



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
DOUTORADO EM ENGENHARIA DE TELEINFORMÁTICA

FRANCISCO ALIXANDRE ÁVILA RODRIGUES

MÉTODO DE LOG-CUMULANTES EM PROCESSAMENTO DE IMAGENS SAR

FORTALEZA

2017

FRANCISCO ALIXANDRE ÁVILA RODRIGUES

MÉTODO DE LOG-CUMULANTES EM PROCESSAMENTO DE IMAGENS SAR

Tese apresentada ao Curso de Doutorado em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e sistemas

Orientadora: Prof^a. Dr^a. Fátima N. Sombra de Medeiros

FORTALEZA

2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- R613m Rodrigues, Francisco Alixandre Avila.
Método de log-cumulantes em processamento de imagens SAR / Francisco Alixandre Avila Rodrigues.
– 2017.
60 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2017.
Orientação: Profa. Dra. Fátima N. Sombra de Medeiros.
1. Segmentação. 2. Imagem SAR. 3. Rugosidade. 4. Limiarização. 5. Log-cumulantes. I. Título.
CDD 621.38
-

FRANCISCO ALIXANDRE ÁVILA RODRIGUES

MÉTODO DE LOG-CUMULANTES EM PROCESSAMENTO DE IMAGENS SAR

Tese apresentada ao Curso de Doutorado em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e sistemas

Aprovada em: 19 de Janeiro de 2017

BANCA EXAMINADORA

Prof^ª. Dr^ª. Fátima N. Sombra de
Medeiros (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Danielo Gonçalves Gomes
Universidade Federal da Ceará (UFC)

Prof. Dr. Régis Cristiano Pinheiro Marques
Instituto Federal de Educação, Ciência e
Tecnologia do Ceará (IFCE)

Prof. Dr. Geraldo Luís Bezerra Ramalho
Instituto Federal de Educação, Ciência e
Tecnologia do Ceará (IFCE)

Prof. Dr. Abraão David Costa do Nascimento
Universidade Federal de Pernambuco (UFPE)

Dedico este trabalho à minha esposa Lígia, meus pais Antônio e Rita, minhas irmãs Andrea e Adriane.

AGRADECIMENTOS

Agradeço a Deus, à minha orientadora professora Fátima Sombra pelos ensinamentos sobre ciência, ética e pela sua dedicação com seus orientandos. Ao professor e amigo Juvêncio, do Departamento de Estatística e Matemática Aplicada da Universidade Federal do Ceará. Ao professor Rui Vigelis da Universidade Federal do Ceará. Aos colegas do LABVIS pelo companherismo e pela ajuda no desenvolvimento deste trabalho. Aos membros da banca pelas sugestões e contribuições. À CAPES pelo apoio financeiro.

“O que importa nessa vida são os afetos. O resto
é cenário.”

(Marcelo Predebon)

RESUMO

A segmentação de imagens é uma tarefa que pode ser aplicada a 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 tese introduz uma metodologia geral e simples para segmentação de imagens usando os parâmetros de rugosidade estimados a partir de dados modelados pelas distribuições G_I^0 e G_A^0 , em vez de processar diretamente as imagens ruidosas. Para tanto, adotamos o método log-cumulantes para a estimação de parâmetros de rugosidade. A avaliação de desempenho dos resultados foi realizada em termos das medidas de Erro de Segmentação e de *Cross-Region Fitting* para imagens SAR sintéticas e reais, respectivamente. Em relação às imagens sintéticas, foram realizadas experimentos de Monte Carlo que confirmaram a adequação da segmentação da imagem SAR por meio de parâmetros de rugosidade. Os resultados mostraram que a metodologia fornece uma entrada viável para algoritmos de segmentação de imagens SAR dentre os quais se incluem métodos baseados em limiarização. Na verdade, a abordagem proposta obteve resultados satisfatórios para o estudo de caso mais crítico, que são as imagens com número de visadas igual a 1, as quais são bastante afetadas pelo *speckle*. A estimação de parâmetros de funções de densidade de probabilidade usando o método log-cumulantes tem sido utilizada no processamento de imagens de radar de abertura sintética. O bom desempenho deste método tem fomentado a pesquisa em modelagem e processamento de dados SAR com a distribuição G_I^0 e G_A^0 . Em geral, métodos numéricos são aplicados para estimar os parâmetros das distribuições G_I^0 e G_A^0 pelo método de log-cumulantes e, portanto, podem resultar em alto custo computacional. Neste trabalho, também propomos uma abordagem rápida para o método de log-cumulantes mantendo a boa qualidade das estimativas dos parâmetros. A abordagem proposta foi aplicada a conjuntos de dados simulados e reais.

Palavras-chave: Segmentação. Imagem SAR. Rugosidade. Limiarização. Log-cumulantes.

ABSTRACT

Image segmentation can be applied to a broad class of different problems. However, it is not usually a simple task for Synthetic Aperture Radar (SAR) images due to the presence of speckle. Given the importance of SAR images in remote sensing problems, this thesis introduces a general and simple methodology to achieve SAR image segmentation by using the estimated roughness parameters of SAR data modeled by G_I^0 and G_A^0 distributions, instead of directly processing the speckled images. In this paper, we adopted the log-cumulants method for the roughness parameter estimation. The performance evaluation of the results was attained in terms of the Error of Segmentation and Cross-Region Fitting measures for synthetic and real SAR images, respectively. Regarding synthetic images, we performed Monte Carlo experiments which confirmed the suitability of SAR image segmentation by means of roughness parameters. The results showed that the methodology provides a feasible input to SAR image segmentation algorithms which also include thresholding based methods. Actually, the proposed approach accomplished satisfactory results for the most critical case study, the single-look images, which are markedly affected by speckle. The application of the log-cumulants method to synthetic aperture radar data processing encompasses parameter estimation of probability density functions. The good estimation performance of this method has fostered researches in SAR data modeling and processing with the G_I^0 distribution. Numerical methods are usually applied to estimate parameters of the G_I^0 distribution by log-cumulants and therefore they can result in high computational cost. Here, we propose a fast log-cumulants approach for SAR data modeled by the G_I^0 distribution. Experimental tests were carried out on sets of simulated and real SAR data.

Keywords: Segmentation. SAR image. Roughness. Thresholding. Log-cumulants.

LISTA DE TABELAS

Tabela 1	– Bandas de frequência utilizadas nos sistemas SAR, com indicação de frequências e comprimentos de onda associados.	15
Tabela 2	– Cenários dos experimentos realizados para a distribuição G_I^0	33
Tabela 3	– Cenários dos experimentos para a distribuição G_A^0	33
Tabela 4	– Tempo de execução total médio em segundos (s) de estimação para realização de todos os experimentos de cada distribuição.	39
Tabela 5	– Média e desvio padrão de EoS para o método de Otsu.	45
Tabela 6	– Medidas de DOS e CRF da imagem SAR real da baía de São Francisco segmentada pelos métodos Met1:(OTSU, 1979), Met2: (HUANG <i>et al.</i> , 2005) e Met3: (MARQUES <i>et al.</i> , 2012).	49
Tabela 7	– DOS e CRF da imagem real da mancha de óleo segmentada pelos métodos Met1:(OTSU, 1979), Met2: (HUANG <i>et al.</i> , 2005) e Met3: (MARQUES <i>et al.</i> , 2012).	50
Tabela 8	– Tempo de processamento (segundos) gasto na estimativa dos parâmetros de rugosidade e escala pixel a pixel das imagens exibidas nas Figuras 22(a) e 22(b).	53
Tabela 9	– Medidas descritivas das distâncias estocásticas obtidas por ambos os métodos $FMoLC$ e MLC	53
Tabela 10	– Distâncias estocásticas entre recortes de oceano.	54
Tabela 11	– Distâncias estocásticas entre recortes da mancha.	54
Tabela 12	– Distâncias estocásticas entre recortes de oceano e mancha escura.	55

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Produção científica	13
1.2	Organização da tese	13
2	FUNDAMENTOS DE IMAGENS SAR	15
2.1	Processamento <i>multi-look</i> de imagens SAR	17
3	MODELOS ESTATÍSTICOS PARA DADOS SAR	19
3.1	Relações importantes entre as distribuições G_I^0 e G_A^0	23
3.2	Distância estocástica aritmética-geométrica	24
3.3	Estimação de parâmetros via método de log-cumulantes	25
4	PROPOSTA DE UMA ABORDAGEM RÁPIDA PARA O MÉTODO DE LOG-CUMULANTES	29
4.1	Velocidade e acurácia dos métodos de estimação	32
5	PROCESSAMENTO DE IMAGENS SAR USANDO O MÉTODO DE LOG-CUMULANTES	40
5.1	Segmentação de imagens SAR	40
5.1.1	<i>Segmentação de imagens sintéticas</i>	45
5.1.2	<i>Segmentação de imagens SAR reais</i>	48
5.2	Detecção de mudanças em imagens SAR	51
6	CONCLUSÕES E TRABALHOS FUTUROS	56
6.1	Trabalhos futuros	57
	REFERÊNCIAS	58

1 INTRODUÇÃO

Processamento de imagens de radar de abertura sintética (SAR, do inglês *Synthetic Aperture Radar*) é um tema muito importante em sensoriamento remoto. Nos últimos anos o uso desse tipo de radar tem se intensificado e muitas aplicações, de interesse das comunidades científica e civil, têm surgido. Como exemplos podemos citar segmentação e identificação de manchas de óleo no mar (HUANG *et al.*, 2005; MARQUES *et al.*, 2012), mapeamento da extensão de desastres naturais como inundações (LONG *et al.*, 2014), mapeamento de rios subterrâneos em áreas áridas (SKONIECZNY *et al.*, 2015), mapeamento de águas da superfície terrestre (XU *et al.*, 2016), dentre outras. Neste trabalho destacamos o processamento de imagens SAR que utiliza modelos estatísticos para a descrição e análise das mesmas. Em particular, utilizamos as distribuições G_I^0 e G_A^0 propostas por Frery *et al.* (1997) para descrever imagens SAR em intensidade e amplitude, respectivamente.

Técnicas de processamento de imagens SAR que utilizam modelos estatísticos em geral fazem uso de métodos para inferir parâmetros do modelo adotado. Vale ressaltar a importância do conhecimento do modelo estatístico dos dados e de seus parâmetros nas etapas do processamento para que se obtenha sucesso nas mesmas. As estimativas dos parâmetros podem ser utilizadas como entradas em algoritmos de processamento de imagens SAR, assim como em filtragem e classificação. Inspirados em Mejail *et al.* (2003), propomos nesta tese o uso de estimativas dos parâmetros de modelo de dados SAR, em particular, o parâmetro de rugosidade, para construir uma imagem auxiliar a ser utilizada como entrada para algoritmos de segmentação baseados em *level set* e em limiarização.

Os métodos de estimação mais difundidos para derivar estimadores são o método dos momentos (MM) e o de máxima verossimilhança (MV) (LEHMANN, 1999). Recentemente, Nicolas (2002) desenvolveu um método alternativo para estimar parâmetros de funções densidades de probabilidades definidas em \mathbb{R}^+ , conhecido como método de log-cumulantes (MLC). Esse método é uma alternativa interessante aos métodos MM e MV pois gera estimadores fortemente consistentes, inclusive em situações em que o MM falha, e comumente envolve operações algébricas mais simples do que o MV. Além disso, o MLC é computacionalmente mais rápido que o MV e torna-se especialmente útil quando a abordagem do método MV revela-se inviável (KRYLOV *et al.*, 2013a).

Em virtude da vasta aplicação de imagens SAR em problemas de interesse da comunidade científica e civil, pelo menos dois aspectos são desejáveis, quando se usa os

parâmetros estimados de um modelo estatístico para processar estas imagens: rapidez e precisão. Portanto, existe a necessidade do processamento rápido e eficiente das imagens SAR, mas mantendo a fidedignidade da informação processada.

O objetivo central dessa tese é desenvolver, implementar e aplicar ferramentas de síntese, processamento e análise de imagens SAR, com ênfase nas informações contidas nos parâmetros de textura e escala das distribuições G_I^0 e G_A^0 estimados pelo método de log-cumulantes. Propomos ainda uma abordagem rápida para o método de log-cumulantes, denotada por FMoLC, para estimar os parâmetros de rugosidade e escala das distribuições G_I^0 e G_A^0 .

1.1 Produção científica

A produção científica oriunda desta tese resultou na publicação de um artigo de revista da base ISI (*Institute for Scientific Information*) destacado a seguir.

1. RODRIGUES, F. A. A. NETO, J. F. S. R. MARQUES, R. C. P. MEDEIROS, F. N. S. NOBRE, J. S.. SAR image segmentation using the roughness information. *IEEE Geosci. Remote Sens. Lett.*, v. 13, n. 2, p. 146–160, Fev. 2016.
2. RODRIGUES, F. A. A. NOBRE, J. S. VIGÉLIS, R. LIESENBERG, V. MEDEIROS, F. N. S.. A fast approach for parameter estimation via method of log-cumulants (a ser submetido).

1.2 Organização da tese

A estrutura desta tese segue a ordem a seguir.

- **Capítulo 2:** Apresenta os fundamentos de imagens de radar de abertura sintética.
- **Capítulo 3:** Descreve os modelos estatísticos atribuídos aos dados SAR em intensidade e amplitude, conhecidos como distribuições G_I^0 e G_A^0 , respectivamente. Este capítulo apresenta ainda algumas relações importantes entre essas distribuições, assim como uma breve introdução sobre a distância estocástica aritmética-geométrica.
- **Capítulo 4:** Descreve o método de estimação de parâmetros de distribuições de probabilidades adotado nesta tese que é o método de log-cumulantes.
- **Capítulo 5:** Introduce uma abordagem rápida do método de log-cumulantes.
- **Capítulo 6:** Apresenta duas propostas de aplicações em imagens SAR do método de log-cumulantes e sua abordagem rápida. A primeira aplicação trata da segmentação de

imagens SAR e a segunda da detecção de mudanças em imagens SAR.

- **Capítulo 7:** Resume as principais conclusões dessa tese, bem como perspectivas de prosseguimento desta pesquisa.

2 FUNDAMENTOS DE IMAGENS SAR

Ao longo das últimas décadas o uso do radar de abertura sintética tem aumentado principalmente porque o sistema de imageamento SAR emite sua própria fonte de luz, o que o torna independente da luz do dia, cobertura de nuvens e condições meteorológicas. 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 da simulação de uma antena de maior abertura por meio do deslocamento do sistema utilizado, conhecido como abertura sintética (MARQUES, 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.

O processo de geração de imagens SAR é influenciado por aspectos como banda de frequência e comprimento da onda eletromagnética (HORTA, 2009). O comprimento da onda tem influência na interação entre o sinal eletromagnético emitido e a superfície imageada, podendo ocorrer uma maior ou menor penetração (MARQUES, 2011). Uma maior penetração dos pulsos eletromagnéticos nos meios irá ocorrer para 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.

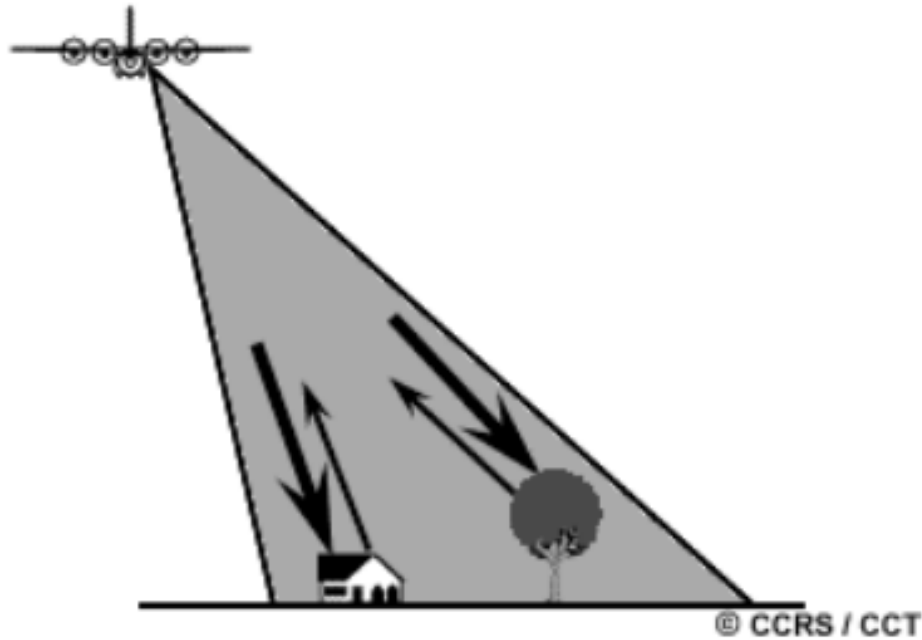
Tabela 1 – Bandas de frequência utilizadas nos sistemas SAR, com indicação de frequências e comprimentos de onda associados.

