaustiva de amostras aleatórias para obter resultados numéricos, isto é, repetindo a geração e segmentação de imagens sintéticas um elevado número de vezes seguido do cálculo e avaliação da métrica *EoS* para cada resultado. Foram simuladas um conjunto de 324 imagens binárias com tamanho 128 x 128 e geometrias variadas. As regiões de *foreground* e *background* seguiram distribuições $\mathcal{G}_A^0$ distintas com parâmetros $\alpha = \{(-3,0;-8,0);(-1,5;-4,5);(-1,5;-8,0)\}$, $\gamma = \{(0,5;2,0);(7,0;0,5);(3,5;7,0)\}$ e $L = \{1,0;3,0;8,0\}$. É demonstrado na Figura 10 alguns resultados de segmentação utilizando o

método SARSVM.




Figura 10: Resultados do experimento de Monte Carlo: (a) imagens artificialmente contaminadas por ruído *speckle* com $\alpha = -1,5; -8,0$, $\gamma = 0,5; 2,0$ e $L = 1,0$ looks e (b) resultados da segmentação.

5.1.1 Comparação das técnicas de segmentação em imagens sintéticas

É exibida na Figura 11(b) uma imagem sintética 128 x 128 com *foreground* e *background* seguindo distribuições $\mathcal{G}_A^0$ distintas com parâmetros $\alpha = \{(-1,5; -8,0)\}$ e $L = 1,0$. Os padrões simulados tendem a apresentar uma dificuldade de segmentação crescente da região Ω_1 para Ω_2 . Esta característica se deve aos diferentes valores do parâmetro de rugosidade (α). O resultado do método SARSVM é mostrado na Figura 11(c). As Figuras 11(d), 11(e) e 11(f) exibem os resultados para KNN, BAYES e SVM, respectivamente.




Figura 11: Resultado de segmentação para uma imagem sintética: (a) verdade terrestre ou imagem de referência, (b) imagem simulada seguindo uma distribuição $\mathcal{G}_A^0$, (c) resultado do método SARSVM, (d) resultado do método KNN, (e) resultado do método BAYES, (f) resultado do método SVM.

É demonstrado na Figura 12 a probabilidade acumulada do *EoS* para o conjunto das 324

imagens sintéticas. As imagens sintéticas compreendem duas classes, e o parâmetro de escala foi escolhido para produzir regiões de média unitária em todos os testes, ou seja, imagens de baixo contraste. Assim as replicações das imagens foram geradas com os seguintes valores $\alpha = \{(-3,0; -8,0); (-1,5; -4,5); (-1,5; -8,0)\}$, $\gamma = \{(0,5; 2,0); (7,0; 0,5); (3,5; 7,0)\}$ e com $L = \{1,0; 3,0; 8,0\}$.




Figura 12: Probabilidade acumulada de EoS para o experimento de Monte Carlo.

É demonstrado na Tabela 2 os resultados comparativos exibidos na Figura 12 dos valores médios de EoS encontrados para imagens SAR sintéticas com diferentes parâmetros de rugosidade e números de looks para o experimento de Monte Carlo. A medida de EoS é definida no intervalo $[0,1]$, onde valores de $EoS = 0$ indica um melhor resultado de segmentação e valores de $EoS = 1$ indica que o método não conseguiu segmentar a imagem. Observa-se que para o SARSVM 92% das amostras tem um $EoS \leq 0,05$, enquanto o KNN e BAYES apresentaram apenas 33% e 31% respectivamente das amostras com $EoS \leq 0,05$. Merece destaque o método KNN que obteve 0% de amostras para $0,19 < EoS \leq 0,23$, enquanto o SARSVM teve 2% das amostras. Na verdade o método proposto não atingiu um erro maior, por exemplo $EoS > 0,23$, enquanto o BAYES atingiu $EoS = 0,55$ e SVM $EoS = 1$. O tempo computacional médio para SARSVM, KNN, BAYES e SVM são 3,22 s; 1,03 s; 2,01 s; 31,9 s, respectivamente.

Tabela 2: Valores médios de EoS para o experimento de Monte Carlo.

