



UNIVERSIDADE FEDERAL DO CARIRI - UFCA
DESENVOLVIMENTO REGIONAL SUSTENTÁVEL
PÓS-GRADUAÇÃO

IAN HENRIQUE TELES BRAGA

SIMILARIDADE ESTOCÁSTICA NO PROCESSAMENTO DE IMAGENS DE
RADAR DE ABERTURA SINTÉTICA

CRATO

2022

IAN HENRIQUE TELES BRAGA

SIMILARIDADE ESTOCÁSTICA NO PROCESSAMENTO DE IMAGENS DE RADAR DE
ABERTURA SINTÉTICA

Dissertação apresentada ao Programa de Pós-Graduação em Desenvolvimento Regional Sustentável da Universidade Federal do Cariri - UFCA, como requisito parcial à obtenção do título de mestre em Desenvolvimento Regional Sustentável. Área de Concentração: Ciências Ambientais.

Linha de Pesquisa: Tecnologia e Modelagem.

Sublinha de Pesquisa: Processamento estatístico de imagens e sinais.

Orientador: Prof. Dr. Francisco Alexandre Ávila Rodrigues

Coorientadora: Profa. Dra. Lígia Cláudia Castro de Oliveira

IAN HENRIQUE TELES BRAGA

SIMILARIDADE ESTOCÁSTICA NO PROCESSAMENTO DE IMAGENS DE RADAR DE
ABERTURA SINTÉTICA

Dissertação apresentada ao Programa de Pós-Graduação em Desenvolvimento Regional Sustentável da Universidade Federal do Cariri - UFCA, como requisito parcial à obtenção do título de mestre em Desenvolvimento Regional Sustentável. Área de Concentração: Ciências Ambientais.

Linha de Pesquisa: Tecnologia e Modelagem.
Sublinha de Pesquisa: Processamento estatístico de imagens e sinais.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Francisco Alixandre Ávila
Rodrigues (Orientador)
Universidade Federal do Cariri (UFCA)

Profa. Dra. Lígia Claudia Castro de
Oliveira (Coorientadora)
Universidade Regional do Cariri (URCA)

Prof. Dr. Jeová Farias Sales Rocha Neto (Membro
externo)
Haverford College (USA)

Prof. Dr. Fidel Ernesto Castro Morales (Membro
externo)
Universidade Federal do Rio Grande do Norte

Prof. Dr. Paulo Renato Alves Firmino (Membro
Interno)
Universidade Federal do Cariri

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Cariri
Sistema de Bibliotecas

-
- B813s Braga, Ian Henrique Teles.
Similaridade estocástica no processamento de imagens de radar de abertura sintética / Ian Henrique Teles Braga. – 2022.
50 f.: il. color., enc. ;30 cm.
(Inclui bibliografia, p.48-50)
- Dissertação (Mestrado) - Universidade Federal do Cariri, Centro de Ciências Agrárias e Biodiversidade, Programa de Pós-Graduação em Desenvolvimento Regional Sustentável - PRODER, Crato, 2022.
Área de Concentração: Ciências Ambientais
- Orientador: Prof. Dr. Francisco Alixandre Ávila Rodrigues.
Coorientadora: Prof.^a Dr.^a. Lígia Claudia Castro de Oliveira.
1. Imagens SAR. 2. Matriz Indicadora de Mudança. 3. Distância estocástica. 4. Dificuldade de segmentação modificada. 5. Contraste. I. Título.

CDD 363.73

Quero dedicar esta dissertação à minha avó Raimunda cujo amor e dedicação que me deu durante seus anos de vida foram fundamentais para a construção do meu caráter. Grato por tudo. Quero agradecer ao professor Alixandre Ávila por ser uma constante fonte de motivação e incentivo ao longo de todo o projeto. Muito obrigado.

AGRADECIMENTOS

Agradeço a Deus pelas oportunidades e pela saúde que me foram permitidas até hoje. Agradeço às minhas duas mães, Adriana e Raimunda, que, mesmo com dificuldades em termos de recursos, me deram todo o apoio, suporte e dedicação necessários.

Agradeço a todos os professores por me proporcionar o conhecimento não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional, por tanto que se dedicaram a mim, não somente por terem me ensinado, mas por terem me feito aprender. Em especial aos professores Alixandre Ávila, Vinicius Sacramento e Lígia Claudia pela contribuição neste trabalho.

E à Fundação Cearense de Apoio ao Desenvolvimento (Funcap), pelo financiamento da pesquisa de Mestrado via bolsa de estudos.

“Tenho a impressão de ter sido uma criança brincando à beira-mar, divertindo-me em descobrir uma pedrinha mais lisa ou uma concha mais bonita que as outras, enquanto o imenso oceano da verdade continua misterioso diante de meus olhos”.

(Isaac Newton)

RESUMO

A detecção de fenômenos na superfície da terra é um trabalho importante e necessário, principalmente quando se tratam de fenômenos de grande escala como manchas de óleo no mar e desmatamentos em florestas de grande extensão. Porém, o monitoramento desses fenômenos por meio de imagens ópticas de satélite traz consigo complicações em termos de continuidade na geração de imagens. O Radar de Abertura Sintética se apresenta como ideal para monitoramento da superfície terrestre de forma confiável, contínua e global, uma vez que possibilita a geração de imagens com fonte de luz própria e com resolução maior que os sistemas ópticos convencionais, além de permitir sua operação independentemente de condições climáticas. No entanto, a dificuldade de se trabalhar com estas imagens centra-se na interpretação dos dados imageados, necessitando de processamentos para extração de informações. Isto se deve à presença de um ruído de natureza estocástica que degrada significativamente a imagem. Assim, a utilização de distribuições de probabilidade é de fundamental importância na modelagem destes dados. Nesta dissertação, apresentamos uma medida de similaridade estocástica para imagens SAR que expressa ganhos significativos em termos de informação e classificação, podendo ser utilizadas para monitorar desastres naturais na superfície terrestre, como por exemplo, vazamentos de óleo em alto mar, evolução do desmatamento de florestas, poluição de rios e lagos.

Palavras-chave: Imagens SAR. Matriz Indicadora de Mudanças. Distâncias Estocásticas. Dificuldade de segmentação modificada. Contraste.