Banda	Ka	Ku	X	C	S	L	P
Frequência (GHz)	40-25	17,6-12	12-7,5	7,5-3,75	3,75-2	2-1	0,5-0,25
Comprimento da onda (cm)	0,75-1,2	1,7-2,5	2,5-4	4-8	8-15	15-30	60-120

Fonte: Adaptado de (MOREIRA *et al.*, 2013).

O sinal de retorno ou retroespalhado depende da rugosidade da superfície imageada (LEE; POTTIER, 2009), de modo que superfícies mais rugosas apresentam maior retroespalhamento do sinal de retorno do que superfícies menos rugosas. Em (MARQUES, 2011), o autor reporta que superfícies lisas (como lagos e rios) não geram retorno, pois toda radiação incidente não é refletida na direção da antena, o que resulta na formação de regiões escuras na imagem.

Figura 1 – Reflexão da energia emitida pelo sensor para diferentes graus de rugosidade da superfície.



Fonte: Retirada de (ANFINSEN, 2010).

Por outro lado, superfícies extremamente rugosas (como áreas urbanas) podem apresentar pontos de alto retroespalhamento formando regiões mais claras na imagem. A Figura 1 ilustra o efeito do retroespalhamento do sinal em diferentes tipos de superfícies.

Quando a rugosidade da superfície imageada é da mesma ordem de grandeza do comprimento de onda, a interferência das inúmeras componentes difusas gera um ruído denominado *speckle*, que dificulta a interpretação das imagens SAR. Este efeito provoca uma variação nas intensidades dos pixels causando na imagem um padrão granular (LEE; POTTIER, 2009).

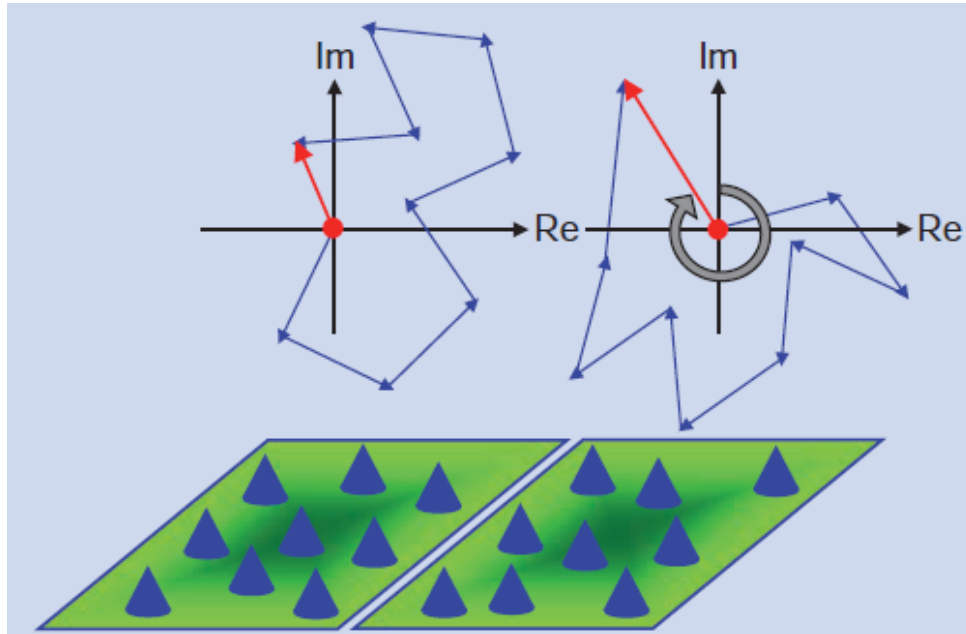
A intensidade de cada pixel de uma imagem SAR é formada pelo sinal retornado dentro de uma célula de resolução. O sinal consiste nas ondas refletidas de vários refletores elementares, ou melhor dizendo, na soma dos sinais refletidos dentro da célula de resolução. A Figura 2 ilustra dois exemplos de duas células de resolução distintas. Observe que a seta vermelha representa a soma (vetor resultante) dos sinais refletidos dentro de cada célula.

O vetor resultante ou fador, como mostra a Figura 2, é uma 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.



Fonte: Retirada de (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, $I = \text{Re}(S)^2 + \text{Im}(S)^2$. De acordo com Lee e Pottier (2009), ambos A e I podem ser considerados aleatórios.

2.1 Processamento *multi-look* de imagens SAR

Um procedimento bastante utilizado em imagens SAR é o processamento de múltiplas visadas (*multilook*). Esse procedimento consiste em imagear a célula de resolução L vezes e então gerar um único pixel por meio da média aritmética dos L vetores resultantes (LEE; POTTIER, 2009). Esse procedimento é feito na tentativa de diminuir o efeito do ruído *speckle*. Usualmente, L é denominado 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 uma visada ou *single look*. A Figura 3 apresenta duas imagens SAR reais da mesma região, mas com diferentes número de *looks*.

O processamento *multilook* de uma imagem SAR reduz o desvio padrão do ruído

Figura 3 – Imagem SAR com diferentes números de *looks*: 1 *look* e 8 *looks* .



Fonte: Adaptada de (MOREIRA *et al.*, 2013).

speckle por um fator de \sqrt{L} (OLIVER; QUEGAN, 1998). No entanto, este processamento é realizado à custa de uma resolução que se deteriora por um fator de L (LEE; JURKEVICH, 1994). Isto quer dizer que o processamento *multilook* reduz o ruído *speckle* e também reduz a informação de intensidade dos pixels. A imagem SAR resultante de um processamento por múltiplas visadas (*multilook*) é supostamente mais fácil de ser processada por técnicas clássicas de segmentação e classificação. Entretanto, por conta da redução da informação de intensidade dos pixels que o processamento *multilook* causa, nem sempre isso é verdade.

No próximo capítulo serão apresentadas duas distribuições de probabilidade, propostas por Frery *et al.* (1997), para descrever imagens SAR nos formatos de amplitude e intensidade.

3 MODELOS ESTATÍSTICOS PARA DADOS SAR

Com a aquisição da primeira imagem SAR nos EUA na década de 1970, a análise de dados SAR reais impulsionou o desenvolvimento de técnicas de modelagem estatística para descrever este tipo de dados (GAO *et al.*, 2013). De fato, os modelos estatísticos são essenciais para a interpretação destes dados (FRERY *et al.*, 1997). Um dos trabalhos precursores sobre modelagem estatística de dados SAR foi desenvolvido por Arsenault e April (1976). Este trabalho propôs um modelo para o ruído *speckle* e também estabeleceu um fundamento teórico para as pesquisas posteriores.

Um marco para o desenvolvimento da modelagem estatística de dados SAR foi o trabalho de Ward (1981), pois o mesmo estabeleceu um mecanismo físico para a composição de imagens SAR. Esse mecanismo hoje é conhecido como modelo multiplicativo e estabelece que o retorno Z do sistema SAR é obtido pelo produto entre o retroespalhamento da superfície imageada X e o ruído *speckle* Y . Sua expressão matemática é dada por:

$$Z = X.Y \tag{3.1}$$

Baseado na Equação (3.1) e considerando X e Y como variáveis aleatórias independentes, vários modelos estatísticos para dados SAR foram propostos, tais como as distribuições K (JAO, 1984; FRERY *et al.*, 1997) e *Weibull* (GAO *et al.*, 2013). Um trabalho de revisão desses modelos pode ser encontrado em (GAO *et al.*, 2013). Dentre os modelos conhecidos na literatura, merecem destaque as distribuições G_I^0 e G_A^0 apresentadas em (FRERY *et al.*, 1997). Os subscritos I e A em G_I^0 e G_A^0 indicam a clara distinção entre os formatos de imagens SAR em intensidade (I) e amplitude (A).

Considerando que o sinal de retorno Z pode ser representado como o produto de duas variáveis aleatórias independentes, Frery *et al.* (1997) propuseram a representação do retorno Z em intensidade como o produto das variáveis aleatória $X \sim \Gamma^{-1}(-\alpha, \gamma)$ e $Y \sim \Gamma(L, L)$. A distribuição resultante do produto dessas duas variáveis aleatórias é a distribuição G_I^0 . Para o retorno em amplitude, Frery *et al.* (1997) consideraram as variáveis aleatórias $X \sim \Gamma^{-1/2}(\alpha, \gamma)$ e $Y \sim \Gamma^{1/2}(L, L)$, tendo como distribuição resultante a distribuição G_A^0 . A seguir são apresentadas as distribuições para os retornos em intensidade e amplitude para imagens SAR.

Uma variável aleatória contínua Z tem distribuição G_I^0 se sua função densidade de

probabilidade é dada por:

$$f_{G_I^0}(z, \theta) = \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{L-1} (\gamma + Lz)^{\alpha-L}, \quad (3.2)$$

com r -ésimo momento não central dado por:

$$E_{G_I^0}[Z^r] = \left(\frac{\gamma}{L}\right)^r \frac{\Gamma(-\alpha - r) \Gamma(L + r)}{\Gamma(-\alpha) \Gamma(L)}, \quad \alpha < -r. \quad (3.3)$$

Diz-se que a variável aleatória contínua Z tem distribuição G_A^0 se sua função densidade de probabilidade é dada por:

$$f_{G_A^0}(z, \theta) = \frac{2L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{2L-1} (\gamma + Lz^2)^{\alpha-L}, \quad (3.4)$$

com r -ésimo momento não central dado por:

$$E_{G_A^0}[Z^r] = \left(\frac{\gamma}{L}\right)^{\frac{r}{2}} \frac{\Gamma(-\alpha - \frac{r}{2}) \Gamma(L + \frac{r}{2})}{\Gamma(-\alpha) \Gamma(L)}, \quad \alpha < -\frac{r}{2}. \quad (3.5)$$

Para ambas as distribuições, $z > 0$, $\theta = (\alpha, \gamma, L)^\top$, $\alpha < 0$ é o parâmetro de rugosidade, $\gamma > 0$ o parâmetro de escala, $L \geq 1$ o número de *looks* e $\Gamma(\cdot)$ a função gama. Nesta tese, adotamos como modelos de dados SAR em intensidade e amplitude as distribuições G_I^0 e G_A^0 , respectivamente como sugerido em (FRERY *et al.*, 1997).

A grande vantagem em utilizar as distribuições G_I^0 e G_A^0 é a flexibilidade das mesmas descreverem regiões homogêneas, heterogêneas e extremamente heterogêneas de imagens SAR (FRERY *et al.*, 1997). Essa vantagem não é encontrada em algumas distribuições propostas para modelar imagens SAR, tais como as distribuições K e Weibull (GAO *et al.*, 2013). Outro aspecto importante nessas distribuições é que o parâmetro α tem interpretação física de rugosidade (textura), podendo assim ser utilizado como uma medida de textura (FRERY *et al.*, 1997).

Como descreve o Capítulo 1, o processamento *multilook* de imagens SAR impõe um parâmetro de controle do ruído *speckle*, reduzindo a variância das intensidades dos pixels. As distribuições G_I^0 e G_A^0 nas Figuras 4 e 5 confirmam e apresentam esse comportamento de redução de variância, quando o número de *looks* aumenta. A Figura 4 apresenta vários padrões da distribuição G_A^0 com $L = 1$ segundo diferentes padrões de rugosidade. A Figura 5 ilustra

a redução na variância, em decorrência do aumento do número de *looks* para $L = 8$. A curva representada pela linha azul contínua na Figura 4 ($L = 1$) apresenta variância maior que a da curva azul contínua da Figura 5 ($L = 8$), indicando assim uma redução na variância. Comportamento idêntico é observado para a distribuição G_I^0 .

Figura 4 – Padrão da distribuição G_A^0 com parâmetros $L = 1$, $\gamma = 1$ (linha contínua), $\gamma = 10$ (linha tracejada), $\alpha = -1.5$ (vermelho), $\alpha = -4.5$ (verde) e $\alpha = -12.5$ (azul).





Figura 5 – Padrão da distribuição G_A^0 com parâmetros $L = 8$, $\gamma = 1$ (linha contínua), $\gamma = 10$ (linha tracejada), $\alpha = -1.5$ (vermelho), $\alpha = -4.5$ (verde) e $\alpha = -12.5$ (azul).



Fonte: Retirada de (MARQUES, 2011).

Vale destacar que a redução da variância pode ser demonstrada matematicamente em que a variância de Z , com distribuição G_A^0 , tende para 0 (zero) quando $L \rightarrow \infty$. Para tanto, a demonstração de que $\lim_{L \rightarrow \infty} Var[Z] = 0$ é dada por:

$$Var[Z] = E_{G_A^0}[Z^2] - \left(E_{G_A^0}[Z]\right)^2, \quad (3.6)$$

em que $Var[Z]$ pode ser escrita, usando a Equação (3.5), como:

$$Var[Z] = \left(\frac{\gamma}{L}\right) \frac{\Gamma(-\alpha - 1)\Gamma(L + 1)}{\Gamma(-\alpha)\Gamma(L)} - \left[\left(\frac{\gamma}{L}\right)^{\frac{1}{2}} \frac{\Gamma(-\alpha - \frac{1}{2})\Gamma(L + \frac{1}{2})}{\Gamma(-\alpha)\Gamma(L)}\right]^2. \quad (3.7)$$

Desenvolvendo um pouco mais esta expressão, tem-se:

$$Var[Z] = \left(\frac{\gamma}{L}\right) \left[\frac{\Gamma(-\alpha - 1)\Gamma(L + 1)}{\Gamma(-\alpha)\Gamma(L)} - \left(\frac{\Gamma(-\alpha - \frac{1}{2})\Gamma(L + \frac{1}{2})}{\Gamma(-\alpha)\Gamma(L)} \right)^2 \right]. \quad (3.8)$$

A partir da Equação (3.8) pode-se verificar que $\lim_{L \rightarrow \infty} Var[Z] = 0$. Esse mesmo resultado é válido quando a variável aleatória Z segue uma distribuição G_I^0 , com demonstração análoga. A Equação (3.8) pode ser reescrita, colocando $\Gamma(-\alpha)$ em evidência, como:

$$Var[Z] = \left(\frac{\gamma}{\Gamma(-\alpha)L}\right) \left[\frac{\Gamma(-\alpha - 1)\Gamma(L + 1)}{\Gamma(L)} - \frac{1}{\Gamma(-\alpha)} \left(\frac{\Gamma(-\alpha - \frac{1}{2})\Gamma(L + \frac{1}{2})}{\Gamma(L)} \right)^2 \right], \quad (3.9)$$

que pode ser reescrita como:

$$\text{Var}[Z] = \frac{1}{\Gamma(-\alpha)} \left(\frac{\gamma}{L} \right) \left[\frac{\Gamma(-\alpha - 1)\Gamma(L + 1)}{\Gamma(L)} - \frac{1}{\Gamma(-\alpha)} \left(\frac{\Gamma(-\alpha - \frac{1}{2})\Gamma(L + \frac{1}{2})}{\Gamma(L)} \right)^2 \right]. \quad (3.10)$$

A função $\Gamma(x)$ é crescente, e $\forall x > 0$ temos que $\Gamma(x) > 0$. Como $\alpha < 0$, temos que $\Gamma(-\alpha) > 0$ e portanto na Equação (3.10) temos $\lim_{\alpha \rightarrow -\infty} \text{Var}[Z] = 0$. Esse mesmo resultado é válido quando a variável aleatória Z segue uma distribuição G_I^0 , com demonstração análoga.