Intervalo	SARSVM	SVM	BAYES	KNN
$EoS \leq 0,05$	92%	16%	31%	33%
$0,05 < EoS \leq 0,19$	6%	52%	30%	67%
$0,19 < EoS \leq 0,23$	2%	13%	7%	0%
$0,23 < EoS \leq 0,55$	0%	15%	32%	0%
$EoS > 0,55$	0%	4%	0%	0%

5.2 Segmentação de imagens SAR reais

5.2.1 Descrição das imagens

Os testes foram realizados com um conjunto de 4 imagens em amplitude, no qual buscou-se maior variabilidade de cenários e condições de aquisição. Para os experimentos com imagens SAR reais, é adotado o índice CRF, abordagem proposta por Marques, Medeiros e Nobre (2012) para quantificar a precisão da segmentação. Esse índice é definido no intervalo $[0,1]$, com $CRF = 1$ indicando um melhor resultado de segmentação. Adotamos $CRF_{1,2}$ para segmentação binária, onde Ω_1^s , Ω_2^s são o primeiro plano segmentado e o fundo, respectivamente. Para imagens com 3 regiões calculamos o CRF médio $\frac{1}{3}(CRF_{1,2} + CRF_{1,3} + CRF_{2,3})$. Segue aqui uma breve descrição dos dados utilizados neste trabalho, em que são destacadas algumas características de cada imagem e das respectivas regiões de interesse analisadas.

- **São Francisco:** A imagem exibida na Figura 13 foi adquirida pelo sensor AIRSAR sobre a Baía de São Francisco com 600×450 pixels, com $L = 4$ looks, em polarização L-Banda e HH.

- **Espanha:** A imagem exibida na Figura 14 foi adquirida pela sensor Envisat sobre a Galiza, Espanha com 500×400 pixels, com $L = 8$ looks, em polarização de banda C e VV.

- **óleo:** A imagem exibida na Figura 15 foi adquirida pelo satélite RADARSAT que mostra uma mancha de óleo com 512×512 pixels na costa do estado do Rio Grande do Norte - Brasil, com $L = 4$ looks.

- **Tapajós:** A imagem exibida na Figura 16 foi obtida sobre a cidade de Tapajós, PA-Brasil, e mostra uma área da Amazônia brasileira. Esta imagem foi adquirida pelo sensor JERS (Japanese Earth Resources Satélite) com polarização HH, banda L, resolução espacial de 12,5 m/pixel, com $L = 3$ looks e detecção linear.




Figura 13: São Francisco: imagem em amplitude adquirida pelo sensor AIRSAR sobre a Baía de São Francisco com $L = 4$ looks (ESA, 2016).



Figura 14: Espanha: imagem em amplitude adquirida pela Envisat sobre a Galiza, Espanha, com $L = 8$ looks (ESA, 2016).




Figura 15: Óleo: imagem em amplitude e $L = 4$ looks, adquiridas pelo sensor RADARSAT. Esta imagem mostra um derrame de óleo. Cedido pelo professor Venerando Amaro, UFRN.




Figura 16: Tapajós: imagem em amplitude e $L = 3$ looks, adquirida pelo sensor JERS, mostrando áreas de desmatamento na Amazônia Brasileira. Cedido pelo INPE.

São demonstrados na Figura 17 os resultados da segmentação das imagens citadas anteriormente. Foram retiradas amostras de diferentes regiões para realizar uma avaliação estocástica com base nos parâmetros estimados. Vale ressaltar que as amostras selecionadas para treinamento dos classificadores foram as mesmas aplicadas a todos os métodos para permitir uma análise confiável.




Figura 17: Da esquerda para a direita, os resultados de segmentação das imagens SAR. (a) São Francisco; (b) Espanha; (c) Óleo e (d) Tapajós para os métodos KNN, BAYES, SVM e SARSVM, respectivamente.

A Tabela 3 resume os resultados comparativos dos índices de avaliação CRF e também inclui o tempo computacional do processamento das imagens SAR real com duas e três classes exibidas na Figura 17. Pode-se observar na Tabela 3 que as experiências com KNN, BAYES e SVM obtiveram resultados de CRF próximos para imagens com três classes, já nas imagens com duas classes o método de BAYES e SVM obtiveram resultados mais expressivos, porém, com desempenho inferior ao algoritmo proposto em termos de segmentos detectados com precisão. Em relação ao tempo computacional o método proposto atingiu melhor tempo computacional em relação a técnica SVM. Através destas análises percebe-se que os métodos KNN, BAYES e SVM atingiram valores médios de CRF baixos que nos levaram a concluir que nosso algoritmo superou-os com relação ao ajuste estatístico das regiões segmentadas.

Tabela 3: Valores médios de CRF e tempo computacional.