ABSTRACT

The detection of phenomena on the earth's surface is an important and necessary work, especially when dealing with large-scale phenomena such as oil slicks at sea and deforestation in large-scale forests. However, monitoring these phenomena through optical satellite images brings with it complications in terms of continuity in the generation of images. The Synthetic Aperture Radar is ideal for monitoring the earth's surface in a reliable, continuous and global way, since it allows the generation of images with its own light source and with higher resolution than conventional optical systems, in addition to allowing its operation. regardless of weather conditions. However, the difficulty of working with these images is centered on the interpretation of the imaged data, requiring processing to extract information. This is due to the presence of a stochastic noise that significantly degrades the image. Thus, the use of probability distributions is of fundamental importance in the modeling of these data. In this dissertation, we present a stochastic similarity measure for SAR images that expresses significant gains in terms of information and classification, which can be used to monitor natural disasters on the earth's surface, such as oil spills at sea, evolution of forest deforestation , pollution of rivers and lakes.

Keywords: SAR images. Change Indicator Matrix. Stochastic Distances. Segmentation difficulty. Contrast.

LISTA DE FIGURAS

Figura 1 – Formação do <i>Speckle</i>	19
Figura 2 – .Comparação entre <i>DoS</i> e <i>DoS_{mod}</i>	27
Figura 3 – Fluxograma da metodologia proposta para avaliação de contraste.	28
Figura 4 – Fluxograma da Metodologia proposta para Matriz Indicadora de Mudanças.	29
Figura 5 – Fluxograma da Metodologia proposta para classificação supervisionada 01.	30
Figura 6 – Fluxograma da Metodologia proposta para classificação supervisionada 02.	31
Figura 7 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 1$	33
Figura 8 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 3$	33
Figura 9 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 5$	34
Figura 10 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 8$	34
Figura 11 – Imagem Sar Real - Bahia de São Francisco (EUA), com recortes 50x50 <i>pixels</i>	35
Figura 12 – Imagem SAR multi-temporal real.	38
Figura 13 – Matrizes Indicadoras de Mudanças	39
Figura 14 – Segmentação da MIM usando DoS_{mod} à esquerda e d_{AG} à direita com diferentes limiares de segmentação para DoS_{mod} e seu correspondente d_{AG}	43
Figura 15 – Matrizes Indicadoras de Mudanças - Distância Euclidiana	44
Figura 16 – Localização da Imagem SAR real completa da cidade de Nova Iorque.	45
Figura 17 – Recortes (100x100) de imagens SAR da Cidade de Nova Iorque, Canal HV, $L = 1$	45

LISTA DE TABELAS

Tabela 1 – Valores médio e desvios padrão para DoS_{mod} advindos do experimento de Monte Carlo.	33
Tabela 2 – Valores para a Dificuldade de Segmentação (DoS). * significa indefinição matemática.	36
Tabela 3 – Valores para a medida de similaridade estocástica (DoS_{mod}).	36
Tabela 4 – Valores para a medida de similaridade aplicada a Distância Euclidiana	37
Tabela 5 – Classificação Supervisionada usando DoS_{mod} . Limiar Igual a 0,9009.	40
Tabela 6 – Classificação Supervisionada usando DoS_{mod} . Limiar Igual a 0,9930.	41
Tabela 7 – Classificação Supervisionada usando $DoS_{modeuclid}$. Limiar Igual a 0,9930. . .	42
Tabela 8 – Classificação Supervisionada usando DoS_{mod}	42

LISTA DE ABREVIATURAS E SIGLAS

<i>fdp</i>	<i>função densidade de probabilidade</i>
MLC	Método do log-cumulantes
MTI	Método da Transformação Inversa
PNRH	Política Nacional de Recursos Hídricos
SAR	Radar de Abertura Sintética

LISTA DE SÍMBOLOS

α	Parâmetro de Rugosidade
$d_{AG}(Z_1, Z_2)$	Distância Aritmética-Geométrica entre duas Variáveis Aleatórias Z_1 e Z_2
$DoS(\cdot)$	Dificuldade de Segmentação
$DoS_{mod}(\cdot)$	Dificuldade de Segmentação Modificada
$\exp(\cdot)$	Função Exponencial
$E[Z^r]$	R-ésimo Momento não Central para a Variável Aleatória Z
$f(z)$	Função Densidade de Probabilidade
$\phi_z(s)$	Transformada de <i>Mellin</i>
G_I^0	Distribuição G-intensidade zero
γ	Parâmetro de Escala
$\Gamma(\cdot)$	Função gamma
\tilde{k}_v	Log-cumulant de ordem v
L	Número de <i>Looks</i>
\tilde{m}_v	Log-momento de Ordem v
\hat{m}_v	Log-momento Amostral de Ordem v
$\Psi^0(\cdot)$	Função Digamma
$\Psi^1(\cdot)$	Função Trigamma
$\Psi^2(\cdot)$	Função Quadrigamma
s	Número Complexo de Norma Unitária
$\theta = (\alpha, \gamma, L)$	Vetor de Parâmetros da Distribuição G_I^0
U	Variável Aleatória Uniforme
Υ^{-1}	Função de Distribuição Inversa da Distribuição F-Snedecor
z	Amostra de Z
Z	Variável Aleatória

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos geral e específicos	17
2	FUNDAMENTOS DE IMAGENS SAR	18
3	MODELO ESTATÍSTICO PARA DADOS SAR EM INTENSIDADE	20
3.1	Estimação dos Parâmetros	21
3.2	Simulação de Dados SAR	23
3.3	Distâncias estocásticas	24
3.4	Dificuldade de Segmentação	25
4	METODOLOGIA PROPOSTA	26
4.1	Metodologia para dados SAR Simulados	26
4.2	Metodologia para dados SAR Reais	26
4.2.1	<i>Medida de Similaridade Estocástica</i>	26
4.2.2	<i>Metodologia para avaliar contrastes</i>	28
4.2.3	<i>Metodologia para detecção de mudanças</i>	29
4.2.4	<i>Metodologia para classificação supervisionada 01</i>	29
4.2.5	<i>Metodologia para classificação supervisionada 02</i>	30
5	RESULTADOS	32
5.1	Resultados com dados SAR Simulados	32
5.2	Resultados com Imagens SAR Reais	35
5.2.1	<i>Aplicação 01: Avaliação de contrastes</i>	35
5.2.2	<i>Aplicação 02: Detecção de mudanças</i>	37
5.2.3	<i>Aplicação 03: Classificação supervisionada 01</i>	39
5.2.4	<i>Aplicação 04: Classificação supervisionada 02</i>	42
6	CONCLUSÕES	46
6.1	Trabalhos futuros	46
	REFERÊNCIAS	48