Portanto, se Z é uma variável aleatória seguindo uma distribuição G_I^0 ou G_A^0 , tem-se que:

$$\lim_{L \rightarrow \infty} \text{Var}[Z] = 0 \quad (3.11)$$

e

$$\lim_{\alpha \rightarrow -\infty} \text{Var}[Z] = 0. \quad (3.12)$$

Como a intensidade do ruído *speckle* é diretamente proporcional à variância de Z , a Equação (3.11) evidencia a importância do parâmetro L como controle do ruído *speckle*. Já a Equação (3.12) revela que a intensidade do ruído *speckle* é mais forte quando o parâmetro de rugosidade (α) for próximo de 0 (zero).

3.1 Relações importantes entre as distribuições G_I^0 e G_A^0

Segundo Frery *et al.* (1997), as distribuições G_I^0 e G_A^0 são relacionadas pela expressão:

$$f_{G_I^0}(z) = \frac{1}{2\sqrt{z}} f_{G_A^0}(\sqrt{z}). \quad (3.13)$$

Esse resultado se deve ao fato de que as variáveis aleatórias Z_I e Z_A , modeladas respectivamente pelas distribuições G_I^0 e G_A^0 , apresentam a relação $Z_I = Z_A^2$ (FRERY *et al.*, 1997). Como consequência dessa relação tem-se que:

$$F_{G_I^0}(z) = F_{G_A^0}(\sqrt{z}), \quad (3.14)$$

em que $F_{G_I^0}$ e $F_{G_A^0}$ são as funções de distribuição para G_I^0 e G_A^0 , respectivamente. Para obtermos a Equação (3.13), basta derivarmos ambos os lados da Equação (3.14). Como resultado da Equação (3.14), tem-se que:

$$F_{G_I^0}^{-1}(z) = F_{G_A^0}^{-1}(\sqrt{z}), \quad (3.15)$$

em que $F_{G_I^0}^{-1}$ e $F_{G_A^0}^{-1}$ são as funções de distribuição inversas das distribuições G_I^0 e G_A^0 , respectivamente. Outra relação importante entre as variáveis aleatórias Z_I e Z_A , diz respeito aos momentos não centrais (FRERY *et al.*, 1997):

$$E_{G_I^0}[Z^r] = E_{G_A^0}[Z^{2r}]. \quad (3.16)$$

3.2 Distância estocástica aritmética-geométrica

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 *et al.*, 2010a) é apresentada uma relação de distâncias estocásticas, dentre as quais se encontra a distância aritmética-geométrica, adotada nesta tese.

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 *et al.*, 2010a):

$$d_{AG}(Z_1, Z_2) = \frac{1}{2} \int (f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)) \log \left(\frac{f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)}{\sqrt{f_{Z_1}(z, \theta_1) f_{Z_2}(z, \theta_2)}} \right) dz. \quad (3.17)$$

Em geral, a integral na Equação (3.17) não apresenta solução analítica e, portanto, deve ser solucionada numericamente.

Nesta tese a distância estocástica aritmética-geométrica é utilizada para fornecer medidas que avaliam quantitativamente resultados experimentais de segmentação e também é utilizada como proposta de detecção de mudanças em cenas extraídas de imagens SAR. Em particular, dentre as medidas de avaliação de resultados, utilizamos duas medidas propostas por Marques *et al.* (2012), as quais foram desenvolvidas a partir da distância estocástica aritmética-geométrica. A primeira medida refere-se à dificuldade de segmentação e quantifica o contraste entre o fundo (*background*) e o objeto (*foreground*) em uma imagem SAR, avaliando portanto, a dificuldade do processamento destas regiões (MARQUES *et al.*, 2012):

$$DoS = \frac{1}{d_{AG}(Z_1, Z_2)}. \quad (3.18)$$

A segunda medida de avaliação, denominada ajuste cruzado de região, 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 *et al.*, 2012):

$$CRF = \frac{1}{1 + \sqrt{DoS \left| d_{AG}(Z_f^r, Z_b^s) - d_{AG}(Z_f^s, Z_b^r) \right|}}. \quad (3.19)$$

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 (3.19) indicam respectivamente imagem de referência, segmentada, *background* e *foreground*. Mais detalhes sobre as medidas DoS e CRF se encontram em (MARQUES *et al.*, 2012).

Para utilizarmos efetivamente as distribuições G_I^0 e G_A^0 , a distância estocástica aritmética-geométrica bem como as medidas DoS e CRF em processamento e análise de imagens SAR, é necessário estimarmos os parâmetros das distribuições G_I^0 e G_A^0 . No próximo capítulo será apresentado um método de estimação de parâmetros proposto por Nicolas (2002), conhecido como método de log-cumulantes.

3.3 Estimação de parâmetros via método de log-cumulantes

O método de log-cumulantes (MLC) tem sido utilizado com resultados satisfatórios em processamentos de imagens SAR, especialmente para pequenas amostras que é um problema crítico em várias aplicações (KRYLOV *et al.*, 2013a). 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). O método de log-cumulantes é apresentado a seguir.

Seja Z uma variável aleatória contínua com função densidade de probabilidade $f_Z(z, \theta)$ definida em \mathbb{R}^+ . O método de log-cumulantes, baseado na transformada de Mellin de $f_Z(z, \theta)$ (NICOLAS, 2002; GAO *et al.*, 2013; TISON *et al.*, 2004; CHENG *et al.*, 2013), é definido como:

$$\phi_Z(s) = \int_0^{\infty} u^{s-1} f_Z(u, \theta) du = E[Z^{s-1}], \quad (3.20)$$

com s sendo um número complexo com norma unitária (NICOLAS, 2002).

Existem dois conceitos importantes para a construção do método de log-cumulantes que são os log-momentos e log-cumulantes de ordem ν . É possível obtermos expressões analíticas para os log-momentos e log-cumulantes de ordem ν por simples derivações de $\phi_Z(s)$, avaliadas em $s = 1$. O log-momento de ordem ν pode ser definido como (NICOLAS, 2002):

$$\tilde{m}_\nu = \left. \frac{d^\nu \phi_Z(s)}{ds^\nu} \right|_{s=1}, \nu \in \mathbb{N}. \quad (3.21)$$

Baseado no logaritmo natural de $\phi_Z(s)$, pode-se obter o log-cumulante de ordem ν como (NICOLAS, 2002; CHENG *et al.*, 2013):

$$\tilde{k}_\nu = \left. \frac{d^\nu \psi_Z(s)}{ds^\nu} \right|_{s=1}, \nu \in \mathbb{N}, \quad (3.22)$$

com $\psi_Z(s) = \log(\phi_Z(s))$.

A estratégia do método de log-cumulantes para estimar o vetor de parâmetros θ se baseia na relação entre os log-momentos e log-cumulantes e é dada por:

$$\tilde{k}_\nu = \tilde{m}_\nu - \sum_{i=1}^{\nu-1} \binom{\nu-1}{i-1} \tilde{k}_i \tilde{m}_{\nu-i}. \quad (3.23)$$

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

$$\begin{cases} \tilde{k}_1 = \tilde{m}_1 \\ \tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2. \end{cases} \quad (3.24)$$

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

$$\hat{\tilde{m}}_\nu = \frac{1}{n} \sum_{i=1}^n \log z_i^\nu, \quad (3.25)$$

em que z_i , $i \in \{1, 2, \dots, n\}$, é uma amostra da variável aleatória Z . A seguir é exibido o método de log-cumulantes e sua utilização na estimação dos parâmetros das funções densidades de probabilidades G_I^0 e G_A^0 .

Para a distribuição de probabilidade G_I^0 , a função $\phi_Z(s)$ pode ser obtida aplicando a Equação (3.20), ou seja, utilizando a Equação (3.3) para obter $E[Z^{s-1}]$, e portanto,

$$\phi_{G_I^0}(s) = \left(\frac{\gamma}{L}\right)^{s-1} \frac{\Gamma(1-s-\alpha)\Gamma(L+s-1)}{\Gamma(-\alpha)\Gamma(L)}, \quad (3.26)$$

com $\alpha < -s + 1$. Utilizando a Equação (3.22), podemos obter o seguinte sistema de equações (CUI; DATCU, 2011):

$$\begin{cases} \tilde{k}_1 = \log\left(\frac{\gamma}{L}\right) + \Psi^0(L) - \Psi^0(-\alpha) \\ \tilde{k}_2 = \Psi^1(L) - \Psi^1(-\alpha), \end{cases} \quad (3.27)$$

em que $\Psi^0(\cdot)$ e $\Psi^1(\cdot)$ correspondem às funções digamma e trigamma, respectivamente (ARF-KEN; WEBER, 2005).

Assim, para estimar o vetor de parâmetros $\theta^* = (\alpha, \gamma)^\top$ da distribuição G_γ^0 , aplicamos as Equações (3.24) e (3.27) substituindo \tilde{m}_1 e \tilde{m}_2 pelos correspondentes log-momentos amostrais, dados pela Equação (3.25).

Para a distribuição de probabilidade G_A^0 , a função $\phi_Z(s)$ pode ser obtida de maneira análoga que a encontrada para a distribuição G_γ^0 . No caso da G_A^0 tem-se:

$$\phi_{G_A^0}(s) = \left(\frac{\gamma}{L}\right)^{\frac{s-1}{2}} \frac{\Gamma(\frac{1-s}{2} - \alpha)\Gamma(L + \frac{s-1}{2})}{\Gamma(-\alpha)\Gamma(L)}, \quad (3.28)$$

com $\alpha < \frac{-s+1}{2}$. A partir da Equação (3.22) obtém-se o seguinte sistema de equações (CUI *et al.*, 2014):

$$\begin{cases} 2\tilde{k}_1 = \log\left(\frac{\gamma}{L}\right) + \Psi^0(L) - \Psi^0(-\alpha) \\ 4\tilde{k}_2 = \Psi^1(L) - \Psi^1(-\alpha), \end{cases} \quad (3.29)$$

com $\Psi^0(\cdot)$ e $\Psi^1(\cdot)$ sendo as funções digamma e trigamma, respectivamente. A estimação do vetor de parâmetros $\theta^* = (\alpha, \gamma)$ da distribuição G_A^0 é obtida de maneira idêntica como a obtida para a distribuição G_A^0 .

As funções $\Psi^0(\cdot)$ e $\Psi^1(\cdot)$ não admitem inversa, logo a solução dos sistemas nas Equações (3.27) e (3.29) não podem ser obtidas explicitamente e portanto, procedimentos numéricos são necessários. Em geral, esses procedimentos são computacionalmente lentos e reduzir o custo computacional é um desafio importante e desejável. Vale ressaltar que as estimativas obtidas por métodos numéricos estão sujeitas a problemas de convergência para um ótimo local, não convergência, dentre outros.

Nesta tese utilizamos propriedades da função gama para sugerir uma mudança analítica que reduz o custo computacional do método de log-cumulantes para estimar os parâmetros de escala e rugosidade das distribuições G_I^0 e G_A^0 . No próximo capítulo é apresentada essa abordagem rápida para o método de log-cumulantes.

4 PROPOSTA DE UMA ABORDAGEM RÁPIDA PARA O MÉTODO DE LOG-CUMULANTES

Neste capítulo apresentamos uma abordagem rápida do método de log-cumulantes para a estimação dos parâmetros de rugosidade (α) e escala (γ) das distribuições G_I^0 e G_A^0 .

Para encontrar as soluções dos sistemas descritos nas Equações (3.27) e (3.29), podemos inicialmente considerar que $\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2$. Com isso, a única variável (incógnita) na segunda equação dos sistemas descritos nas Equações (3.27) e (3.29) é o parâmetro de rugosidade (α) como um argumento da função trigama, isto é, $\tilde{m}_2 - \tilde{m}_1^2 = \Psi^1(L) - \Psi^1(-\alpha)$ para a distribuição G_I^0 e $4(\tilde{m}_2 - \tilde{m}_1^2) = \Psi^1(L) - \Psi^1(-\alpha)$ para a distribuição G_A^0 .

O método proposto para encontrar a solução para as Equações (3.27) e (3.29) consiste de duas etapas. Inicialmente encontra-se um estimador ($\hat{\alpha}$) para o parâmetro de rugosidade (α) das distribuições G_I^0 e G_A^0 considerando as identidades $\tilde{m}_2 - \tilde{m}_1^2 = \Psi^1(L) - \Psi^1(-\alpha)$ e $4(\tilde{m}_2 - \tilde{m}_1^2) = \Psi^1(L) - \Psi^1(-\alpha)$, respectivamente. Em seguida, é feita a substituição de α por $\hat{\alpha}$ na primeira equação de cada sistema (Equações (3.27) e (3.29)), resultando em estimadores para os parâmetros de escala das distribuições G_I^0 e G_A^0 .

A obtenção dos estimadores de rugosidade para as distribuições G_I^0 e G_A^0 é baseada em duas identidades, sendo a primeira delas a função poligama (ARFKEN; WEBER, 2005) dada por:

$$\Psi^n(w) = \frac{d^{n+1} \ln(\Gamma(w))}{dw^{n+1}}, \quad (4.1)$$

em que $n \in \mathbb{N}^*$ e $w > 0$. A segunda identidade é a representação alternativa da função gama (ABRAMOWITZ; STEGUN, 1972):

$$\Gamma(w) = \frac{1}{we^{\tau w} \prod_{k=1}^{\infty} \left(1 + \frac{w}{k}\right) e^{-\frac{w}{k}}}, \quad (4.2)$$

em que $\tau = 0,5772156649\dots$ é a constante de Euler-Macheroni. Aplicando o logaritmo natural na Equação (4.2), obtém-se:

$$\ln(\Gamma(w)) = -\ln(w) - \tau w - \sum_{k=1}^{\infty} \left[\ln\left(1 + \frac{w}{k}\right) - \frac{w}{k} \right]. \quad (4.3)$$

Utilizando a Equação (4.1) podemos reescrever o termo $\Psi^1(-\alpha)$ como:

$$\Psi^1(-\alpha) = \frac{d^2 \ln(\Gamma(-\alpha))}{d(-\alpha)^2}. \quad (4.4)$$

Desenvolvendo as derivadas parciais do lado direito da Equação (4.4), em que $\ln(\Gamma(-\alpha))$ pode ser obtido substituindo w por $-\alpha$ na Equação (4.3), tem-se:

$$\Psi^1(-\alpha) = \sum_{k=0}^{\infty} \frac{1}{(k-\alpha)^2}, \quad (4.5)$$

ou ainda:

$$\Psi^1(-\alpha) = \frac{1}{(-\alpha)^2} + \sum_{k=1}^{\infty} \frac{1}{(k-\alpha)^2}. \quad (4.6)$$

Como $\forall \alpha < 0$, então a ordem de magnitude do termo $\sum_{k=1}^{\infty} \frac{1}{(k-\alpha)^2}$ não excede o valor $\frac{1}{-\alpha}$. Para representar esse fato utilizamos a notação apresentada em (KHURI, 2003):


$$\sum_{k=1}^{\infty} \frac{1}{(k-\alpha)^2} = O\left(\frac{1}{-\alpha}\right). \quad (4.7)$$

Nessa tese, tomamos apenas o primeiro termo da soma infinita na Equação (4.6) como uma aproximação para $\Psi^1(-\alpha)$, ou seja,

$$\Psi^1(-\alpha) = \frac{1}{\alpha^2} + O\left(\frac{1}{-\alpha}\right), \quad (4.8)$$

$\forall \alpha < 0$. É importante enfatizar que o termo não considerado na aproximação, ou seja, $\sum_{k=1}^{\infty} \frac{1}{(k-\alpha)^2}$, tem menor impacto quando $\alpha \rightarrow -\infty$. A Figura 6 ilustra esse comportamento. Pode-se verificar que a medida que $\alpha \rightarrow -\infty$, as duas curvas (funções) se aproximam.

Figura 6 – Comportamento das funções $\Psi^1(-\alpha)$ e $\frac{1}{\alpha^2}$.