<i>Métodos</i>	<i>São Francisco</i>		<i>Espanha</i>		<i>Óleo</i>		<i>Tapajós</i>	
	Tempo(s)	CRF	Tempo(s)	CRF	Tempo(s)	CRF	Tempo(s)	CRF
KNN	11,5	0,72	6,3	0,73	8,5	0,70	2,5	0,54
BAYES	8,8	0,68	9,1	0,72	4,3	0,83	3,2	0,89
SVM	44,1	0,65	79,1	0,75	120,5	0,88	69,5	0,83
SARSVM	20,5	0,74	13,2	0,77	13,0	0,90	10,0	0,96

5.3 Conclusão do capítulo

Este capítulo apresenta os experimentos realizados na segmentação de imagens SAR sintéticas e reais, no qual é feito, a comparação do método proposto com três técnicas existentes na literatura.

A análise de dados sintéticos incluiu um experimento de Monte Carlo que permitiu a avaliação dos métodos na segmentação de regiões com diferentes níveis de dificuldade. Os testes com dados reais foram realizados em um conjunto de 4 imagens, obtidas em diferentes condições e cenários, e a técnica de segmentação proposta se mostrou capaz de identificar diferentes tipos de regiões e com resultado superior ou similar aos das outras técnicas testadas.

CONCLUSÃO E TRABALHOS FUTUROS

Este capítulo tem como objetivo apresentar as conclusões desta dissertação, obtidas a partir da consideração dos objetivos, dos aspectos metodológicos, da análise e discussão dos resultados obtidos. Além disso, são apresentadas as perspectivas de trabalhos futuros.

6.1 Conclusões

Nesse trabalho, é feito uma abordagem no uso do classificador SVM para segmentação de imagens SAR, introduzimos uma metodologia que utiliza a informação de rugosidade presente na intensidade do *pixel*, como entrada para algoritmos de segmentação em vez de processar diretamente a imagem SAR. Adotamos a distribuição $\mathcal{G}_A^0$ para modelagem dos dados SAR em amplitude. Para a estimação dos parâmetros α e γ adotamos o método rápido de log-cumulantes.

O desempenho do método proposto foi analisado e comparado com o desempenho de três técnicas existentes na literatura. Primeiramente foram apresentados os resultados de um experimento de Monte Carlo. Os testes realizados com imagens sintéticas permitiram a análise simultânea da técnica de segmentação proposta SARSVM, os resultados mostraram a capacidade do método em analisar imagens com diferentes níveis de contraste, para as quais o método proposto obteve valores de *EoS* inferiores aos outros métodos, como a abordagem proposta por Ping *et al.* (2009) que apresentou *EoS* = 1 em alguns testes.

Na análise com dados reais foi avaliada a capacidade do método em detectar derrames de óleo em alto mar; desmatamentos florestais e segmentar regiões homogêneas, heterogêneas e extremamente heterogêneas com diferentes níveis de contraste. Segundo as métricas adotadas, na segmentação de imagens reais, o SARSVM atingiu resultados superiores, ou se não, similares aos obtidos pelos outros métodos em relação ao EoS e CRF. Ao comparar as diferentes técnicas, é destacada a capacidade do SARSVM em detectar diferentes tipos de alvos e regiões, sem a necessidade de ajuste de parâmetros empíricos. Esta interessante característica deve

ser atribuída à estimativa dos parâmetros pelo método de log-cumulantes, que maximiza as variações entre regiões e reduz a interferência do ruído *speckle*.

Os resultados mostraram que o método de log-cumulantes fornece um mapa de rugosidade estimado que indica claramente as regiões predominantes presentes nas imagens SAR, facilitando o uso da técnica de segmentação. Esse fato ocorreu, principalmente nas imagens *single look* ($L = 1$). Isto significa que a metodologia de segmentação de imagens foi efetiva para o caso mais crítico, ou seja, em que o ruído *speckle* apresenta-se mais intensamente presente, como é o caso de imagens *single look*.

6.2 Trabalhos futuros

Dentre as sugestões de trabalhos futuros, destacam-se:

- propor uma abordagem não supervisionada para segmentação de alvos militares, utilizando a segmentação inicial da estimativa dos mapas de parâmetros para automatizar a escolha das amostras de treinamento;
- classificar as imagens segmentadas de acordo com o número de classes e os parâmetros de rugosidade e escala estimados;
- estudar a aplicabilidade da abordagem proposta em dados polarimétricos, que nos últimos anos tem sido alvo de inúmeros estudos.