1 INTRODUÇÃO

Quando se analisa o panorama mundial e local em termos de desenvolvimento sustentável atrelado ao uso do radar de abertura sintética para monitoramento de fenômenos na superfície terrestre, observa-se que tal ferramenta contribui de forma interessante para os objetivos de desenvolvimento sustentável criados na Cúpula das Nações Unidas. Nele, foram definidos 17 objetivos ambiciosos e interconectados que abordam os principais desafios de desenvolvimento enfrentados por pessoas no Brasil e no mundo (ONU, c2021.).

No panorama de monitoramento e gestão de recursos naturais se destaca o Objetivo 6: Assegurar a disponibilidade e gestão sustentável da água e o saneamento para todos. No subitem 5 deste objetivo há uma alusão à gestão integrada que profere: até 2030, implementar a gestão integrada dos recursos hídricos em todos os níveis, inclusive via cooperação transfronteiriça, conforme apropriado.

Nesse ínterim, A *Global Water Partnership*, defini a gestão integrada dos recursos hídricos como sendo um processo que favorece o desenvolvimento e a gestão coordenados da água, das terras e dos recursos relacionados, de forma a potencializar o bem-estar social e econômico resultante de forma equânime e sem comprometer com a sustentabilidade dos ecossistemas vitais (WATER, 2012).

Nesse tipo de gestão, se fazem necessários instrumentos para viabilizar a execução deste trabalho de integração da gestão. Dentre os instrumentos de gestão integrada, Water (2012) cita o uso da tecnologia no quesito pesquisa e desenvolvimento, diretrizes para avaliação e seleção de tecnologias. Já no Brasil, a Política Nacional de Recursos Hídricos (PNRH) estabeleceu como um de seus instrumentos de gestão o Sistema de Informações sobre Recursos Hídricos (BRASIL, 1997).

Tais instrumentos reforçam a necessidade de tecnologias e sistemas que favoreçam a informação sobre os recursos hídricos. Uma boa alternativa para sanar essas necessidades é o uso do sensoriamento remoto como ferramenta de aquisição de imagens para posterior processamento e extração de informações relevantes para aperfeiçoar o processo de tomada de decisões acerca dos recursos naturais na esfera política mundial e local.

Por exemplo, no trabalho de Ngo *et al.* (2020) o qual demonstrou a utilidade das imagens de um Radar de Abertura Sintética na caracterização do uso e cobertura da terra em Bac Lieu, no Vietnã, para apoiar o gerenciamento de recursos naturais no planejamento e monitoramento do uso da terra (NGO *et al.*, 2020).

Já no trabalho de Peruzzo *et al.* (2019), foram utilizados imagens de satélites e sensoriamento remoto para avaliar mudanças de uso do solo que ocorrem ao longo de 30 anos na Bacia Hidrográfica do Alto Piranhas (PERUZZO *et al.*, 2019).

Nesse sentido, é notório observar que o sensoriamento remoto, e conseqüentemente o radar de abertura Sintética, é uma ferramenta muito útil e necessária para o monitoramento e gerenciamento de recursos hídricos, conseqüentemente corroboram para alcançar objetivos em termos de desenvolvimento Sustentável.

As aplicações de imagens de Radar de Abertura Sintética (SAR) para entendimento e monitoramento de fenômenos na superfície terrestre são inúmeras. Os sistemas SAR já foram usados para estimar variáveis biofísicas em florestas brasileiras (JESUS; KUPLICH, 2020), no reconhecimento de padrões de uso e ocupação do solo em costas tropicais (SANTOS *et al.*, 2009), no mapeamento de óleo no mar Cáspio (IVANOV; ERMOSHKIN, 2004) dentre outras aplicações. O grande número de aplicações dos sistemas SAR se deve principalmente pelas características únicas desse tipo de radar, uma vez que fornece imagens bidimensionais de alta resolução, independentes da luz do dia, cobertura de nuvens e condições climáticas (MOREIRA *et al.*, 2013).

Entretanto, as imagens formadas por este sistema trazem consigo complicações em termos de processamento, o ruído *speckle*. Abordagens estatísticas são geralmente necessárias para lidar com esse tipo de ruído. Por isso, a escolha de uma distribuição de probabilidades para descrever dados SAR é de fundamental importância para o processamento dessas imagens. A distribuição G_I^0 apresenta-se como uma boa alternativa para essa tarefa, uma vez que possibilita a modelagem de regiões homogêneas, heterogêneas e extremamente heterogêneas de dados SAR (FRERY *et al.*, 1997).

Paralelamente, a análise de contrastes em imagens SAR é uma tarefa importante para a compreensão desse tipo de imagem. O estudo de medidas de contraste pode ser útil, por exemplo, para investigar o quão distinguíveis duas regiões da imagem são. Neste contexto, podemos destacar as distâncias estocásticas (NASCIMENTO *et al.*, 2010) como possíveis medidas de contraste.

Baseado em distâncias estocásticas, Marques *et al.* (2012) apresentaram uma medida de avaliação de contraste denominada dificuldade de segmentação, doravante chamada de *DoS*. Apesar de bastante interessante, essa medida apresenta uma indefinição matemática. Baseado no número de Euler, propomos uma alteração na *DoS* de tal sorte que a indefinição matemática

foi corrigida. Essa versão corrigida da *DoS* foi considerada nesse trabalho como uma medida de similaridade estocástica. Usando imagens sintéticas e reais, nossa proposta foi avaliada em três situações, avaliação de contrastes, detecção de mudanças e classificação supervisionada, com resultados satisfatórios em comparação com medidas já aplicadas na literatura como o *DoS* (MARQUES *et al.*, 2012).