A partir do resultado alcançado na Equação (4.8) foi elaborada a seguinte proposição:

Proposição 1. A função $\Psi^1(x) = \sum_{k=0}^{\infty} \frac{1}{(k-\alpha)^2}$ satisfaz a expressão:

$$\Psi^1(x) = \frac{1}{x^2} + O\left(\frac{1}{x}\right). \quad (4.9)$$

Adicionalmente, vale a desigualdade:

$$0 < \Psi^1(x) - \frac{1}{x^2} \leq \frac{1}{x}, \quad \forall x > 0. \quad (4.10)$$

Demonstração:

Para qualquer $x > 0$, podemos escrever:

$$\int_x^{\infty} \frac{1}{y^2} dy = \sum_{k=1}^{\infty} \int_{x+k-1}^{x+k} \frac{1}{y^2} dy \geq \sum_{k=1}^{\infty} \int_{x+k-1}^{x+k} \frac{1}{(k+x)^2} dy = \sum_{k=1}^{\infty} \frac{1}{(k+x)^2}.$$

como

$$\int_x^{\infty} \frac{1}{y^2} dy = \left[-\frac{1}{y} \right]_{y=x}^{y=\infty} = \frac{1}{x},$$

obtem-se então,

$$0 < \Psi^1(x) - \frac{1}{x^2} = \sum_{k=1}^{\infty} \frac{1}{(k+x)^2} \leq \frac{1}{x},$$

como mostra a Equação (4.9).

Portanto, para encontrar o estimador para o parâmetro de rugosidade da distribuição G_I^0 basta substituir $\Psi^1(-\alpha)$ em $\tilde{m}_2 - \tilde{m}_1^2 = \Psi^1(L) - \Psi^1(-\alpha)$ pela aproximação proposta na Equação (4.8). Tem-se, portanto as expressões:

$$\hat{\alpha} = \begin{cases} -\left| \sqrt{\frac{1}{\Psi^1(L) - \tilde{k}_2}} \right|, & \Psi^1(L) - \tilde{k}_2 < 0 \\ -\sqrt{\frac{1}{\Psi^1(L) - \tilde{k}_2}}, & \Psi^1(L) - \tilde{k}_2 > 0. \end{cases} \quad (4.11)$$

Em que $|\cdot|$ representa o operador norma. Para os casos em que $\Psi^1(L) - \tilde{k}_2 = 0$, não é possível estimar o parâmetro de rugosidade. Entretanto, esses casos são raros.

A segunda etapa do método proposto consiste em encontrar um estimador para o parâmetro de escala (γ) da distribuição G_I^0 . O estimador para γ é obtido substituindo α na primeira expressão da Equação (3.27) por seu estimador $\hat{\alpha}$, proposto na Equação (4.11). Assim, o estimador para o parâmetro γ é obtido segundo a expressão:

$$\hat{\gamma} = \exp \left[\tilde{k}_1 - \Psi^0(L) + \Psi^0(-\hat{\alpha}) \right] L. \quad (4.12)$$

Os estimadores para os parâmetros de rugosidade e escala da distribuição G_A^0 são obtidos de forma análoga aos encontrados para a distribuição G_I^0 . Para tanto, inicialmente substitui-se o termo $\Psi^1(-\alpha)$ em $4(\tilde{m}_2 - \tilde{m}_1^2) = \Psi^1(L) - \Psi^1(-\alpha)$ pela aproximação proposta na Equação (4.8), de modo que:

$$\hat{\alpha} = \begin{cases} -\left| \sqrt{\frac{1}{\Psi^1(L) - 4\tilde{k}_2}} \right|, & \Psi^1(L) - \tilde{k}_2 < 0 \\ -\sqrt{\frac{1}{\Psi^1(L) - 4\tilde{k}_2}}, & \Psi^1(L) - \tilde{k}_2 > 0. \end{cases} \quad (4.13)$$

Em que $|\cdot|$ corresponde ao operador norma. Finalmente, o estimador para γ é obtido substituindo α na primeira expressão da Equação (3.29) por seu estimador $\hat{\alpha}$, proposto na Equação (4.13). Assim, o estimador para o parâmetro γ é dado por:

$$\hat{\gamma} = \exp\left[2\tilde{k}_1 - \Psi^0(L) + \Psi^0(-\hat{\alpha})\right] L. \quad (4.14)$$

Nessa tese, o método proposto foi denominado FMoLC, do inglês *Fast Method of Log-Cumulants*.

4.1 Velocidade e acurácia dos métodos de estimação

Para avaliar e comparar a precisão dos dois métodos de estimação de parâmetros estudados, isto é, MLC e FMoLC, realizamos experimentos de Monte Carlo, com amostras simuladas das distribuições G_I^0 e G_A^0 , e calculamos o erro quadrático médio (MSE) para ambos os métodos. Também calculamos o tempo computacional consumido por cada método para estimar os parâmetros de rugosidade e escala. Esses experimentos foram realizados com o Matlab versão 7.8.0 e R versão 3.1.1, em uma máquina com CPU de 3,4GHz com 8GB de RAM.

As simulações das amostras aleatórias de ambas distribuições G_I^0 e G_A^0 foram realizadas utilizando o método da transformada inversa. Esse método de simulação é descrito como segue. *Seja U uma variável aleatória sobre o intervalo $(0, 1)$. Para qualquer função de distribuição F contínua, a variável aleatória definida como $Z = F^{-1}(U)$ tem função de distribuição dada por F (ROSS, 2013).*

Com base nessa descrição, a simulação de uma variável aleatória contínua Z com função de distribuição F pode ser obtida gerando um valor aleatório u da distribuição uniforme no intervalo $(0, 1)$ e aplicando esse valor em $F^{-1}(u)$. Desse modo, o procedimento de simulação das variáveis aleatórias envolvidas nos experimentos de Monte Carlo foram:

- As amostras simuladas da variável aleatória Z_A , seguindo uma distribuição G_A^0 , foram obtidas usando a identidade (MARQUES *et al.*, 2012):

$$Z_A = \sqrt{-\frac{\gamma}{\alpha} \Upsilon_{2L, -2\alpha}^{-1}(U)}, \quad (4.15)$$

em que $\Upsilon_{2L, -2\alpha}^{-1}$ é a função de distribuição inversa da distribuição F -Snedecor with $2L$ e -2α sendo os graus de liberdade, e U uma variável aleatória com distribuição uniforme sobre $(0, 1)$. Nesse caso, $\Upsilon_{2L, -2\alpha}^{-1}$ é uma aproximação para a função de distribuição inversa da distribuição G_A^0 , ou seja para $F_{G_A^0}^{-1}(z)$.

- Para gerar amostras da variável aleatória Z_I , com distribuição G_I^0 , foi considerada a relação entre as variáveis aleatórias $Z_I = Z_A^2$ (FRERY *et al.*, 1997; LEE; POTTIER, 2009), logo:

$$Z_I = -\frac{\gamma}{\alpha} \Upsilon_{2L, -2\alpha}^{-1}(U). \quad (4.16)$$

Utilizando esse procedimento de simulação, foram geradas amostras aleatórias das distribuições G_I^0 e G_A^0 combinando os seguintes espaços paramétricos: Para a distribuição G_I^0 os parâmetros de rugosidade foram $\alpha \in \{-1,5, -3,0, -5,0\}$, número de *looks* $L \in \{1, 5, 8\}$ e sem perdas de generalidades, os parâmetros de escala foram escolhidos de forma que $E_{G_I^0}[Z_I] = 1$. Para a distribuição G_A^0 utilizamos $\alpha \in \{-1,5, -5,0, -8,0\}$, número de *looks* $L \in \{1, 5, 8\}$ e os parâmetros de escala foram escolhidos de forma que $E_{G_A^0}[Z_A] = 1$. As Tabelas 2 e 3 mostram os cenários dos experimentos avaliados para as distribuições G_I^0 e G_A^0 , respectivamente.

Tabela 2 – Cenários dos experimentos realizados para a distribuição G_I^0 .

Cenários	1	2	3	4	5	6	7	8	9
α	-1,5	-1,5	-1,5	-3,0	-3,0	-3,0	-5,0	-5,0	-5,0
γ	0,5	0,5	0,5	2	2	2	4	4	4
L	1	5	8	1	5	8	1	5	8

Tabela 3 – Cenários dos experimentos para a distribuição G_A^0 .

Cenários	1	2	3	4	5	6	7	8	9
α	-1,5	-1,5	-1,5	-5,0	-5,0	-5,0	-8,0	-8,0	-8,0
γ	1	0,82	0,81	5,42	4,47	4,39	9,24	7,62	7,48
L	1	5	8	1	5	8	1	5	8

Os experimentos de Monte Carlo foram realizados para cada cenário usando diferentes tamanhos de amostra, ou seja, $n \in \{9, 25, 49, 81, 121\}$. Para cada tamanho de amostra, foram realizadas 1000 repetições, ou seja, foram considerados 45000 experimentos de Monte Carlo para cada distribuição de probabilidade.

Para cada amostra aleatória simulada das distribuições G_I^0 e G_A^0 nos experimentos de Monte Carlo, estimamos os respectivos parâmetros de rugosidade e escala considerando ambos os métodos *MLC* e *FoMLC*. Daí computamos o erro médio quadrático das estimativas dos parâmetros de rugosidade e escala segundo (GAMBINI *et al.*, 2015):

$$EMQ_\alpha = \frac{1}{1000} \sum_{i=1}^{1000} (\hat{\alpha}_i - \alpha)^2, \quad (4.17)$$

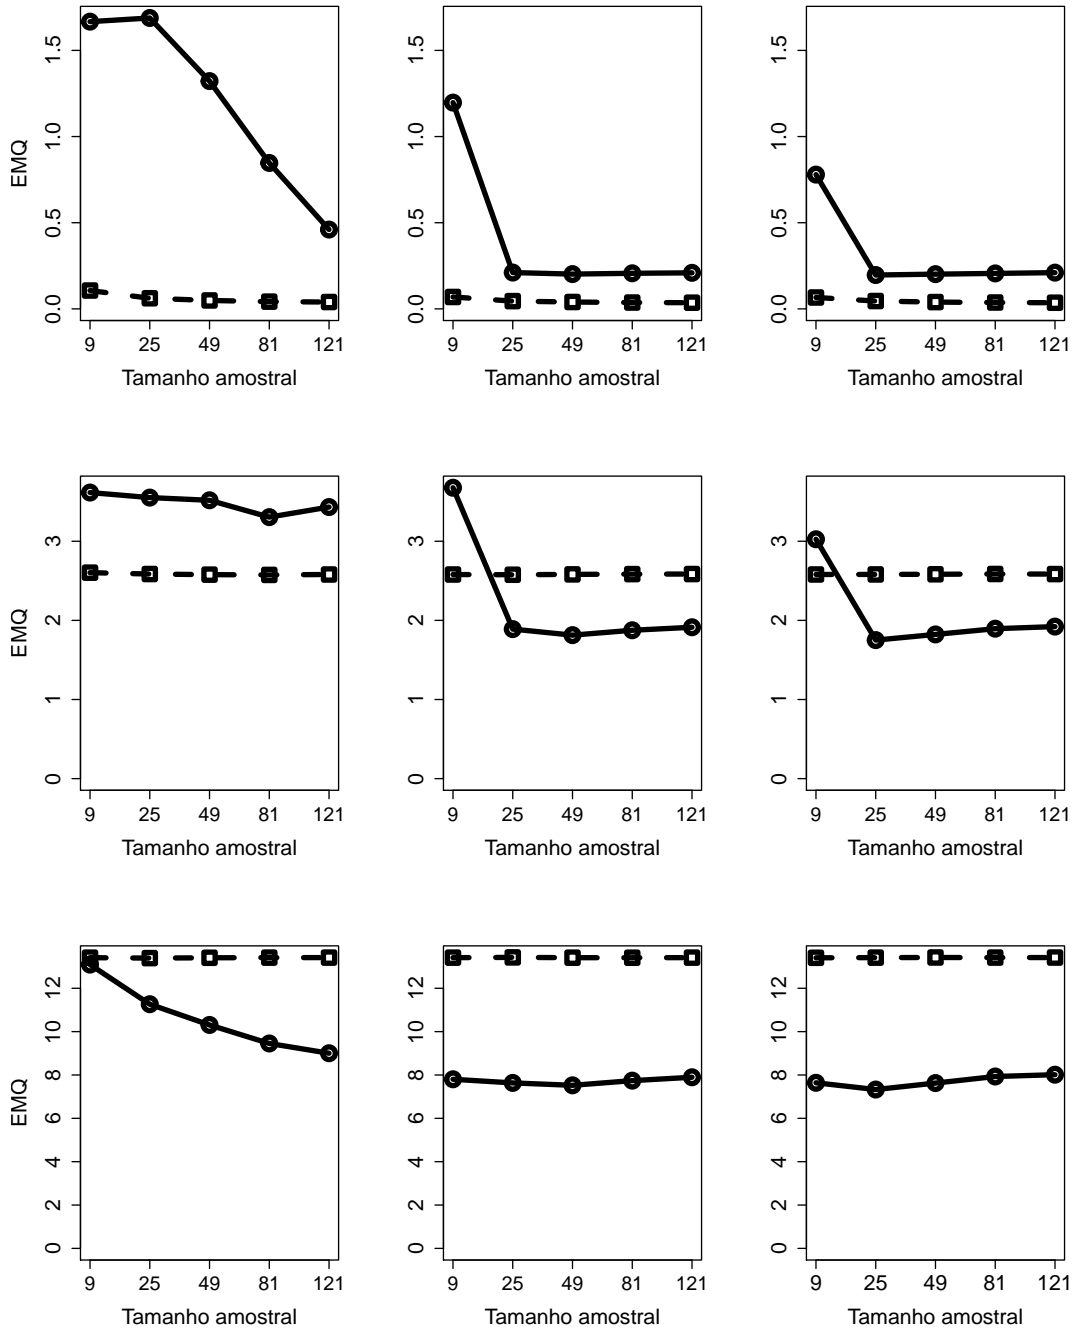
$$EMQ_\gamma = \frac{1}{1000} \sum_{i=1}^{1000} (\hat{\gamma}_i - \gamma)^2. \quad (4.18)$$

Os resultados dos experimentos de Monte Carlo estão apresentados nas Figuras 7 e 8 para a distribuição G_I^0 , e nas Figuras 9 e 10 para a distribuição G_A^0 .

Os resultados mostraram que, para a distribuição G_I^0 , o erro médio quadrático (*EMQ*) das estimativas dos parâmetros de rugosidade e escala gerados pela versão rápida do método de log-cumulantes (*FMoLC*), foi mais sensível ao tamanho da amostra. Observa-se que nas Figuras 7 e 8, em geral, o *EMQ* das estimativas pelo método *FMoLC*, decresce com o incremento do tamanho da amostra. Os experimentos mostraram portanto, que quando a amostra é muito pequena, ou seja, pouco informativa, o método *FMoLC* apresentou maior *EMQ*. Entretanto, à medida que o tamanho da amostra aumentou o *EMQ* diminuiu consideravelmente. Vale ressaltar também que, por conta da aproximação apresentada no Capítulo 5 para a função trigamma (Equação 4.8), espera-se que o método *FMoLC* apresente resultados tão bons quanto o *MLC*, mas com número menor de operações.

Os resultados do *EMQ* para o método de log-cumulantes foram estáveis mesmo com o incremento do tamanho da amostra. A estabilidade do método *MLC* também foi igualmente observada por (KRYLOV *et al.*, 2013a; NICOLAS, 2002). Ainda assim os resultados do *EMQ*, para ambos os métodos, foram próximos. Assim como na distribuição G_I^0 , a estabilidade do *EMQ* também foi observada nas estimativas dos parâmetros da distribuição G_A^0 geradas pelo método *MLC*, como mostram as Figuras 9 e 10. De um modo geral, os experimentos com a distribuição G_A^0 mostraram que os resultados do *EMQ* para ambos os métodos foram muito próximos.

Figura 7 – Erro médio quadrático para as estimativas do parâmetro de rugosidade da distribuição G_I^0 para os cenários da Tabela 2. Da direita para a esquerda de cima para baixo referem-se aos cenários de 1 a 9, respectivamente. A linha contínua refere-se ao método *FMoLC* e a linha tracejada ao método *MLC*.



Outro aspecto considerado nesse trabalho, foi o custo computacional de cada método para estimar os parâmetros de rugosidade e escala (α , γ). Para cada distribuição, foi estimado os parâmetros de rugosidade e escala pelos métodos *FMoLC* e *MLC*. O custo computacional para estimar os parâmetros de cada distribuição foi semelhante. Desse modo, foi calculada a soma do

Figura 8 – Erro médio quadrático para as estimativas do parâmetro de escala da distribuição G_7^0 para os cenários da Tabela 2. Da direita para a esquerda de cima para baixo referem-se aos cenários de 1 a 9, respectivamente. A linha contínua refere-se ao método *FMoLC* e a linha tracejada ao método *MLC*.