Referências

- ALLENDE, Héctor; FRERY, Alejandro C.; GALBIATI, Jorge; PIZARRO, Luis. M-estimators with asymmetric influence functions: the distribution case. **Journal of Statistical Computation and Simulation**, Taylor & Francis, v. 76, n. 11, p. 941–956, 2006.
- ANLAUF, Joachim K.; BIEHL, Michael. The adatron: an adaptive perceptron algorithm. **EPL (Europhysics Letters)**, IOP Publishing, v. 10, n. 7, p. 687, 1989.
- ARGENTI, Fabrizio; BIANCHI, Tiziano; ALPARONE, Luciano. Multiresolution map despeckling of sar images based on locally adaptive generalized gaussian pdf modeling. **IEEE Transactions on Image processing**, IEEE, v. 15, n. 11, p. 3385–3399, 2006.
- ARSENAULT, Henri H.; APRIL, Gilbert. Properties of speckle integrated with a finite aperture and logarithmically transformed. **JOSA**, Optical Society of America, v. 66, n. 11, p. 1160–1163, 1976.
- BEYER, William H. Handbook of mathematical science:.. **CRC press**, 2018.
- BHATTI, Asghar M. Practical optimization methods: With mathematica® applications. **Springer Science and Business Media**, 2012.
- BIAU, Gérard; DEVROYE, Luc. The nearest neighbor regression function estimate. **Lectures on the Nearest Neighbor Method**, Springer, p. 95–103, 2015.
- BLANCHARD, Philippe; BRÜNING, Erwin. Mathematical methods in physics: Distributions, hilbert space operators, variational methods, and applications in quantum physics. **Birkhäuser**, v. 69, 2015.
- BOURGEAU CHAVEZ, Laura L.; SMITH, Kevin B.; BRUNZELL, Suzanne M.; KASISCHKE, Eric S.; ROMANOWICZ, Edwin A.; RICHARDSON, Curtis J. Remote monitoring of regional inundation patterns and hydroperiod in the greater everglades using synthetic aperture radar. **Wetlands**, BioOne, v. 25, n. 1, p. 176–191, 2005.
- BUJOR, Florentin; TROUVÉ, Emmanuel; VALET, Lionel; NICOLAS, Jaean Mair; RUDANT, J-P. Application of log-cumulants to the detection of spatiotemporal discontinuities in multitemporal sar images. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 42, n. 10, p. 2073–2084, 2004.
- BUSTOS, Oscar H.; LUCINI, María Magdalena; FRERY, Alejandro C. M-estimators of roughness and scale for modelled SAR imagery. **EURASIP Journal on Advances in Signal Processing**, Springer, v. 2002, n. 1, p. 297349, 2002.
- CARVALHO, Eduardo A.; USHIZIMA, Daniela M.; MEDEIROS, Fátima N. S.; MARTINS, Charles I. O.; MARQUES, Regis C. P.; OLIVEIRA, Isaura N. S. SAR imagery segmentation

by statistical region growing and hierarchical merging. **Digital Signal Processing**, Elsevier, v. 20, n. 5, p. 1365–1378, 2010.

CARVALHO, Naiallen R. L.; FERNANDES, David. Classificação não-supervisionada de imagens sar polarimétricas utilizando os parâmetros polarimétricos h - α - a e uma variante da matriz de müller. 2015.

CHENG, Jianghua; GAO, Gui; DING, Wenxia; KU, Xishu; SUN, Jixiang. An improved scheme for parameter estimation of g distribution model in high-resolution sar images. **Progress In Electromagnetics Research**, EMW Publishing, v. 134, p. 23–46, 2013.

CHITROUB, Salim; HOUACINE, Amrane; SANSAL, Boualem. Statistical characterisation and modelling of sar images. **Signal Processing**, Elsevier, v. 82, n. 1, p. 69–92, 2002.

CHRISTOPHER, M. Bishop. Pattern recognition and machine learning. **Springer-Verlag New York**, v. 1, n. 1, 2016.

CUI, Shiyong; SCHWARZ, Gottfried; DATCU, Mihai. A comparative study of statistical models for multilook SAR images. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 11, n. 10, p. 1752–1756, 2014.

DASARI, Kiran; ANJANEYULU, L. Importance of speckle filter window size and its impact on speckle reduction in SAR images. **International Journal of Advances in Microwave Technology**, International Journal of Advances in Microwave Technology, v. 2, 2017.

DENG, Huawu; CLAUSI, David A. Unsupervised segmentation of synthetic aperture radar sea ice imagery using a novel Markov random field model. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 43, n. 3, p. 528–538, 2005.

DENG, Xinping; CHEN, Jinsong; LI, Hongzhong; SUN, Luyi. Statistical analysis of polarimetric sar data using log-cumulants. **SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA)**, n. 1, p. 1–7, 2017.

DUAN, Yiping; LIU, Fang; JIAO, Licheng; ZHAO, Peng; ZHANG, Lu. Sar image segmentation based on convolutional-wavelet neural network and markov random field. **Pattern Recognition**, Elsevier, v. 64, p. 255–267, 2017.