1.1 Objetivos geral e específicos

O objetivo geral desse trabalho foi propor uma medida de similaridade estocástica para uso em processamento de imagens SAR. Alguns objetivos específicos podem ser destacados:

- Verificar o uso da medida de similaridade estocástica na detecção de mudanças em imagens SAR multi-temporais;
- Avaliar o contraste existente entre regiões em imagens SAR reais e sintéticas;
- Avaliar o desempenho em problemas de classificação supervisionada.

2 FUNDAMENTOS DE IMAGENS SAR

O radar de abertura sintética ao longo do tempo vem sendo cada vez mais utilizado na geração de imagens da superfície terrestre. Seu sucesso se deve à sua possibilidade única de geração de imagens, pois pode gerar dados independentemente da luz do dia, da cobertura de nuvens e de condições meteorológicas. Portanto, ideal para monitorar processos dinâmicos na superfície da Terra de forma confiável, contínua e global (MOREIRA *et al.*, 2013).

Esses sistemas são embarcados em satélites ou em aeronaves e a geração de imagens se deve a ondas eletromagnéticas na faixa de microondas (MARQUES, 2011). Essas ondas incidem na superfície imageada, e a geração das imagens depende da posterior captação da radiação refletida (retroespalhamento).

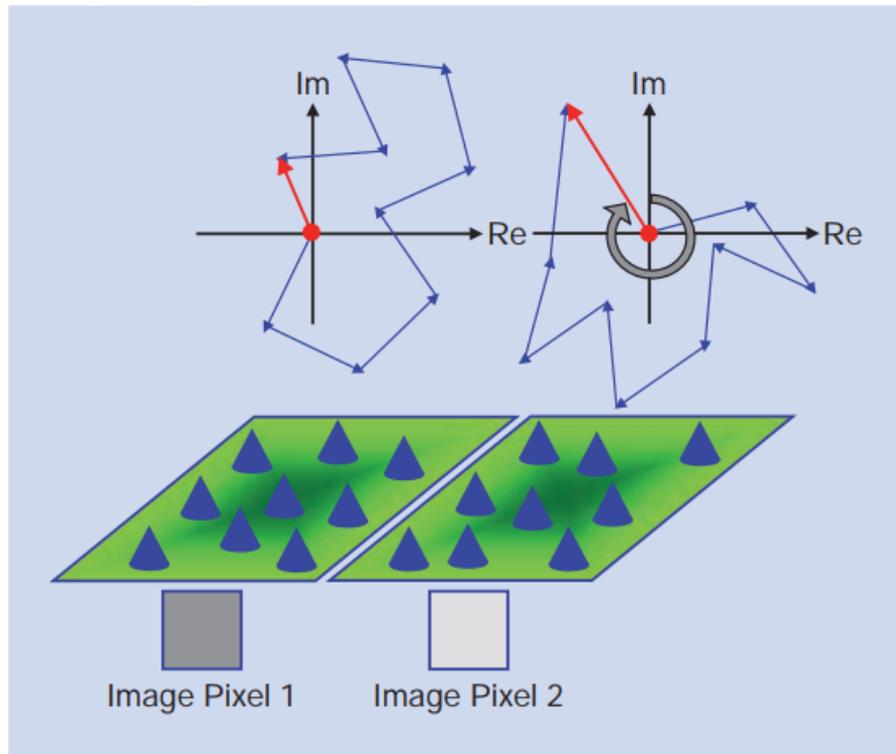
O sinal de retorno depende das propriedades físicas (por exemplo, geometria e rugosidade) e das propriedades elétricas (por exemplo, permissividade) do objeto imageado (MOREIRA *et al.*, 2013). Além disso, o comprimento de onda influencia na capacidade de penetração das microondas e na interação destas com a superfície imageada. Superfícies pouco rugosas, como lagos e rios, não geram retorno, uma vez que toda radiação incidente não é refletida na direção da antena, formando regiões escuras na imagem. Em contrapartida, regiões urbanas e em alvos localizados como navios, tanques e plataformas petrolíferas podem apresentar pontos de alto retroespalhamento o que causa a formação de regiões mais claras na imagem (MARQUES, 2011).

O ruído *speckle* é um fenômeno que acontece nesse tipo de radar. Ele se deve ao fato de que os radares usam energia eletromagnética coerente, que resulta em interferência construtiva e destrutiva quando a energia transmitida interage com as características presentes na superfície da Terra (KASISCHKE *et al.*, 1997). Ou seja, esse ruído se forma quando a rugosidade da superfície imageada é da mesma ordem de grandeza do comprimento de onda emitido. 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, como mostrado na Figura 1. O sinal consiste nas ondas refletidas de vários refletores elementares, ou melhor dizendo, na soma dos sinais refletidos dentro da célula de resolução (RODRIGUES, 2017a).

Na Figura 1 tem-se a ilustração de um exemplo de duas células de resolução e os sinais refletidos. O sinal de retorno é o vetor resultante (soma) dos sinais refletidos dentro de

Figura 1 – Formação do *Speckle*.



Fonte: retirada de Moreira *et al.* (2013)

cada célula de resolução. Este vetor, é uma representação de número complexo dado por:

$$S = Re(S) + i(lm(S)), \quad (2.1)$$

em que Re é a parte real de S , lm a parte imaginária e $i = \sqrt{-1}$. Esse sinal complexo pode ser transformado em amplitude (A), que é expresso como (RODRIGUES, 2017a):

$$A = \sqrt{Re(S)^2 + lm(S)^2}. \quad (2.2)$$

É possível também utilizar a intensidade (I) do vetor S , que é definida como o quadrado da amplitude, assim:

$$I = Re(S)^2 + lm(S)^2. \quad (2.3)$$

Na seção seguinte apresentaremos um modelo estatístico para descrever dados SAR, o qual foi utilizado na construção da metodologia central deste trabalho.

3 MODELO ESTATÍSTICO PARA DADOS SAR EM INTENSIDADE.

Na década de 1970, com a aquisição da primeira imagem de radar de abertura sintética, a análise de dados SAR reais impulsionou o desenvolvimento de técnicas de modelagem estatística para descrever este tipo de dados (GAO *et al.*, 2013). Nesse ínterim, os modelos estatísticos são primordiais para o processamento dos mesmos (FRERY *et al.*, 1997). Arsenault e April (1976) desenvolveram um dos primeiros trabalhos sobre modelagem estatística de dados SAR. Seu estudo propôs um modelo para o ruído *speckle* e também estabeleceu um fundamento teórico para as pesquisas futuras.