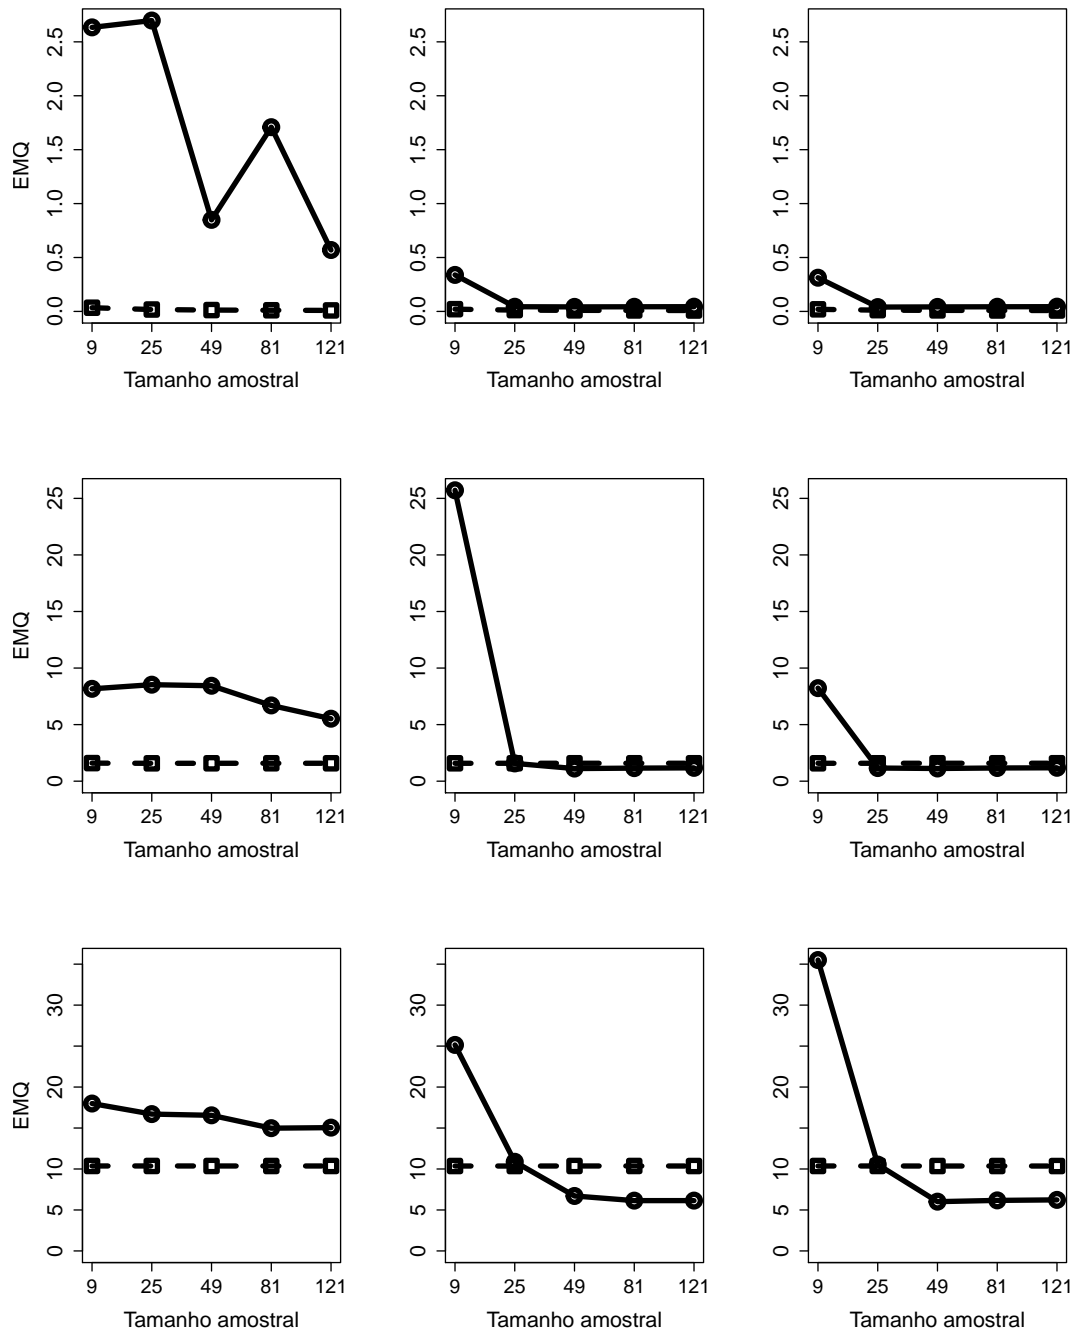


Figura 9 – Erro médio quadrático para as estimativas do parâmetro de rugosidade da distribuição G_A^0 para os cenários da Tabela 3. Da direita para a esquerda de cima para baixo referem-se aos cenários de 1 a 9, respectivamente. A linha contínua refere-se ao método *FMoLC* e a linha tracejada ao método *MLC*.

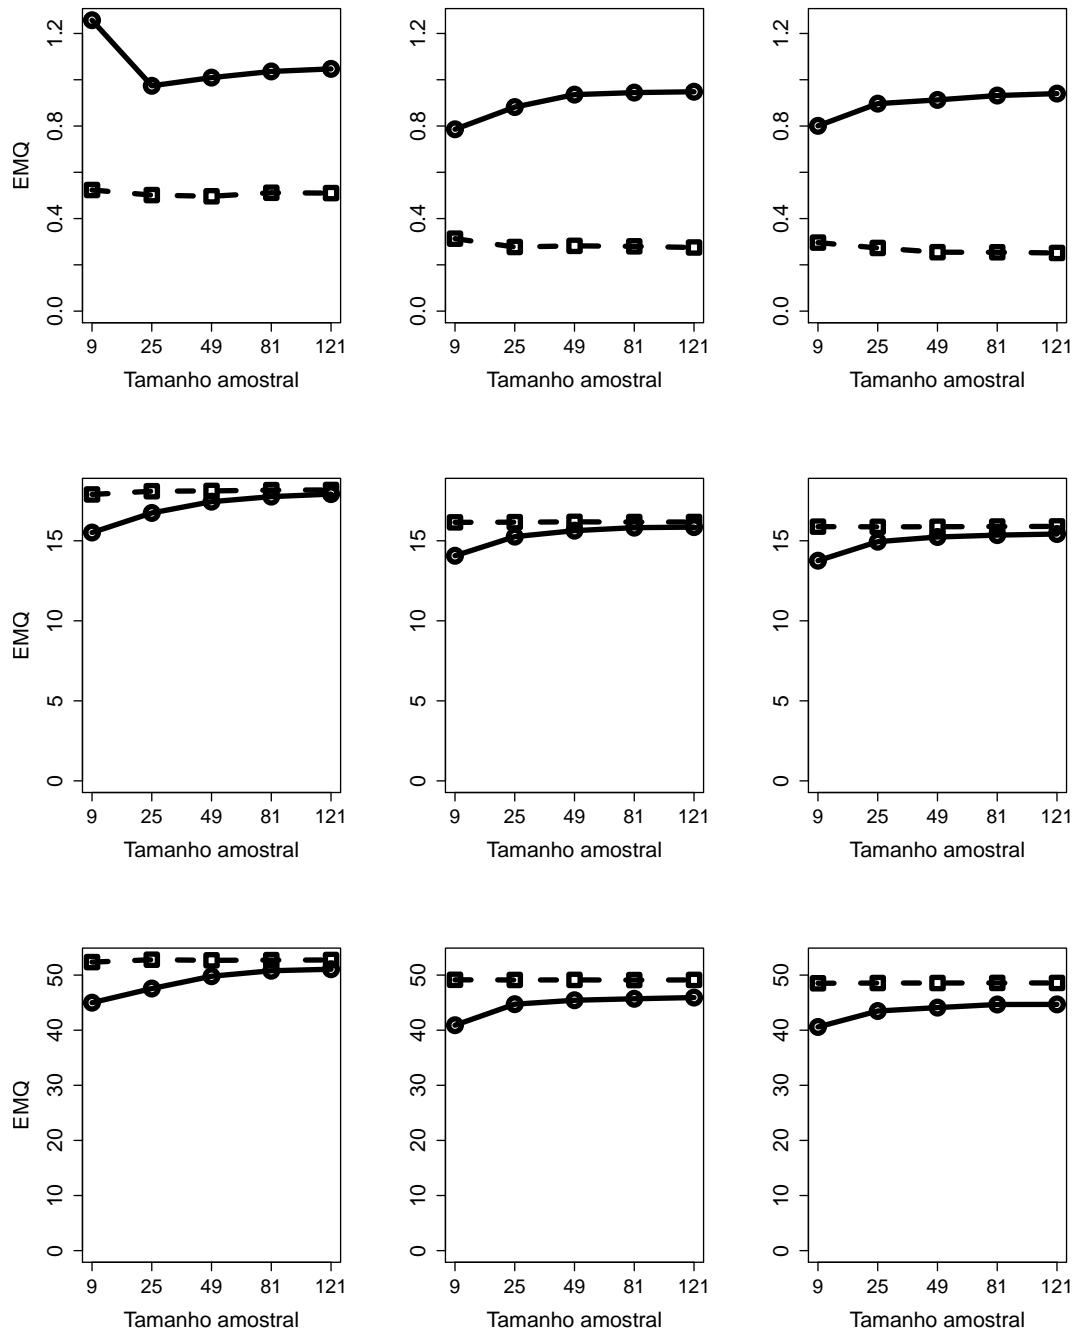


Figura 10 – Erro médio quadrático para as estimativas do parâmetro de escala da distribuição G_A^0 para os cenários da Tabela 3. Da direita para a esquerda de cima para baixo referem-se aos cenários de 1 a 9, respectivamente. A linha contínua refere-se ao método *FMoLC* e a linha tracejada ao método *MLC*.

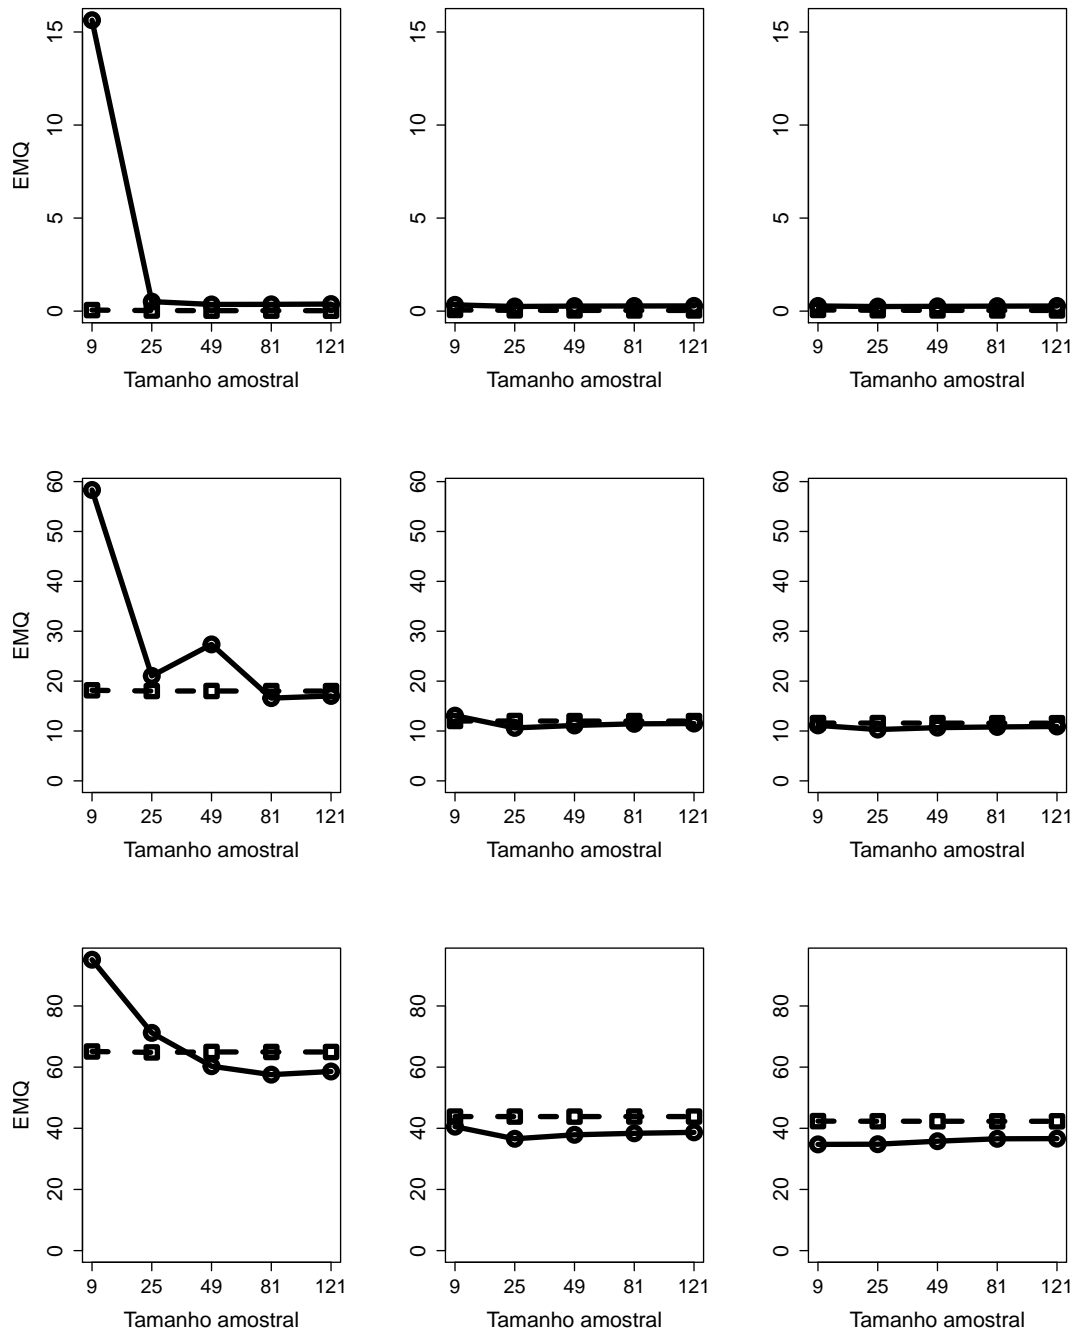


Tabela 4 – Tempo de execução total médio em segundos (s) de estimação para realização de todos os experimentos de cada distribuição.

FMoLC	MLC
6,05	94,34

custo computacional envolvido na estimativa dos parâmetros (α, γ) nos experimentos de Monte Carlo, separadamente para cada distribuição. Como era esperado, o custo computacional do método *FMoLC* foi bem menor do que o custo para o método *MLC*. A Tabela 4 apresenta o custo computacional total médio para a estimativa dos parâmetros das distribuições utilizadas. Por exemplo, em média o método *FMoLC* levou 6,05 segundos para estimar os parâmetros de rugosidade e escala da distribuição G_I^0 . Afirmção análoga pode ser feita para a distribuição G_A^0 .

Assim, os experimentos de Monte Carlo confirmaram que a proposta de abordagem rápida, para estimar os parâmetros de escala e rugosidade das distribuições G_I^0 e G_A^0 , é viável computacionalmente e gera estimativas próximas à sua versão clássica (obtida usando método numérico).

5 PROCESSAMENTO DE IMAGENS SAR USANDO O MÉTODO DE LOG-CUMULANTES

Este capítulo apresenta algumas aplicações em processamento de imagens SAR considerando os dois métodos de estimação de parâmetros: o método de log-cumulantes (*MLC*) e a proposta da versão rápida do método de log-cumulantes (*FMoLC*).

5.1 Segmentação de imagens SAR

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.