DUAN, Yiping; TAO, Xiaoming; XU, Mai; QIN, Xiaowei; YANG, Ren; HAN, Chaoyi; LU, Jianhua. Hierarchical multinomial latent model with g_0 distribution for synthetic aperture radar image semantic segmentation. **IEEE Access**, IEEE, 2018.

DUIN, Robert P. W.; TAX, David M. J. Statistical pattern recognition. **Handbook of Pattern Recognition and Computer Vision**, World Scientific, v. 1, n. 1, p. 3–24, 2005.

DUTRA, Luciano V.; MURA, José C.; FREITAS, Corina C.; ELMIRO, Marcos T. Processamento de imagens de radar de abertura sintética—princípios e aplicações. **Anais do IV Workshop em Tratamento de Imagens, NPDI/DCC/ICEx/UFMG**, 2003.

ESA. **Airborne images and sample data**. 2016. [Online]. Available: <https://earth.esa.int>.

FENG, Jilan; CAO, Zongjie; PI, Yiming. Multiphase SAR image segmentation with G^0 -statistical-model-based active contours. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 51, n. 7, p. 4190–4199, 2013.

- FRERY, Alejandro C.; CRIBARI-NETO, Francisco; SOUZA, Marcelo de. Analysis of minute features in speckled imagery with maximum likelihood estimation. **EURASIP Journal on Advances in Signal Processing**, Springer, v. 2004, n. 16, p. 375370, 2004.
- FRERY, Alejandro C.; MULLER, Herman J.; YANASSE, Corina C. F.; SANT'ANNA, Sidnei J. S. A model for extremely heterogeneous clutter. **IEEE transactions on geoscience and remote sensing**, IEEE, v. 35, n. 3, p. 648–659, 1997.
- FRERY, Alejandro C.; NASCIMENTO, Abraao D.; CINTRA, Renato J. Contrast in speckled imagery with stochastic distances. **Image Processing (ICIP), 2010 17th IEEE International Conference on**, p. 69–72, 2010.
- FRERY, Alejandro C.; SANT'ANNA, Sidinei; MASCARENHAS, N.; BUSTOS, O. Robust inference techniques for speckle noise reduction in 1-look amplitude sar images. **Applied Signal Processing**, Springer Science and Media, v. 4, n. 2, p. 61–76, 1997.
- FROST, Victor S.; STILES, Josephine A.; SHANMUGAN, Kumar S.; HOLTZMAN, Julian C. A model for radar images and its application to adaptive digital filtering of multiplicative noise. **IEEE Transactions on pattern analysis and machine intelligence**, IEEE, n. 2, p. 157–166, 1982.
- GAMBINI, Juliana; MEJAIL, Marta E.; JACOBO-BERLLES, Julio; FRERY, Alejandro C. Feature extraction in speckled imagery using dynamic b-spline deformable contours under the model. **International Journal of Remote Sensing**, Taylor & Francis, v. 27, n. 22, p. 5037–5059, 2006.
- GAMBINI, Juliana; MEJAIL, Marta E.; JACOBO-BERLLES, Julio; FRERY, Alejandro C. Accuracy of edge detection methods with local information in speckled imagery. **Statistics and Computing**, Springer, v. 18, n. 1, p. 15–26, 2008.
- GAO, Gui. Statistical modeling of sar images: A survey. **Sensors**, Molecular Diversity Preservation International, v. 10, n. 1, p. 775–795, 2010.
- GAO, Gui; QIN, Xianxiang; ZHOU, Shilin. Modeling sar images based on a generalized gamma distribution for texture component. **Progress In Electromagnetics Research**, EMW Publishing, v. 137, p. 669–685, 2013.
- GOODMAN, Nathaniel R. Statistical analysis based on a certain multivariate complex gaussian distribution (an introduction). **The Annals of mathematical statistics**, JSTOR, v. 34, n. 1, p. 152–177, 1963.
- HAYAKAWA, Ericson H.; BACANI, Vitor M.; BREUNIG, Fábio M.; SILVA, Aguinaldo; TRENTIN, Romário; PEREIRA, Filho W. Sensoriamento remoto aplicado aos estudos geográficos: Considerações a partir dos trabalhos submetidos ao xi enanpege. **Revista da ANPEGE**, v. 12, n. 18, p. 77–96, 2017.
- HAYKIN, Simon. Redes neurais: princípios e prática. 2ª edição. trad: Paulo martins engel. **São Paulo: Bookman companhia editora**, 2000.
- HAYKIN, Simon. Redes neurais princípios e aplicações. **Segunda Edição. Porto Alegre**, 2001.