O legado de Ward (1981) foi um marco para o desenvolvimento da modelagem estatística de dados de radar de abertura sintética, uma vez que estabeleceu um mecanismo físico para a composição de imagens SAR. Esse mecanismo foi apresentado posteriormente como modelo multiplicativo e determina que o retorno Z do sistema SAR é obtido pelo produto entre o retroespalhamento da superfície imageada X e o ruído *speckle* Y . Pode-se representar matematicamente da seguinte forma:

$$Z = XY \quad (3.1)$$

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, merece destaque a distribuição G_I^0 apresentada em (FRERY *et al.*, 1997). O subscrito I em G_I^0 representa o formato de imagem SAR em intensidade.

A partir da Equação 3.1, 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 $Y \sim \Gamma(L, L)$, onde Γ^{-1} trata da distribuição Gama inversa. O produto dessas duas variáveis aleatórias define a distribuição G_I^0 . A seguir é apresentada a distribuição para o retorno em intensidade para imagens SAR.

Seja uma variável aleatória contínua Z , a *função densidade de probabilidade (fdp)* para a distribuição G_I^0 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:

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

em que, $z > 0$ é o retorno, $\alpha < 0$ é o parâmetro de rugosidade e está relacionado com a rugosidade do alvo. Pequenos valores de α ($\alpha < -10$) descrevem regiões suaves (homogêneas), por exemplo, plantações e campos queimados. Quando α está próximo de zero ($\alpha > -5$), o alvo observado é extremamente heterogêneo, como é o caso de manchas urbanas. Situações intermediárias ($-10 < \alpha < -5$) geralmente estão relacionadas a áreas acidentadas (heterogêneas), por exemplo, florestas (FRERY *et al.*, 2004). $\gamma > 0$ é o parâmetro de escala e está relacionado com o brilho da imagem (LUCINI *et al.*, 2002), $L \geq 1$ é o número (equivalente) de *looks* (visadas), parâmetro que pode ser controlado no processo de geração da imagem e está relacionado com a relação sinal-ruído e com a precisão espacial da imagem (FRERY *et al.*, 2004). $\Gamma(\cdot)$ é a função Gama.

O fato da distribuição G_I^0 permitir descrever regiões homogêneas, heterogêneas e extremamente heterogêneas de imagens SAR (FRERY *et al.*, 1997) é uma característica vantajosa, pois não é encontrada em outras distribuições de probabilidade usadas para modelar dados SAR, como por exemplo, as distribuições K e Weibull (GAO *et al.*, 2013). Além disso, a G_I^0 se destaca por possuir o parâmetro α , o qual possui interpretação física de rugosidade, o que permite a mesma ser utilizada como medida de textura (FRERY *et al.*, 1997).

Outra característica dos parâmetros da distribuição G_I^0 é o fato do parâmetro L estar relacionado ao controle do ruído *speckle* reduzindo a variância das intensidades dos *pixels* (RODRIGUES, 2017b). A próxima seção detalhará o método que será usado para estimar os parâmetros da distribuição G_I^0 .

3.1 Estimação dos Parâmetros

Para estimar os parâmetros da distribuição G_I^0 , adotamos o Método do log-cumulantes (MLC). A seguir apresentamos uma breve descrição do método.

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

$$\phi_Z(s) = \int_0^{\infty} u^{s-1} f_Z(u, \theta) du, \quad (3.4)$$

s é um número complexo com norma unitária (NICOLAS, 2002). Observe que a transformada de Mellin pode ser representada em função do valor esperado, $\phi_z = E[z^{s-1}]$.

Duas relações são importantes para a construção do método de log-cumulantes, são elas os log-momentos e log-cumulantes de ordem ν . Expressões analíticas são possíveis de serem obtidas para os log-momentos e log-cumulantes de ordem ν por simples derivação, avaliada em $s = 1$. O log-momento de ordem ν é obtido por (NICOLAS, 2002):

$$\tilde{m}_\nu = \left. \frac{d^\nu \phi_z(s)}{ds^\nu} \right|_{s=1}, \nu \in \mathbb{N}^*. \quad (3.5)$$

Aplicando o logaritmo natural de $\phi_z(s)$, pode-se obter o log-cumulante de ordem ν como (NICOLAS, 2002; CHENG *et al.*, 2013):

$$\tilde{k}_\nu = \left. \frac{d^\nu \psi_z(s)}{ds^\nu} \right|_{s=1}, \nu \in \mathbb{N}^*, \quad (3.6)$$

com $\psi_z(s) = \log(\phi_z(s))$.

A relação entre os log-momentos e log-cumulantes é dada por:

$$\tilde{k}_\nu = \tilde{m}_\nu - \sum_{i=1}^{\nu-1} \binom{\nu-1}{i-1} \tilde{k}_i \tilde{m}_{\nu-i}. \quad (3.7)$$

Como exemplo, destacamos os log-momentos e log-cumulantes de ordem 1,2 e 3 como tendo a seguinte relação:

$$\begin{cases} \tilde{k}_1 = \tilde{m}_1 \\ \tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2 \\ \tilde{k}_3 = \tilde{m}_3 - 3\tilde{m}_1\tilde{m}_2 + 2\tilde{m}_1^3 \end{cases} \quad (3.8)$$

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

$$\hat{\tilde{m}}_\nu = \frac{1}{n} \sum_{i=1}^n \log z_i^\nu, \quad (3.9)$$

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 da função densidade de probabilidade G_I^0 .