Em geral, métodos de segmentação baseados em limiarização utilizam a informação mais evidente de uma imagem que é a intensidade dos pixels. A limiarização é uma abordagem de segmentação bastante simples e útil pois se trata de uma forma de redução de dados, como é o caso da representação de imagem binária. Imagens do tipo binária são facilmente manipuladas para produzir descritores de cenas e objetos, tais como bordas, etc (KITTLER *et al.*, 1985).

No entanto, na presença de ruído, a distribuição de intensidade de pixels, em geral, não é bi-modal ou multimodal e, portanto, técnicas baseadas em limiarização não podem ser diretamente aplicadas a imagens em nível de cinza. De fato, essas técnicas são adequadas quando o nível de cinza dos pixels que pertencem a um objeto (primeiro plano ou *foreground*) é substancialmente diferente dos pixels de fundo (*background*) (SEZGIN; SANKUR, 2004). Isto pode ocorrer, por exemplo, em imagens de alto contraste. Portanto, esses são alguns dos desafios na aplicação de técnicas baseadas em limiarização para imagens ruidosas. Para abordar algumas destas questões, apresentamos uma metodologia para a segmentação automática de imagens SAR que engloba o modelo de dados e a estimação de parâmetros.

A escolha de uma distribuição de probabilidade apropriada para descrever dados SAR é fundamental na segmentação de imagem SAR (FRERY *et al.*, 1997). Nesse trabalho, adotamos as distribuições de probabilidade G_I^0 e G_A^0 propostas por Frery *et al.* (1997) para modelar dados SAR em intensidade e amplitude, respectivamente.

Estudos recentes mostraram que a informação de rugosidade, isto é, textura é um atributo importante e poderoso na detecção de bordas (DIAS *et al.*, 2015) e segmentação de imagens SAR (TIAN *et al.*, 2015). Nessa tese, empregamos os mapas de parâmetros de

rugosidade estimados a partir de dados modelados pelas distribuições G_I^0 e G_A^0 como entradas para realizar a segmentação de imagens SAR usando algoritmos baseados em limiarização e *level set*. Para a estimação de parâmetros, resolvemos um sistema não-linear baseado nos log-cumulantes de ordem 1 e 2, para ambas as distribuições acima mencionadas.

Inspirados por Mejail *et al.* (2003), consideramos a idéia de que a estimação de parâmetros para cada pixel pode levar a mapas de parâmetros estimados que, por sua vez, podem ser empregados como entradas para métodos de classificação, dentre outras aplicações. Investigamos a família de distribuições G^0 que consiste em modelos gerais para dados SAR em intensidade (G_I^0) e em amplitude (G_A^0). As funções densidades de probabilidade dessas distribuições, repetidas neste capítulo por conveniência, são definidas como:

- Distribuição G_I^0 :

$$f_{G_I^0}(z, \alpha, \gamma) = \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{L-1} (\gamma + Lz)^{\alpha-L}, \quad (5.1)$$

com r -ésimo momento dado por:

$$E_{G_I^0}[Z^r] = \left(\frac{\gamma}{L}\right)^r \frac{\Gamma(-\alpha - r) \Gamma(L + r)}{\Gamma(-\alpha) \Gamma(L)}, \alpha < -r. \quad (5.2)$$

- Distribuição G_A^0 :

$$f_{G_A^0}(z, \alpha, \gamma) = \frac{2L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{2L-1} (\gamma + Lz^2)^{\alpha-L}, \quad (5.3)$$


com r -ésimo momento dado por:

$$E_{G_A^0}[Z^r] = \left(\frac{\gamma}{L}\right)^{\frac{r}{2}} \frac{\Gamma(-\alpha - \frac{r}{2}) \Gamma(L + \frac{r}{2})}{\Gamma(-\alpha) \Gamma(L)}, \alpha < -\frac{r}{2}. \quad (5.4)$$

Para ambas as distribuições, $z > 0$, $L \geq 1$ corresponde ao número de *looks*, $\Gamma(L)$ é a função gama, $\alpha > 0$ e $\gamma > 0$ correspondem aos parâmetros de rugosidade e escala, respectivamente. O parâmetro α tem interpretação imediata em termos de rugosidade e, portanto, é considerado como uma medida de rugosidade ou textura (FRERY *et al.*, 1997; MEJAIL *et al.*, 2003). O número de *looks* L foi considerado conhecido e constante para todos os pixels da imagem.

Para estimar os parâmetros das distribuições G_I^0 e G_A^0 , utilizamos o método log-cumulantes (*MLC*) que é uma alternativa às abordagens clássicas dos métodos de máxima verossimilhança e método de momentos (KRYLOV *et al.*, 2013b). Embora o estimador de máxima verossimilhança tenha propriedades ótimas (como eficiência) sob algumas condições de regularidade, especialmente na família exponencial, não o empregamos devido a certas limitações discutidas em (NICOLAS, 2002; FENG; CAO, 2013). Essas limitações envolvem principalmente

Figura 11 – Imagens sintéticas com 1 *look*, mapas de rugosidades estimados pelo método de log-cumulantes, e histogramas dos mapas de rugosidades. (a) Imagem em intensidade simulada com 4 regiões utilizando $\alpha \in \{-1.5, -3, -4.5, -6\}$, (b) imagem em amplitude simulada com 2 regiões utilizando $\alpha \in \{-1.5, -3\}$.




expressões analíticas complexas para modelos de dados SAR, sendo necessários procedimentos numéricos intensivos para derivá-los. Vale ressaltar que o método dos momentos é mais simples e rápido na estimativa, no entanto tem sérias limitações (KRYLOV *et al.*, 2013b; LEHMANN, 1999; SEN *et al.*, 2010).

Por outro lado, o *MLC* gera estimadores fortemente consistentes, incluindo situações em que o método dos momentos falha, e envolve operações algébricas mais simples do que o método de máxima verossimilhança. Além disso, o *MLC* é computacionalmente mais rápido que o método de máxima verossimilhança e torna-se especialmente útil quando a abordagem de máxima verossimilhança revela-se inviável. Outro aspecto importante para a escolha do método log-cumulantes é que o histograma dos parâmetros de rugosidade estimados indica claramente o número de regiões presentes na imagem, como mostra a Figura 11. De fato, este padrão de histograma é desejável para aplicar métodos de segmentação de imagens baseados em limiares.

O fluxograma da Figura 12 exibe a metodologia proposta, em que a primeira etapa estima os parâmetros de rugosidade aplicando o método log-cumulantes. Na etapa seguinte, os parâmetros estimados são as entradas para algoritmos de segmentação, que também podem ser técnicas baseadas em limiarização. Com isso, disponibilizamos uma metodologia de segmentação de imagens SAR que processa a informação de rugosidade ou seu histograma ao invés de processar a imagem ruidosa original, propriamente dita.

Figura 12 – Fluxograma da metodologia de segmentação proposta.



Para investigar a viabilidade da abordagem proposta para a segmentação de imagens SAR, aplicamos os algoritmos introduzidos por Otsu (OTSU, 1979), *Huang et al.* (HUANG *et al.*, 2005) e *Marques et al.* (MARQUES *et al.*, 2012) diretamente nas imagens SAR e também nos mapas de rugosidades estimados pelo método de log-cumulantes. O método de *Otsu* procura por um valor de limiar automaticamente, enquanto o método de *Huang et al.* extrai um valor de limiar de forma supervisionada para orientar a evolução da função de velocidade do *level set*. O método de *Marques et al.* combina propriedades estatísticas de dados SAR e *level set* para derivar um esquema que divide as imagens SAR em diferentes regiões.

Nesse trabalho, propomos ainda versões modificadas dos algoritmos de segmentação de imagens SAR baseados em *level set*. O método introduzido por *Huang et al.* (2005) baseia-se em valores de limiar que são definidos manualmente, para orientar a evolução da função de velocidade, F , do *level set*. A evolução é realizada de acordo com (HUANG *et al.*, 2005):

$$F = \begin{cases} I(x,y) - I_{\text{lower}}, & I(x,y) < I_{\text{average}} \\ I_{\text{high}} - I(x,y), & I(x,y) \geq I_{\text{average}}, \end{cases} \quad (5.5)$$

em que $I(x,y)$ denota o valor do pixel na coordenada (x,y) , I_{lower} e I_{high} são parâmetros definidos pelo usuário e I_{average} é a média entre I_{lower} e I_{high} .

A nova versão substitui $I(x,y)$ pelo mapa de parâmetros de rugosidade, $M_{\alpha}(x,y)$, e adota um único limiar, $I_{\text{lower}} = I_{\text{high}} = T_{\alpha}$, na Equação (5.6) para evitar intervenções do usuário. Essas alterações resultaram na versão modificada do método de *Huang et al.*, dada por:

$$F^* = \begin{cases} M_{\alpha}(x,y) - T_{\alpha}, & M_{\alpha}(x,y) < T_{\alpha} \\ T_{\alpha} - M_{\alpha}(x,y), & M_{\alpha}(x,y) \geq T_{\alpha}, \end{cases} \quad (5.6)$$

em que T_{α} é estimado pelo método de Otsu (OTSU, 1979). Assim, F^* é uma versão não-supervisionada de F .

Para a obtenção do limiar T_{α} , aplicamos o método de *Otsu* diretamente na matriz M_{α} e, além disso, utilizamos T_{α} como entrada para o método *Huang et al.*, para orientar a evolução

da função de velocidade deste algoritmo. Com relação ao método introduzido por Marques *et al.* (2012), substituímos o termo do funcional de energia original pelo mapa de rugosidade. Assim, a versão modificada da função de velocidade em (MARQUES *et al.*, 2012) é dada por:

$$F^* = -\frac{(M_\alpha - \mu_1)}{\mathcal{A}_1} + \frac{(M_\alpha - \mu_2)}{\mathcal{A}_2}, \quad (5.7)$$

onde os índices 1 e 2 referem-se às regiões de *background* e *foreground* na evolução do *level set*, μ e \mathcal{A} são a rugosidade média e a área de ambas as regiões, respectivamente.

Inspirado no trabalho de Frery *et al.* (2004), adotamos um tamanho de janela 5x5 para estimar os parâmetros de rugosidade e escala das distribuições G_I^0 e G_A^0 . Frery *et al.* (2004) demonstraram que quanto maior o tamanho da janela, mais suavizada é a análise e, portanto, concluíram que a maioria dos pixels correspondia a pontos heterogêneos ou extremamente heterogêneos. Além disso, quando a janela era pequena, apareciam áreas mais heterogêneas. Em outras palavras, as imagens processadas com janelas muito grandes sofriam um efeito de borramento maior que em janelas pequenas. Esse borramento pode causar, portanto, distorções nas análises. Por exemplo, a detecção de bordas em imagens que apresentam várias regiões distintas utilizando janelas muito grandes pode ser comprometida. Por outro lado, imagens mais homogêneas como áreas de oceano a escolha do tamanho da janela de processamento é mais flexível.

Para avaliar a metodologia proposta na segmentação de dados SAR sintéticos em intensidade e amplitude, foi utilizada a medida de Erro de Segmentação (*EoS*) que é dada por:

$$EoS = \frac{\#(A)}{\#(Image)} \quad (5.8)$$


em que $\#(A)$ e $\#(Image)$ representam o número de pixels segmentados erroneamente e o número de pixels total da imagem, respectivamente.

Dois índices foram utilizados para quantificar a precisão e a dificuldade da segmentação com imagens reais. O primeiro deles é o índice *CRF* (*Cross-Region Fitting*) introduzido em (MARQUES *et al.*, 2012). Esse índice é definido no intervalo $[0, 1]$, com $CRF = 1$ indicando um melhor resultado de segmentação. O segundo índice diz respeito à dificuldade de segmentação, *DoS*, também proposto em (MARQUES *et al.*, 2012). O objetivo desse índice é quantificar a dificuldade de segmentar imagens SAR com base no contraste entre regiões. Ambos os índices *CRF* e *DoS* dependem da distância estocástica utilizada entre duas amostras de regiões que são modeladas pelas distribuições G_I^0 ou G_A^0 . A distância estocástica utilizada nessa tese foi a aritmética-geométrica descrita em (NASCIMENTO *et al.*, 2010a).

5.1.1 Segmentação de imagens sintéticas

Os experimentos de segmentação com imagens SAR sintéticas foram conduzidos com dados em intensidade e amplitude com duas regiões de diferentes padrões, parâmetros de rugosidade e número de *looks*. Realizamos experimentos de Monte Carlo com 10.000 imagens em intensidade e amplitude, respectivamente. Para gerar imagens em amplitude, Z_A , utilizamos o método da transformação inversa (MARQUES *et al.*, 2012). Para gerar imagens em intensidade, Z_I , consideramos a relação entre dados de amplitude e intensidade $Z_A^2 = Z_I$. A Figura 13 exhibe exemplos de imagens SAR sintéticas e suas respectivas versões segmentadas pela metodologia adotada.

Figura 13 – Exemplos de imagens sintéticas e suas respectivas versões segmentadas.

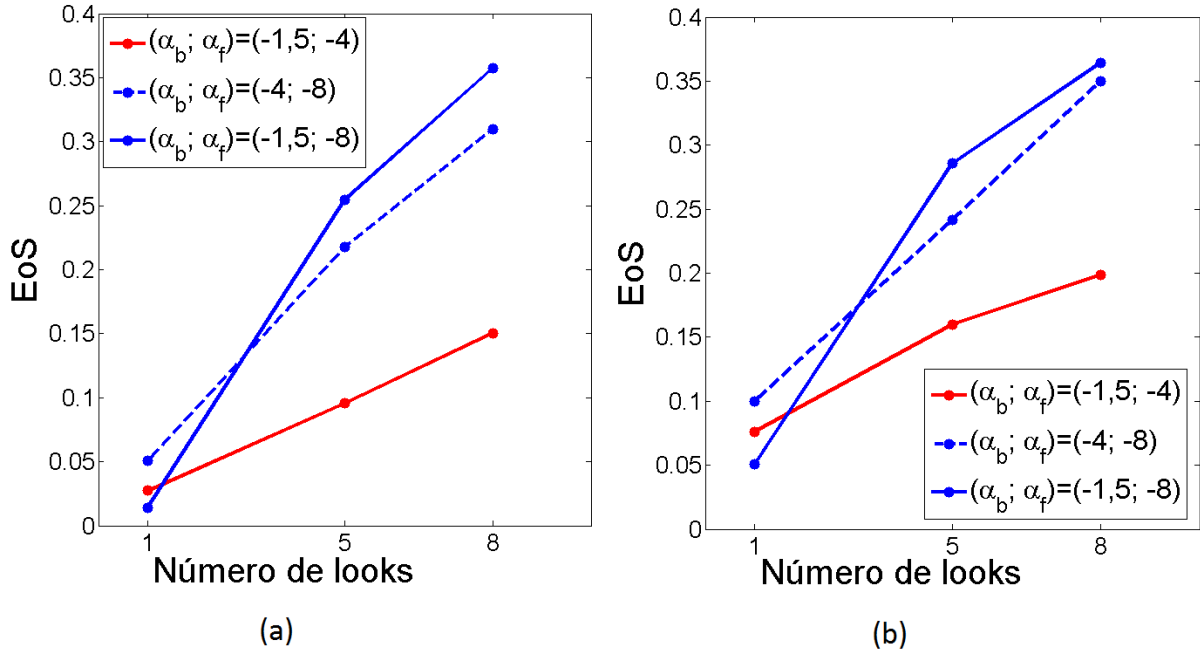


Com o intuito de investigar a adequação da metodologia proposta na segmentação de imagens SAR sintéticas, aplicamos algoritmos baseados em limiarização. A Tabela 5 exhibe valores de média e desvio padrão do erro de segmentação (EoS) obtidos para os experimentos de Monte Carlo aplicando o método de Otsu. Realizamos os experimentos com parâmetros distintos de rugosidade para *background* (α_b) e *foreground* (α_f). Quanto aos parâmetros de escala, estes foram ajustados, para o *background* e *foreground*, de modo que o momento de ordem 1 fosse igual a 1, ou seja, $E_{G_I^0}[Z_I] = 1$ e $E_{G_A^0}[Z_A] = 1$. Com isso, asseguramos nos experimentos de segmentação a presença de imagens sintéticas de baixo contraste, ou seja, com maior dificuldade de segmentação. A Tabela 5 apresenta os resultados em imagens SAR sintéticas com $L = 1$.

Tabela 5 – Média e desvio padrão de EoS para o método de Otsu.