HORTA, Michelle M. **Modelos de mistura de distribuições na segmentação de imagens SAR polarimétricas multi-look**. Tese (Doutorado) — Universidade de São Paulo, 2009.

HUANG, Shi-qi; LIU, Dai-zhi; GAO, Gui-qing; GUO, Xi-jian. A novel method for speckle noise reduction and ship target detection in sar images. **Pattern Recognition**, Elsevier, v. 42, n. 7, p. 1533–1542, 2009.

HUANG, Xiaoxia; HUANG, Bo; LI, Hongga. A fast level set method for synthetic aperture radar ocean image segmentation. **Sensors**, Molecular Diversity Preservation International, v. 9, n. 2, p. 814–829, 2009.

ISONO, Hiroshi; HIRATA, Shinnosuke; HACHIYA, Hiroyuki. Quantitative analysis of ultrasonic images of fibrotic liver using co-occurrence matrix based on multi-rayleigh model. **Japanese Journal of Applied Physics**, IOP Publishing, v. 54, n. 7S1, p. 07HF15, 2015.

JAO, Jen. Amplitude distribution of composite terrain radar clutter and the κ -distribution. **IEEE Transactions on Antennas and Propagation**, IEEE, v. 32, n. 10, p. 1049–1062, 1984.

KOVÁCS, Zsolt L. Redes neurais artificiais. **Editora Livraria da Física**, 2002.

KRYLOV, Vladimir A.; MOSER, Gabriele; SERPICO, Sebastiano B.; ZERUBIA, Josiane. On the method of logarithmic cumulants for parametric probability density function estimation. **IEEE Transactions on Image Processing**, IEEE, v. 22, n. 10, p. 3791–3806, 2013.

LEE, Jong-Sen; AINSWORTH, Thomas L; WANG, Yanting; CHEN, Kun-Shan. Polarimetric sar speckle filtering and the extended sigma filter. **IEEE Transactions on geoscience and remote sensing**, IEEE, v. 53, n. 3, p. 1150–1160, 2015.

LEE, Jong-Sen; POTTIER, Eric. Polarimetric radar imaging: from basics to applications. **Lee, Jong-Sen and Pottier, Eric**, 2009.

LEE, Jong-Sen; WEN, Jen-Hung; AINSWORTH, Thomas L.; CHEN, Kun-Shan; CHEN, Abel J. Improved sigma filter for speckle filtering of sar imagery. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 47, n. 1, p. 202–213, 2009.

LEHMANN, Erich L. Elements of large-sample theory. **Springer Science and Business Media**, 2004.

LI, Zhigang; YANG, Zhen; XIONG, Huilin. Homogeneous region segmentation for sar images based on two steps segmentation algorithm. **Computers, Communications, and Systems (ICCCS), International Conference on**, p. 196–200, 2015.

LIMA, Fabiana S. Análise espaço-temporal da cobertura vegetal na área de proteção ambiental (apa) do cariri-pb. **Universidade Federal da Paraíba**, 2016.

LIU, Fang; DUAN, Yiping; LI, Lingling; JIAO, Licheng; WU, Jie; YANG, Shuyuan; ZHANG, Xiangrong; YUAN, Jialin. SAR image segmentation based on hierarchical visual semantic and adaptive neighborhood multinomial latent model. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 54, n. 7, p. 4287–4301, 2016.

LIU, Meng; ZHANG, Hong; WANG, Chao. Applying the log-cumulants of texture parameter to fully polarimetric sar classification using support vector machines classifier. **Radar (Radar), 2011 IEEE CIE International Conference on**, v. 1, p. 728–731, 2011.