Para a distribuição de probabilidade G_I^0 , a função $\phi_Z(s)$ pode ser obtida aplicando a Equação (3.4), ou seja, utilizando a Equação (3.3) para obter $E[Z^{s-1}]$, e portanto,

$$\phi_{G_I^0}(s) = \left(\frac{\gamma}{L}\right)^{s-1} \frac{\Gamma(1-s-\alpha)\Gamma(L+s-1)}{\Gamma(-\alpha)\Gamma(L)}. \quad (3.10)$$

Utilizando a Equação (3.6), podemos obter o seguinte sistema de equações (CUI; DATCU, 2011):

$$\begin{cases} \tilde{k}_1 = \log\left(\frac{\gamma}{L}\right) + \Psi^0(L) - \Psi^0(-\alpha) \\ \tilde{k}_2 = \Psi^1(L) - \Psi^1(-\alpha) \\ \tilde{k}_3 = \Psi^2(L) - \Psi^2(-\alpha) \end{cases} \quad (3.11)$$

em que $\Psi^0(\cdot)$, $\Psi^1(\cdot)$ e $\Psi^2(\cdot)$ correspondem às funções digamma, trigamma e quadigamma, respectivamente (ARFKEN; WEBER, 2005). Assim, para estimar o vetor de parâmetros $\theta = (\alpha, \gamma, L)$ da distribuição G_I^0 , aplicamos as Equações (3.8) e (3.11) substituindo \tilde{m}_1 , \tilde{m}_2 e \tilde{m}_3 pelos correspondentes log-momentos amostrais, dados pela Equação (3.9).

As funções $\Psi^0(\cdot)$, $\Psi^1(\cdot)$ e $\Psi^2(\cdot)$ não admitem inversa, logo a solução do sistema de Equações (3.11) não pode ser obtido explicitamente e portanto, procedimentos numéricos são necessários. Em geral, esses procedimentos são computacionalmente lentos, de modo que, 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.

Apesar de possíveis instabilidades numéricas, o método de log-cumulantes (*MLC*) é bastante utilizado com resultados satisfatórios em processamentos de imagens SAR. O *MLC* vem sendo utilizado, especialmente para pequenas amostras que é um problema crítico em vários estudos (KRYLOV *et al.*, 2013). Pesquisadores têm utilizado os parâmetros estimados pelo *MLC* 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).

3.2 Simulação de Dados SAR

Para a construção da metodologia deste trabalho é necessário se valer de métodos de simulação de imagens SAR. Para gerar imagens SAR em intensidade, utilizamos o Método da Transformação Inversa (MTI) (MARQUES *et al.*, 2012). Este método utiliza a seguinte

expressão para geração de amostras da variável aleatória Z_I , com distribuição G_I^0 (RODRIGUES, 2017a):

$$Z_I = -\frac{\gamma}{\alpha} \Upsilon^{-1}_{2L; -2\alpha}(U), \quad (3.12)$$

em que $\Upsilon^{-1}_{2L; -2\alpha}$ é a função inversa da distribuição F-Snedecor com $2L$ e -2α sendo os graus de liberdade, a qual foi utilizada como aproximação para $F_{G_I^0}^{-1}(z)$, e U uma variável aleatória com distribuição uniforme sobre $[0, 1]$.

3.3 Distâncias estocásticas

Quando analisamos medidas que visam a quantificação de diferenças entre objetos é natural se pensar em medidas que mostrem o quão longe estão dois pontos no espaço. A distância Euclidiana é provavelmente a mais conhecida e usada medida para se aferir a distância entre dois pontos do \mathfrak{R}^p . Ela simplesmente é a distância linear no espaço multidimensional. Essa medida é dada pela Equação 3.13:

$$d_{euclid.} = \sqrt{\sum_{i=1}^p (x_i - y_i)^2} \quad (3.13)$$

onde x e y são vetores no espaço p -dimensional. Entretanto, a distância Euclidiana não é indicada para avaliar diferenças em imagens SAR, haja vista a natureza estocástica herdado do ruído *speckle*.

O trabalho de Nascimento *et al.* (2010) apresenta um conjunto de distâncias estocásticas, dentre as quais se encontra a distância aritmética-geométrica, a qual foi utilizada para guiar a proposta deste trabalho. A escolha da distância aritmética-geométrica se deve ao fato dela ter apresentado melhores resultados em testes discutidos em (NASCIMENTO *et al.*, 2010).

A distância estocástica aritmética-geométrica foi utilizada para fornecer medidas que avaliam quantitativamente resultados experimentais de segmentação e detecção de mudanças em imagens SAR. A seguir será apresentado a distância estocástica escolhida para elaboração da metodologia central desse trabalho.

Sejam Z_1 e Z_2 variáveis aleatórias contínuas definidas no mesmo espaço de probabilidades, com funções densidades de probabilidade $f_{Z_1}(z, \theta_1)$ e $f_{Z_2}(z, \theta_2)$, respectivamente, em que θ_1 e θ_2 são vetores de parâmetros. Assumindo que ambas as densidades compartilham um

suporte comum, a distância estocástica aritmética-geométrica entre $f_{Z_1}(z_1, \theta_1)$ e $f_{Z_2}(z_2, \theta_2)$ é dada por (NASCIMENTO *et al.*, 2010):

$$d_{AG}(Z_1, Z_2) = \frac{1}{2} \int_0^\infty (f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)) \ln \left(\frac{f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)}{\sqrt{f_{Z_1}(z, \theta_1) f_{Z_2}(z, \theta_2)}} \right) dz. \quad (3.14)$$

Normalmente, a integral que consta na Equação (3.14) não apresenta solução analítica, portanto, métodos numéricos são geralmente necessários para contornar este problema.

3.4 Dificuldade de Segmentação

Marques *et al.* (2012) propuseram uma medida cujo objetivo inicial é avaliar segmentação de imagens SAR. A segmentação de imagens implica na divisão ou separação da imagem em regiões cujas *pixels* compartilham alguma propriedade e tem como objetivo gerar regiões que representem objetos de interesse. Usando o conceito de distância estocástica, a medida quantifica o contraste entre *background* e *foreground* em imagens SAR. Os autores denotaram essa medida como Dificuldade de Segmentação (*DoS*), expressa como:

$$DoS(Z_1, Z_2) = \frac{1}{SD(Z_1, Z_2)}, \quad (3.15)$$

onde $SD(Z_1, Z_2) \geq 0$ é uma distância estocástica entre duas variáveis aleatórias Z_1 e Z_2 . Uma lista de distâncias estocásticas é apresentada em (NASCIMENTO *et al.*, 2010).