Rugosidades ($\alpha_b; \alpha_f$)	Otsu aplicado em	Imagem em intensidade	Imagem em amplitude
(-1, 5; -4)	M_α SAR	$0,0273 \pm 0,0011$ $0,7460 \pm 0,0018$	$0,0296 \pm 0,0105$ $0,6909 \pm 0,0019$
(-4; -8)	M_α SAR	$0,0175 \pm 0,0045$ $0,7567 \pm 0,0017$	$0,0520 \pm 0,0089$ $0,7225 \pm 0,0021$
(-1, 5; -8)	M_α SAR	$0,0140 \pm 0,0009$ $0,2960 \pm 0,0029$	$0,0146 \pm 0,0026$ $0,4734 \pm 0,0035$

Figura 14 – EoS médio para as imagens sintéticas em intensidade com número de *looks* iguais 1, 5 e 10. Resultados do (a) método de Otsu modificado, e (b) método do Huang et al. modificado. Linhas contínuas referem-se a $(\alpha_b; \alpha_f) = (-1, 5; -8)$, linhas tracejadas a $(\alpha_b; \alpha_f) = (-1, 5; -4)$ e linhas pontilhadas a $(\alpha_b; \alpha_f) = (-4; -8)$.




Na Tabela 5, as linhas com valores realçados exibem os erros de segmentação (EoS) obtidos aplicando o método Otsu aos mapas de rugosidades obtidos pelo método de log-cumulantes utilizando a função *fsolve* do Matlab. Os valores que não estão destacados na Tabela 5, se referem aos resultados obtidos ao aplicar o método de Otsu diretamente nas imagens SAR. Estes resultados confirmaram que não é viável aplicar técnicas baseadas em limiares diretamente a imagens com ruído *speckle*. No entanto, quando a entrada do algoritmo foi o mapa de rugosidades, os resultados foram superiores. Da mesma forma, observamos desempenho semelhante com o método de Huang *et al.* (2005).

A Figura 14 mostra os valores médios de EoS para os métodos de Otsu e Huang modificados das imagens SAR sintéticas com diferentes parâmetros de rugosidade e número de *looks*. Estes resultados mostraram que os métodos modificados apresentaram menores valores de EoS para imagens SAR com $L = 1$ (imagens *single look*), que são fortemente afetadas pelo *speckle*. Além disso, o desempenho da abordagem proposta foi substancialmente comprometido com o aumento do número de *looks*. Na verdade, o aumento do número de *looks* implica em redução da variância do *speckle* assim como da informação de rugosidade. As Figuras 14a e 14b também ilustram o quão difícil é segmentar imagens SAR sintéticas de múltiplos *looks* aplicando algoritmos baseados em limiarização da informação de rugosidade.

Observamos ainda com a redução da informação de rugosidade com o aumento do número de *looks*, problemas de convergência na função *fsolve* do Matlab que foi utilizada. Foram detectadas convergências para valores bem distantes do valor ótimo. Esse problema descaracteriza os histogramas da matriz de rugosidade. Entretanto, ao utilizarmos a versão rápida do método de log-cumulantes (*FMoLC*), o problema da não convergência desaparece. Para ilustrar este achado, realizamos um experimento com imagens SAR sintéticas com duas regiões, como mostram as Figuras 15 e 16. Os parâmetros de rugosidades para *background* e *foreground* para ambos os casos foram considerados iguais, mas com parâmetros de escala e número de *looks* distintos.


Figura 15 – (a) Imagem SAR sintética em amplitude gerada com os parâmetros $L = 1$, $\alpha_b = \alpha_f = -1.5$, $\alpha_b = 1$ e $\alpha_f = 10$. (b) Histograma da matriz de rugosidades extraída por MLC e (c) histograma da matriz de rugosidades extraída por FMoLC.



Esses experimentos revelaram que a versão rápida do método de log-cumulantes, além de não apresentar problemas de convergência, é menos sensível ao aumento do número de *looks*. Essa observação se confirma com o aumento do número de *looks*, o histograma da matriz de rugosidade extraída por *FMoLC* ainda é capaz de discriminar duas regiões (histograma bimodal) predominantes na imagem. Outro aspecto observado com esses experimentos, é que apesar da restrição imposta de rugosidades iguais e escalas distintas, a versão rápida ainda permite a identificação das duas regiões presentes na imagem. Vale ressaltar que a estimação do parâmetro de rugosidade é também afetada pela informação de escala contida nos valores de intensidades dos pixels.


A Figura 17 apresenta duas imagens sintéticas em amplitude de uma mancha de óleo no mar com diferentes números de *looks* ($L = 1$ e $L = 8$). Para cada uma dessas imagens,

Figura 16 – (a) Imagem SAR sintética em amplitude gerada com os parâmetros $L = 8$, $\alpha_b = \alpha_f = -1.5$, $\alpha_b = 1$ e $\alpha_f = 10$. (b) Histograma da matriz de rugosidades extraída por MLC e (c) histograma da matriz de rugosidade extraída por FMoLC.



foi gerada a matriz de rugosidades utilizando o método *FMoLC* com janela 5×5 , e obtidos os histogramas 3D como mostra a Figura 18. A partir desses histogramas verifica-se que as rugosidades da mancha foram evidenciadas, indicando o bom desempenho do método *FMoLC* em discriminar regiões, apesar do número de *looks* diferentes.

Figura 17 – Imagem SAR sintética em amplitude com parâmetros (a) 1 *look*, $(\alpha_b, \gamma_b) = (-15, 1)$, $(\alpha_f, \gamma_f) = (-8, 3)$ e (b) 8 *looks*, $(\alpha_b, \gamma_b) = (-15, 1)$, $(\alpha_f, \gamma_f) = (-8, 3)$.



5.1.2 Segmentação de imagens SAR reais

Os testes com imagens SAR reais incluíram uma imagem em intensidade com 3 *looks* e sua versão em amplitude, e uma outra imagem em amplitude com 4 *looks* com sua versão em intensidade, todas adquiridas com polarização HH. A imagem SAR real em intensidade na

Figura 18 – Exibição das matrizes de rugosidades correspondentes às imagens sintéticas da Figura 17 (a) 1 look e (b) 8 looks.

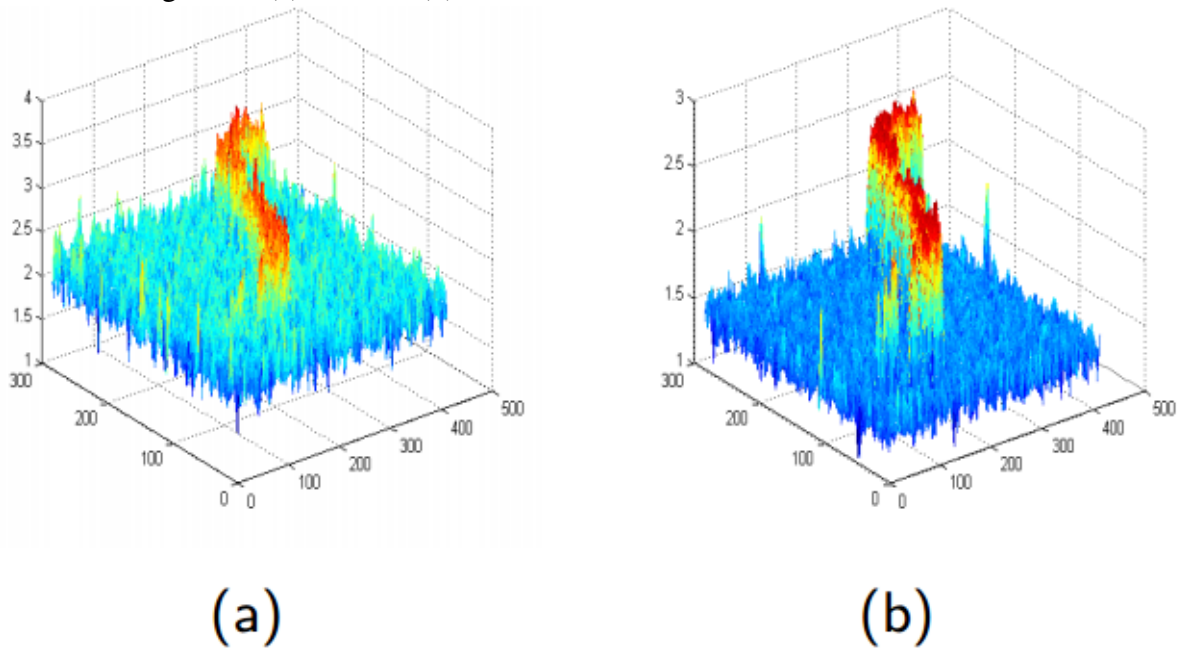


Figura 19(a) mostra parte da baía de São Francisco e foi adquirida pelo sensor AIRSAR. A Figura 20(a) mostra a imagem real em amplitude da costa do Nordeste brasileiro obtida pelo sensor RADARSAT, evidenciando uma mancha de óleo no Oceano Atlântico.

As Tabelas 6 e 7 apresentam os valores dos índices de avaliação (*CRF* e *DoS*) para as imagens reais da baía de São Francisco e da mancha de óleo, respectivamente. Como era esperado, os valores de *DoS* sugerem que a dificuldade de segmentação de imagens reais SAR em intensidade é maior do que nas imagens em amplitude. De fato, a medida *DoS* se baseia no contraste entre regiões e as imagens SAR em intensidade apresentam menor contraste entre as mesmas do que as imagens em amplitude. Em relação aos valores da medida *CRF*, estes foram calculados a partir dos resultados obtidos com os métodos introduzidos por Otsu (1979), Huang *et al.* (2005) e Marques *et al.* (2012) e suas respectivas versões modificadas.

Tabela 6 – Medidas de *DOS* e *CRF* da imagem SAR real da baía de São Francisco segmentada pelos métodos Met1:(OTSU, 1979), Met2: (HUANG *et al.*, 2005) e Met3: (MARQUES *et al.*, 2012).

Imagem processada em	<i>DoS</i>	Abordagens de segmentação	Métodos		
			Met1	Met2	Met3
Intensidade	2,9449	Original	0,2943	0,6058	0,6634
		Modificado	0,6698	0,6431	0,6623
Amplitude	1,1714	Original	0,3670	0,6813	0,7452
		Modificado	0,7515	0,7128	0,7407

Figura 19 – Segmentação de imagem SAR real. (a) Imagem SAR real em intensidade da baía de São Francisco e (b) imagem segmentada aplicando o método de *Otsu* modificado.





Tabela 7 – *DOS* e *CRF* da imagem real da mancha de óleo segmentada pelos métodos Met1:(OTSU, 1979), Met2: (HUANG *et al.*, 2005) e Met3: (MARQUES *et al.*, 2012).

Imagem processada em	<i>DoS</i>	Abordagens de segmentação	Métodos		
			Met1	Met2	Met3
Intensidade	2,4090	Original	0,2722	0,7472	0,8619
		Modificado	0,8647	0,7702	0,8738
Amplitude	1,3911	Original	0,3503	0,7227	0,8914
		Modificado	0,8638	0,7492	0,8813

Figura 20 – Segmentação de imagem SAR real. (a) Imagem SAR real em amplitude de uma mancha de óleo (b) imagem segmentada pelo método de *Marques et al.* (MARQUES *et al.*, 2012).




A partir dos valores de *CRF* mostrados nas Tabelas 6 e 7, concluímos que a abordagem proposta é viável para segmentação de imagens SAR, quando aplicada ao mapa de rugosidade estimado pelo método de log-cumulantes. Além disso, observamos que os resultados de processamento relacionados com os métodos introduzidos em (HUANG *et al.*, 2005) e (MARQUES *et al.*, 2012) foram bastante semelhantes independente de usar o método original ou a sua versão modificada. Esse fato mostra portanto, que a informação do mapa de rugosidade

carrega tanta informação quanto o funcional de energia empregado originalmente no método de Marques *et al.* (2012). Outro aspecto a destacar é que o uso do mapa de rugosidade permite com que a função de velocidade utilizada no método de Huang *et al.* (2005) seja não-supervisionada.

A Figura 21 apresenta os mapas de rugosidades obtidos a partir das imagens nas Figuras 19(a) e 20(a) pelo método de log-cumulantes (*MLC*). Podemos observar que os mapas de rugosidade são mais informativos que as imagens SAR originais. Observa-se que é possível discriminar melhor as regiões predominantes na imagem através dos mapas do que pelas respectivas imagens SAR, sugerindo assim o potencial de processamento do mapa de rugosidade obtido pelo método de log-cumulantes.

Figura 21 – Mapas de rugosidades, obtidos com *FMoLC*, referentes às imagens SAR reais da mancha de óleo e Baía de São Francisco.



Em relação ao custo computacional dos algoritmos, não observamos diferenças significativas no processamento de uma imagem SAR ou de seu mapa de rugosidade. No entanto, a estimativa do mapa de rugosidade pelo método de log-cumulantes (usando a função *fsolve* do Matlab) foi computacionalmente lenta. O tempo computacional para estimar M_α para as imagens de São Francisco e da mancha de óleo foi cerca de 20 e 10 minutos, respectivamente. Embora a estimativa do mapa de rugosidade seja computacionalmente lenta, enfatizamos a atratividade e a utilidade de M_α como entrada para problemas desafiadores como segmentação de imagens SAR, classificação e outras aplicações. Para solucionar o problema de custo computacional, indicamos o uso da versão rápida do método de log-cumulantes (*FMoLC*).

5.2 Detecção de mudanças em imagens SAR

Para investigar o desempenho dos métodos *FMoLC* e *MLC* no processamento de imagens SAR reais, foram utilizadas as estimativas de ambos os métodos como entradas para identificação de mudanças ou alterações em imagens SAR multi-temporais. Inspirado na idéia de Mejail *et al.* (2003), calculamos os parâmetros para cada pixel das imagens multi-temporais

utilizando uma janela de tamanho 5x5 pixels.

Assim, para detectar alterações nas imagens multi-temporais SAR, calculamos a distância estocástica entre pixels correspondentes das imagens multi-temporais. A distância estocástica adotada foi a aritmética-geométrica (NASCIMENTO *et al.*, 2010b) apresentada na Equação (3.17).

A Figura 22 apresenta um recorte de uma cena de sequência temporal de imagem SAR evidenciando um alvo (navio) em dois momentos distintos. Foram calculadas as matrizes de distâncias estocásticas para ambos os métodos *FMoLC* e *MLC* obtendo resultados semelhantes. A Figura 23 apresenta a matriz obtida pelo método *FMoLC*.

Figura 22 – Imagem SAR multi-temporal. Canal HH, $L = 1$.





Figura 23 – Matriz de distância estocástica entre as imagens das Figuras 22(a) e 22(b), obtida pelo método *FMoLC*.



A Tabela 8 exibe o tempo de processamento para estimar os parâmetros de rugosidade e escala para ambos os métodos. Como esperado, o tempo alcançado pelo método *FMoLC* foi bem menor que pelo método *MLC*. A Tabela 9 apresenta algumas medidas descritivas (mínimo, máximo, média e desvio padrão) extraídas das matrizes de distância que auxiliam na comparação entre os dois métodos. Ambos os métodos apresentaram resultados equivalentes com relação à distância estocástica.

Outro experimento realizado com ambos os métodos, em imagem real, foi a detecção

Tabela 8 – Tempo de processamento (segundos) gasto na estimativa dos parâmetros de rugosidade e escala pixel a pixel das imagens exibidas nas Figuras 22(a) e 22(b).

Método de estimação	Figura 22(a)	Figura 22(b)
FMoLC	0,83	0,81
MLC	258,37	246,51

Tabela 9 – Medidas descritivas das distâncias estocásticas obtidas por ambos os métodos *FMoLC* e *MLC*.

	Min	Max	Média	Desvio padrão
FMoLC	$1,13 \times 10^{-16}$	0,0031	$4,12 \times 10^{-5}$	$8,19 \times 10^{-5}$
MLC	$1,17 \times 10^{-16}$	0,0031	$4,19 \times 10^{-5}$	$8,42 \times 10^{-5}$

de manchas no mar. A imagem considerada nesse teste está exibida na Figura 24. Foram recortadas subcenas (100x100) da imagem em regiões de mar aberto (recortes amarelos), de manchas escuras (recortes vermelhos) e de fronteira (recortes verdes). As Figuras 25 e 26 apresentam os recortes de oceano e mancha, respectivamente.