- LOMNICKI, Z. A. On the distribution of products of random variables. **Journal of the Royal Statistical Society. Series B (Methodological)**, JSTOR, p. 513–524, 1967.
- MAHDAVI, Sahel; SALEHI, Bahram; MOLONEY, Cecilia; HUANG, Weimin; BRISCO, Brian. Speckle filtering of synthetic aperture radar images using filters with object-size-adapted windows. **International Journal of Digital Earth**, Taylor & Francis, v. 11, n. 7, p. 703–729, 2018.
- MAITI, Anindya; KUMAR, Sunil S. Applying enhanced k-nearest neighbor approach on satellite images for forest biomass estimation of vellore district. **Engineering Science and Technology: An International Journal (ESTIJ)**, 2012.
- MARQUES, Regis C. P. **Caracterização de regiões em imagens de radar de abertura sintética com aplicações de segmentação por *level set***. 107 p. Tese (Doutorado) — Programa de Pós-graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2011.
- MARQUES, Regis C. P.; MEDEIROS, Fátima N. S.; NOBRE, Juvencio S. SAR image segmentation based on level set approach and $\mathcal{G}$ -amplitude-zero model. **Radar, 2011 IEEE CIE International Conference on**, v. 34, 2012.
- MARTINIS, Sandro; KUENZER, Claudia; TWELE, A. Flood studies using synthetic aperture radar data. **Remote sensing of water resources, disasters and urban studies**, p. 673, 2015.
- MEDEIROS, Fátima N. S.; MASCARENHAS, Nelson D. A.; COSTA, Luciano F. Evaluation of speckle noise map filtering algorithms applied to sar images. **International Journal of Remote Sensing**, Taylor & Francis, v. 24, n. 24, p. 5197–5218, 2003.
- MEJAIL, Marta E.; JACOBO-BERLLES, Julio; FRERY, Alejandro C.; BUSTOS, Oscar H. Classification of sar images using a general and tractable multiplicative model. **International Journal of Remote Sensing**, Taylor & Francis, v. 24, n. 18, p. 3565–3582, 2003.
- MOREIRA, Alberto; PRATS-IRAOLA, Pau; YOUNIS, Marwan; KRIEGER, Gerhard; HAJNSEK, Irena; PAPATHANASSIOU, Konstantinos P. A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, IEEE, v. 1, n. 1, p. 6–43, 2013.
- MOSER, Vladimir A. K. G.; ZERUBIA, Serpico J. On the method of logarithmic cumulants for parametric probability density function estimation. **IEEE Transactions on Image Processing**, 2011.
- NASCIMENTO, Abraao D.; CINTRA, Renato J.; FRERY, Alejandro C. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 48, n. 1, p. 373–385, 2010.
- NICOLAS, Jean M. Introduction aux statistiques de deuxième espèce: Applications des logs-moments et des logs-cumulants à l'analyse des lois d'images radar. **TS. Traitement du signal**, Lavoisier, v. 19, n. 3, p. 139–167, 2002.
- PARREIRA, Michelle O.; DUTRA, Luciano V.; PANTALEÃO, Eliana; RUWER, Sherfis G.; LU, Dengsheng. Sistema classificador parreira: um método de combinação de classificações por pares de classes. **XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, 2015.

- PETROPOULOS, George P.; ARVANITIS, Kostas; SIGRIMIS, Nick. Hyperion hyperspectral imagery analysis combined with machine learning classifiers for land use/cover mapping. **Expert systems with Applications**, Elsevier, v. 39, n. 3, p. 3800–3809, 2012.
- PING, Han; RUI, Zhang; ZHI-GANG, Su; REN-BIAO, Wu. An iterative segmentation algorithm of sar image based on support vector machine. **Synthetic Aperture Radar, 2009. APSAR 2009. 2nd Asian-Pacific Conference on**, n. 1, p. 676–679, 2009.
- PLATT, John. Fast training of support vector machines using sequential minimal optimization. advances in kernel methods—support vector learning (pp. 185–208). **AJ, MIT Press, Cambridge, MA**, 1999.
- PRADHAN, Ratika; GHOSE, Mrinal. K.; JEYARAM, A. Land cover classification of remotely sensed satellite data using bayesian and hybrid classifier. **International Journal of Computer Applications**, v. 7, n. 11, p. 1–4, 2010.
- ROCHA NETO , Ajalmar R. **SINPATCO II: Novas Estratégias de Aprendizado de Máquinas para Classificação de Patologias da Coluna Vertebral**. Tese (Doutorado) — Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, 2011.
- RODRIGUES, Francisco A. Á. **MÉTODO DE LOG-CUMULANTES EM PROCESSAMENTO DE IMAGENS SAR FORTALEZA 2017**. Tese (Doutorado) — Tese (Doutorado)-Departamento de Teleinformática, Universidade Federal do Ceará,, 2017.
- RODRIGUES, Francisco A. Á.; NETO, Jeová. F. S. R.; MARQUES, Regis C. P.; MEDEIROS, Fátima N. S.; NOBRE, Juvencio S. SAR image segmentation using the roughness information. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 13, n. 2, p. 132–136, 2016.
- RUIZ, Pablo; MATEOS, Javier; CAMPS-VALLS, Gustavo; MOLINA, Rafael; KATSAGGELOS, Aggelos K. Bayesian active remote sensing image classification. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 52, n. 4, p. 2186–2196, 2014.
- SAMSÓ, Montserrat; PALUMBO, Michael J.; RADERMACHER, Michael; LIU, Jun S.; LAWRENCE, Charles E. A bayesian method for classification of images from electron micrographs. **Journal of structural biology**, Elsevier, v. 138, n. 3, p. 157–170, 2002.
- SEN, Pranab K.; SINGER, Julio M.; LIMA, Antonio C. P. From finite sample to asymptotic methods in statistics. **Cambridge University Press**, v. 28, 2010.
- SHANG, Ronghua; TIAN, Pingping; JIAO, Licheng; STOLKIN, Rustam; FENG, Jie; HOU, Biao; ZHANG, Xiangrong. A spatial fuzzy clustering algorithm with kernel metric based on immune clone for sar image segmentation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 9, n. 4, p. 1640–1652, 2016.
- SINGH, Jagmal; DATCU, Mihai. SAR image categorization with log cumulants of the fractional fourier transform coefficients. **IEEE transactions on geoscience and remote sensing**, IEEE, v. 51, n. 12, p. 5273–5282, 2013.
- SKONIECZNY, Charlotte; PAILLOU, Philippe; BORY, A.; BAYON, Germain; BISCARA, L.; CROSTA, X.; EYNAUD, F.; MALAIZÉ, B.; REVEL, M.; ALEMAN, N. *et al.* African humid periods triggered the reactivation of a large river system in western sahara. **Nature communications**, Nature Publishing Group, v. 6, p. 8751, 2015.