4 METODOLOGIA PROPOSTA

4.1 Metodologia para dados SAR Simulados

Para avaliar o desempenho do método proposto, realizamos experimentos com dados SAR simulados a partir da distribuição G_I^0 . Para possibilitar a aplicação do método em um grande número de simulações, optamos por um experimento de Monte Carlo especialmente desenhado.

Para o processo de simulação, optou-se pela geração de amostras aleatórias da distribuição G_I^0 , combinando espaços paramétricos de rugosidade e número de *looks* e sem perdas de generalidades os parâmetros de escala foram escolhidos de forma que $E_{G_I^0}[Z_I] = 1$. Cada combinação de parâmetros α e L representa um cenário, as etapas do método são sintetizadas a seguir:

- Passo 1: Simule dois vetores aleatórios $(v_{i,1}, v_{i,2})$, de tamanho n cada, da distribuição G_I^0 com parâmetros de acordo com o cenário C_i , $i \in \{1, 2, 3, \dots, k\}$.
- Passo 2: Calcule a $d_{AG}(v_{i,1}, v_{i,2})$ e $DoS_{mod}(v_{i,1}, v_{i,2})$
- Passo 3: Repita os passos 1 e 2 um número grande de vezes.

Os resultados podem ser expressos por meio de tabelas ou gráfico tipo *boxplot*.

4.2 Metodologia para dados SAR Reais

4.2.1 Medida de Similaridade Estocástica

DoS apresenta algumas limitações que podem dificultar interpretações. Quando a distância estocástica entre duas regiões se aproximam de zero, a *DoS* tende para o infinito. Por outro lado, quando a distância estocástica entre duas regiões é zero, não é possível obtermos a *DoS* pois nesse caso tem-se uma indefinição matemática. Resumindo, a *DoS* apresenta dificuldades na interpretação entre regiões muito semelhantes ou de baixo contraste.

Para contornar as limitações encontradas na *DoS*, propusemos uma correção que é apresentada a seguir:

$$DoS_{mod}(Z_1, Z_2) = \frac{1}{e^{SD(Z_1, Z_2)}}, \quad (4.1)$$

com e sendo a constante de Euler. Com essa versão modificada da *DoS*, as limitações são superadas. Os espaços de variações da DoS_{mod} e *DoS* podem ser mapeados a partir dos valores

que a SD pode assumir. Usando o conceito de limite podemos verificar que quando a SD tende para $+\infty$, ambas DoS_{mod} e DoS tendem para 0, ver Equações (4.2) e (4.3):

$$\lim_{SD \rightarrow +\infty} \frac{1}{e^{SD}} = 0, \quad (4.2)$$

$$\lim_{SD \rightarrow +\infty} \frac{1}{SD} = 0. \quad (4.3)$$

Por outro lado, quando SD se aproxima de zero pela direita a DoS_{mod} tende para 1 e a DoS tende para $+\infty$. As equações (4.4) e (4.5) apresentam esses comportamentos.

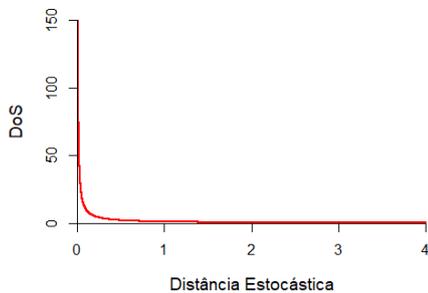
$$\lim_{SD \rightarrow 0^+} \frac{1}{e^{SD}} = 1, \quad (4.4)$$

$$\lim_{SD \rightarrow 0^+} \frac{1}{SD} = +\infty. \quad (4.5)$$

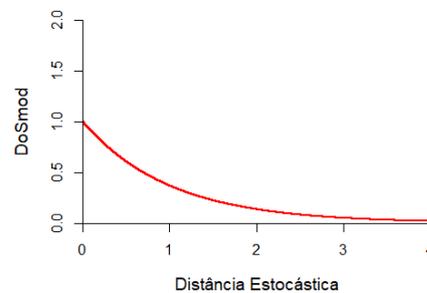
Entretanto, quando $SD = 0$ a DoS apresenta indefinição matemática, enquanto a $DoS_{mod} = 1$. Portanto, $DoS_{mod} \in [0, 1]$ e $DoS \in [0, +\infty)$.

Outro aspecto observado na DoS é que ela apresenta um decaimento abrupto em seu valor (Figura 3(c)). Esse comportamento não é observado na DoS_{mod} (Figura 3(d)).

Figura 2 – .Comparação entre DoS e DoS_{mod} .



(c)



(d)

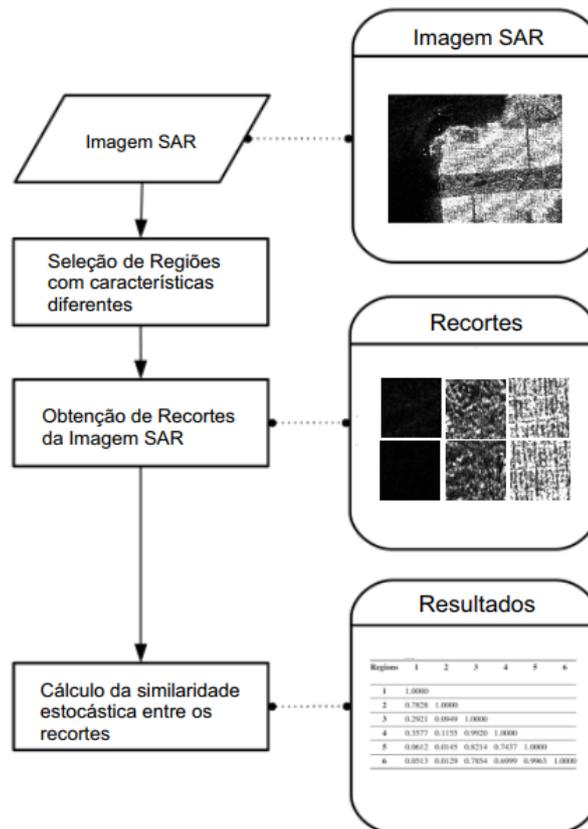
Fonte: elaborada pelo autor (2022).