Figura 24 – Imagem Alos-PalSAR da baía de Campos - RJ, banda P, canal HH, 1 look. Recortes de oceano (OC), mancha escura (ME) e fronteiras das regiões (B).






Figura 25 – Recortes do oceano: (a) OC1 (b) OC2 (c) OC3 (d) OC4 (e) OC5.



Para cada grupo de recortes foi calculada a distância estocástica aritmética-geométrica entre os recortes e montada uma matriz estocástica. Para os recortes de oceano os resultados estão

Figura 26 – Recortes da mancha escura: (a) ME1 (b) ME2 (c) ME3 (d) ME4 (e) ME5.



apresentados na Tabela 10 e a Tabela 11 apresenta os resultados para os recortes de manchas.

Tabela 10 – Distâncias estocásticas entre recortes de oceano.

	OC1	OC2	OC3	OC4	OC5
OC1	0				
OC2	0,0004	0			
OC3	0,0019	0,0005	0		
OC4	0,0023	0,0007	$1,89 \times 10^{-5}$	0	
OC5	$4,74 \times 10^{-5}$	0,0001	0,0013	0,0016	0

Tabela 11 – Distâncias estocásticas entre recortes da mancha.

	ME1	ME2	ME3	ME4	ME5
ME1	0				
ME2	$4,23 \times 10^{-5}$	0			
ME3	0,0001	$1,96 \times 10^{-5}$	0		
ME4	$8,06 \times 10^{-5}$	$6,14 \times 10^{-6}$	$3,82 \times 10^{-6}$	0	
ME5	0,0002	$8,15 \times 10^{-5}$	$2,11 \times 10^{-5}$	$4,29 \times 10^{-5}$	0


Os resultados apresentados nas Tabelas 10 e 11 revelaram que, em geral, as distâncias estocásticas para os recortes de oceano apresentaram magnitudes diferentes das distâncias estocásticas para os recortes de manchas. Quando confrontados os recortes de mar e mancha, observa-se que as distâncias estocásticas aumentaram consideravelmente, vide Tabela 12. Logo esses resultados sugerem a possibilidade da construção de descritores de regiões (ex. manchas) baseados em distância estocástica ou em relação aos parâmetros de textura e rugosidade. Esses descritores poderiam ser utilizados, por exemplo, em aplicações de recuperação baseada em conteúdo (*CBIR*).

A Figura 27 exhibe matrizes de distância estocástica pixel a pixel entre recortes de mar, de mancha, e entre recortes de mar e mancha. Uma vez que a distância estocástica varia de 0 a infinito, torna-se claro que as distâncias entre recortes similares são próximas de zero e portanto a visualização da matriz em tons de cinza ficará mais escura. Quando os recortes são distintos, observa-se uma tonalidade mais clara na visualização desta matriz.

Tabela 12 – Distâncias estocásticas entre recortes de oceano e mancha escura.


	ME1	ME2	ME3	ME4	ME5
OC1	0,0381	0,0356	0,0341	0,0348	0,0324
OC2	0,0306	0,0284	0,0269	0,0276	0,0255
OC3	0,0228	0,0209	0,0197	0,0203	0,0185
OC4	0,0215	0,0197	0,0185	0,0191	0,0173
OC5	0,0354	0,0331	0,0315	0,0322	0,0299

Figura 27 – Matrizes de distâncias estocásticas: (a) OC1 x OC2 (b) ME4 x ME5 (c) OC1 x ME4.



Esse mesmo comportamento é observado na matriz de distâncias estocásticas entre recorte de oceano e recorte de fronteira. A Figura 28(a) exibe de forma mais evidente a fronteira existente na cena. Outro aspecto importante a destacar é a possibilidade da utilização do histograma da matriz de distâncias estocásticas no auxílio à detecção de mudanças numa cena imageada. Como mostra o histograma na Figura 28(b), a presença do vale no histograma indica que houve mudança na cena.

Figura 28 – Matriz de distância estocástica entre os recortes de oceano OC1 e de fronteira B2 extraídos da Figura 24. (a) Visualização desta matriz em níveis de cinza e (b) histograma correspondente dessa matriz.



6 CONCLUSÕES E TRABALHOS FUTUROS

Nesse trabalho, 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. Com relação aos métodos de segmentação baseados em limiarização, os resultados dos mesmos são insatisfatórios quando aplicados diretamente às imagens ruidosas, pois os mesmos, em geral, são sensíveis à presença de ruído.

Por outro lado, a metodologia proposta tem por base a modelagem estatística apropriada para dados SAR, a qual permite a estimação da informação de rugosidade para cada pixel. As distribuições adotadas para modelagem dos dados SAR em intensidade e amplitude foram G_I^0 e G_A^0 , respectivamente. Para a estimação dos parâmetros adotamos o método de log-cumulantes. Os testes realizados incluíram algoritmos de segmentação baseados em limiarização e *level set* aplicados a imagens SAR sintéticas e reais.

Embora a segmentação de imagens SAR seja uma tarefa difícil de realizar através de técnicas baseadas em limiarização devido ao *speckle*, nossa proposta mostrou-se adequada ao aplicar as mesmas técnicas aos parâmetros de rugosidade estimados pelo método de log-cumulantes. 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. 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*.

A abordagem de segmentação alcançou resultados satisfatórios ao aplicar técnicas de limiarização e de *level set* nos mapas do parâmetros de rugosidade. Um aspecto importante considerado nesse trabalho, foi o fato de que o método de log-cumulantes requer procedimentos numéricos para estimar os parâmetros das distribuições G_I^0 e G_A^0 . Portanto, em geral, é lento e dependendo do procedimento numérico utilizado, pode apresentar problemas de convergência.

Para solucionar esses problemas, propusemos uma abordagem rápida para o método de log-cumulantes para estimar os parâmetros de rugosidade e escala das distribuições G_I^0 e G_A^0 . A abordagem rápida proposta mostrou-se competitiva com a versão original do método de log-cumulantes, pois é computacionalmente mais rápida, não apresenta problemas de não convergência e sua acurácia, medida pelo erro médio quadrático (exatidão), foi bem próxima do método de log-cumulantes. Vale ressaltar que as diferenças nas estimativas dos métodos não ocasionaram diferenças significativas nas aplicações em detecção de mudanças e de manchas de

óleo no mar em imagens SAR.

Com relação às aplicações em detecção de mudanças em sequências temporais de imagens SAR e detecção de manchas de óleo no mar, os testes mostraram a adequação da metodologia proposta, quando combinada à distância estocástica aritmética-geométrica.

6.1 Trabalhos futuros

A partir da pesquisa desenvolvida nessa tese, outras linhas de estudo foram identificadas para trabalhos futuros:

- Derivação de um descritor de textura de regiões em imagens SAR a partir do parâmetro de rugosidade.
- Utilização dos parâmetros de rugosidade e escala como atributos em sistemas de recuperação de imagens SAR baseada em conteúdo.
- Proposição de uma metodologia para obtenção de limiares a partir do histograma das estimativas de rugosidades.

REFERÊNCIAS

- ABRAMOWITZ, M.; STEGUN, I. A. **Handbook of Mathematical Functions**. [S.l.]: Elsevier Academic Press, 1972.
- ANFINSEN, S. N. **Statistical Analysis of Multilook Polarimetric Radar Images with the Mellin Transform**. Tese (Doutorado) — Universidade de Thomso, Noruega, 5 2010.
- ARFKEN, G. B.; WEBER, H. J. **Mathematical Methods for Physicists**. [S.l.]: Dover Publications, 2005.
- ARSENAULT, H.; APRIL, G. Properties of speckle integrated with a finite aperture and logarithmically transformed. **Journal of the Optical Society of America**, v. 66, p. 1160–1163, 1976.
- BUJOR, F.; TROUVÉ, E.; VALET, L.; NICOLAS, J.-M.; RUDAN, J.-P. Application of log-cumulants to the detection of spatiotemporal discontinuities in multitemporal SAR images. **IEEE Trans. Geosci. Remote Sens.**, v. 42, n. 10, p. 2073–2084, Oct. 2004.
- CHENG, J.; GAO, G.; DING, W.; KU, X.; SUN, J. An improved scheme for parameter estimation of G^0 distribution model in high-resolution SAR images. **Progress in Electromagnetics Research**, v. 134, p. 23–46, 2013.
- CUI, S.; DATCU, M. Coarse to fine patches-based multitemporal analysis of very high resolutions satellite images. In: **6th Int. Workshop on the Anal. Multi-temp. Remote Sens. Images**. [S.l.: s.n.], 2011. p. 85–88.
- CUI, S.; SCHWARZ, G.; DATCU, M. A comparative study of statistical models for multilook SAR images. **IEEE Geosci. Remote Sens. Letters**, v. 11, n. 10, p. 1752–1756, Oct 2014.
- DIAS, L.; CRIBARI-NETO, F.; OSPINA, R. Interval edge estimation in SAR images. **IEEE Trans. Geosci. Remote Sens.**, v. 53, n. 2, p. 851–861, 2015.
- FENG, J.; CAO, Z. Multiphase SAR image segmentation with G^0 statistical-model-based active contours. **IEEE Trans. Geosci. Remote Sens.**, v. 51, n. 7, p. 4190–4199, Jul 2013.
- FRERY, A. C.; MÜLLER, H.-J.; FREITAS, C. C.; SANT’ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Trans. Geosci. Remote Sens.**, v. 35, n. 3, p. 648–659, 1997.
- FRERY, A. C.; NETO, F. C.; SOUZA, M. O. de. Analysis of minute features in speckled imagery with maximum likelihood estimation. **EURASIP Journal on Applied Signal Process.**, v. 16, n. 1, p. 2476–2491, 2004.
- GAMBINI, J.; CASSETTI, J.; LUCINI, M. M.; FRERY, A. C. Parameter estimation in SAR imagery using stochastic distances and asymmetric kernels. **IEEE Journal of selected topics in applied earth observations and remote sensing**, v. 8, n. 1, p. 365–375, Jan 2015.
- GAO, G.; QIN, X.; ZHOU, S. Modeling SAR images based on a generalized gamma distribution for texture component. **Progress in Electromagnetics Research**, v. 137, p. 669–685, 2013.
- HORTA, M. M. **Modelos de mistura de distribuições na segmentação de imagens SAR polarimétricas multi-look**. Tese (Doutorado) — Instituto de Física de São Carlos, São Carlos, São Carlos, 6 2009.

- HUANG, B.; LI, H.; HUANG, X. A level set method for oil slick segmentation in SAR images. **International Journal of Remote Sensing**, v. 26, n. 6, p. 1145–1156, Mar 2005.
- JAO, J. K. Amplitude distribution of composite terrain radar clutter and the k distribution. **IEEE Trans. Antennas Propagat.**, v. 35, n. 3, p. 1049–1061, May 1984.
- KHURI, A. I. **Advanced Calculus with Applications in Statistics**. [S.l.]: Wiley Series in Probability and Statistics, 2003.
- KITTLER, J.; ILLINGWORTH, J.; FÖGLEIN, J. Threshold selection based on a simple image statistic. **Comput. Vision, Graphics, and Image Process.**, v. 30, n. 1, p. 125–147, 1985.
- KRYLOV, V.; MOSER, G.; SERPICO, S. B.; ZERUBIA, J. On the method of logarithmic cumulants for parametric probability density function estimation. **IEEE Trans. on Image Processing**, v. 22, n. 10, p. 3791–3806, Oct 2013.
- KRYLOV, V.; MOSER, G.; SERPICO, S. B.; ZERUBIA, J. On the method of logarithmic cumulants for parametric probability density function estimation. **IEEE Trans. on Image Process.**, v. 22, n. 10, p. 3791–3806, Oct 2013.
- LEE, J. S.; JURKEVICH, I. Speckle filtering os synthetic aperture radr images: A review. **Remote Sensing Reviewa**, v. 8, p. 313–340, 1994.
- LEE, J.-S.; POTTIER, E. **Polarimetric radar imaging: from basics to applications**. [S.l.]: CRC Press, 2009.
- LEHMANN, E. L. **Elements of large-sample theory**. [S.l.]: Springer Science & Business Media, 1999.
- LONG, S.; FATOYINBO, T. E.; POLICELLI, F. Flood extent mapping for namibia using change detection and thresholding with SAR. **Environmental Research Lett.**, v. 9, p. 1–9, Mar. 2014.
- MARQUES, R. C. P. **Caracterização de regiões em imagens da radar de abertura sintética com aplicações por segmentação por Level Set**. Tese (Doutorado) — Departamento de Teleinformática, Universidade Federal do Ceará, Fortaleza, 7 2011.
- MARQUES, R. C. P.; MEDEIROS, F. N.; NOBRE, J. S. SAR image segmentation based on level set approach and G_A^0 model. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v. 34, n. 10, p. 2046–2057, Oct 2012.
- MEJAIL, M. E.; JACOBO-BERLLES, J. C.; FRERY, A. C. Classification of SAR images using a general and tractable multiplicative model. **International Journal of Remote Sensing**, v. 24, n. 18, p. 3565–3582, 2003.
- MOREIRA, A.; PRATS-IRAOLA, P.; YOUNIS, M.; KRIEGER, G.; HAJNSEK, I.; PAPATHANASSIOU, K. P. A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, p. 6–43, Mar. 2013.
- NASCIMENTO, A. D. C.; CINTRA, R. J.; FRERY, A. C. Hypothesis testing in speckle data with stochastic distances. **IEEE Trans. Geosci. Remote Sens.**, v. 48, n. 1, p. 373–385, 2010.
- NASCIMENTO, A. D. C.; CINTRA, R. J.; FRERY, A. C. Hypothesis testing in speckle data with stochastic distances. **IEEE Trans. Geosci. Remote Sens.**, v. 48, n. 1, p. 373–385, 2010.

- NICOLAS, J.-M. Introduction aux statistiques de deuxième espèce: Application des logs-moments et des logs-cumulants à l'analyse des lois d'images radar. **Traitement du Signal**, v. 19, n. 3, p. 139–167, 2002. In French.
- OLIVER, C.; QUEGAN, S. **Understanding Synthetic Aperture Radar Images**. [S.l.]: Artech House, 1998.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Trans. Systems Cybernetics**, v. 9, n. 1, p. 62–66, Jan 1979.
- ROSS, S. M. **Simulation**. [S.l.]: Academic Press, 2013.
- SEN, P. K.; SINGER, J. M.; LIMA, A. C. P. de. **From finite sample to asymptotic methods in statistics**. [S.l.]: Cambridge University Press, 2010.
- SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. **Journal of Electronic Imaging**, v. 13, n. 1, p. 146–165, Jan 2004.
- SINGH, J.; DATCU, M. SAR image categorization with log cumulants of the fractional fourier transform coefficients. **IEEE Trans. Geosci. Remote Sens.**, v. 51, n. 12, p. 5273–5282, Dec. 2013.
- SKONIECZNY, C.; PAILLOU, P.; BAYON, A.; BISCARA, L.; CROSTA, X.; EYNAUD, F.; MALAIZÉ, B.; REVEL, M.; ALEMAN, N.; BARUSSEAU, J. P.; VERNET, R.; LOPEZ, S.; GROUSSET, F. African humid periods triggered the reactivation of a large river system in western sahara. **Nature communications**, p. 1–6, Nov. 2015.
- TIAN, X.; JIAO, L.; YI, L.; GUO, K.; ZHANG, X. The image segmentation based on optimized spatial feature of superpixel. **J. Vis. Commun. Image R.**, v. 26, p. 146–160, 2015.
- TISON, C.; MARIE, J.; TUPIN, F. A new statistical model for markovian classification of urban areas in high-resolution SAR images. **IEEE Trans. Geosci. Remote Sens.**, v. 42, n. 10, p. 2046–2057, Oct 2004.
- WARD, K. D. Compound representation of high resolution sea clutter. **Electronics Letters**, v. 17, n. 16, p. 561–563, Aug. 1981.
- XU, C.; SUI, H.; XU, F. Land surface water mapping using multi-scale level sets and a visual saliency model from SAR images. **International Journal of Geo-Information**, v. 58, p. 1–19, May. 2016.