TEIXEIRA, Sheiça; OTHERS. Radar de abertura sintética aplicado ao mapeamento e reconhecimento de zonas úmidas costeiras. **Belém: Universidade Federal do Pará**, 2011.

TINER, Ralph W; LANG, Megan W; KLEMAS, Victor V. **Remote sensing of wetlands: applications and advances. CRC press, 2015.**

TISON, Céline; NICOLAS, Jean mair; TUPIN, Florence; MAÎTRE, Henri. A new statistical model for markovian classification of urban areas in high-resolution sar images. **IEEE transactions on geoscience and remote sensing**, IEEE, v. 42, n. 10, p. 2046–2057, 2004.

TORRES, Leonardo; SANT'ANNA, Sidnei; COSTA, Freitas C.; FRERY, Alejandro C. Speckle reduction in polarimetric sar imagery with stochastic distances and nonlocal means. **Pattern Recognition**, Elsevier, v. 47, n. 1, p. 141–157, 2014.

TRIPATHI, Sumit; PRAKASH, Rishi; MELKANI, Neha; KUMAR, Sachin. Study of bayes theorem for classification of synthetic aperture data. **Advances in Computing and Communication Engineering (ICACCE), 2015 Second International Conference on, IEEE**, p. 187–191, 2015.

VAPNIK, Vladimir N. Adaptive and learning systems for signal processing communications, and control. **Statistical learning theory**, John Wiley & Sons, 1998.

VILLANO, Michelangelo; KRIEGER, Gerhard; PAPATHANASSIOU, Konstantinos P; MOREIRA, Alberto. Monitoring dynamic processes on the earth's surface using synthetic aperture radar. **2018 IEEE International Conference on Environmental Engineering (EE)**, p. 1–5, 2018.

WANG, Yanting; AINSWORTH, Thomas L; LEE, Jong-Sen. Application of mixture regression for improved polarimetric sar speckle filtering. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 55, n. 1, p. 453–467, 2017.

XU, Chuan; SUI, Haigang; XU, Feng. Land surface water mapping using multi-scale level sets and a visual saliency model from sar images. **ISPRS International Journal of Geo-Information**, Multidisciplinary Digital Publishing Institute, v. 5, n. 5, p. 58, 2016.

YAN, Tianheng; YIN, Xueke; YANG, Wen; LÓPEZ-MARTÍNEZ, Carlos. Polarimetric sar speckle filtering based on stochastic sampling. **Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International**, p. 7533–7536, 2016.

ZHANG, Peng; LI, Ming; WU, Yan; LI, Hejing. Hierarchical conditional random fields model for semisupervised sar image segmentation. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 53, n. 9, p. 4933–4951, 2015.

ZHENG, Yuhui; JEON, Byeungwoo; XU, Danhua; WU, QM; ZHANG, Hui. Image segmentation by generalized hierarchical fuzzy c-means algorithm. **Journal of Intelligent & Fuzzy Systems**, IOS Press, v. 28, n. 2, p. 961–973, 2015.

ZOLFAGHARI, Kiana; SHANG, Jiali; MCNAIRN, Heather; LI, Jonathon; HOMYOUNI, Saeid. Using support vector machine (svm) for agriculture land use mapping with sar data: Preliminary results from western canada. **Agro-Geoinformatics (Agro-Geoinformatics), 2013 Second International Conference on**, p. 126–130, 2013.