Para evidenciar as vantagens da DoS_{mod} sobre a DoS , realizamos experimentos com dados simulados e reais. As descrições dos experimentos estão na seção 5.1.

4.2.2 Metodologia para avaliar contrastes

A metodologia proposta para avaliar contrastes em imagens SAR está sintetizada no fluxograma da Figura 3. Avaliar contrastes em imagens SAR é importante, por exemplo, para termos noção do grau de dificuldade de segmentá-la. Podemos fazer esse tipo de avaliação em imagens SAR, selecionando regiões de interesse e calculando a medida de similaridade estocástica DoS_{mod} entre essas regiões.

Figura 3 – Fluxograma da metodologia proposta para avaliação de contraste.



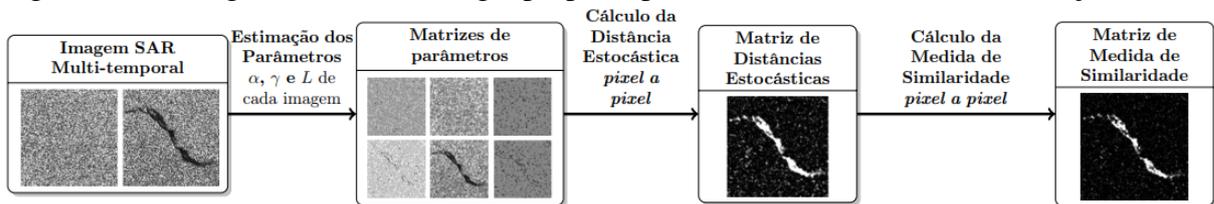
Fonte: elaborada pelo autor (2022).

Esse procedimento gera uma matriz simétrica contendo as medidas de similaridade estocástica entre as regiões, que podem ser interpretadas também como medidas de contraste. Quanto mais próximo de 1 for a DoS_{mod} , mais desafiador é segmentar essas regiões escolhidas e DoS_{mod} próximo de 0 (zero) significa que o contraste entre as regiões é alto, facilitando assim a segmentação.

4.2.3 Metodologia para detecção de mudanças

A Figura 4 apresenta o fluxograma das etapas do método de detecção de mudanças. A metodologia para a detecção de mudanças em imagens SAR multitemporais, inicia com a estimação das informações de rugosidade (α), escala (γ) e número de looks (L) para cada imagem SAR. Esse processo de estimação do trio de parâmetros (α, γ, L) é feito *pixel a pixel* usando o método de log-cumulantes. Ou seja, o resultado desse processo é a obtenção de três matrizes, correspondendo as rugosidades, escalas e números de *looks* para cada imagem SAR.

Figura 4 – Fluxograma da Metodologia proposta para Matriz Indicadora de Mudanças.



Fonte: elaborada pelo autor (2022).

Após a obtenção das matrizes de parâmetros, calcula-se a matriz de distâncias estocásticas Aritmética-Geométrica. Essa matriz é construída calculando a distância estocástica entre *pixels* correspondentes das imagens SAR multitemporais.

E, por fim, aplicando a DoS_{mod} para cada *pixel* da matriz de distâncias estocástica, obtém-se a matriz de similaridades estocástica. Essa matriz apresenta as mudanças detectadas pelo método, que denotamos por matriz indicadora de mudanças (MIM).

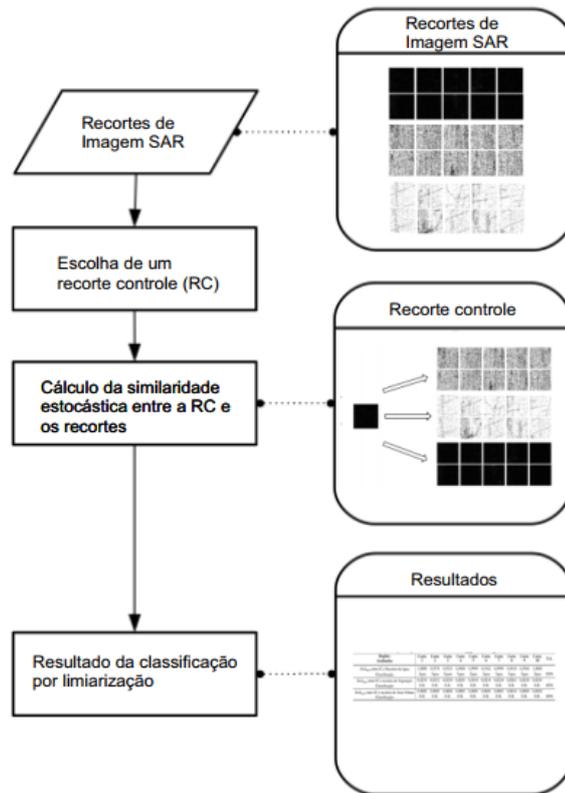
4.2.4 Metodologia para classificação supervisionada 01

A próxima metodologia que se aplicou nessa dissertação a fim de se obter resultados em termos de avaliação da nossa medida de similaridade estocástica, foi desenhada a fim de se classificar de forma supervisionada recortes de imagens SAR. A Figura 5 traz a metodologia.

O método de classificação inicia com uma imagem cuja classe é conhecida, denominada de imagem controle (IC). Em seguida, é calculada a medida de similaridade estocástica (DoS_{mod}) entre o IC e os demais recortes. Para classificar os recortes como sendo da mesma classe do IC ou não, é usado o critério baseado em limiarização a seguir.

$$Classificação = \begin{cases} IC; & DoS_{mod} \geq limiar \\ Outra região; & DoS_{mod} < limiar. \end{cases} \quad (4.6)$$

Figura 5 – Fluxograma da Metodologia proposta para classificação supervisionada 01.



Fonte: elaborada pelo autor (2022).

A escolha do limiar, nesse trabalho, foi feita com base nos experimentos de simulação de dados SAR. Vale ressaltar que a escolha do limiar pode ser alvo de pesquisas científicas, por exemplo envolvendo propriedades da distribuição G_I^0 , mas que nesse trabalho não foi explorado.

4.2.5 Metodologia para classificação supervisionada 02

Nessa seção falaremos sobre a metodologia para classificação supervisionada 02, fluxograma da Figura 6.

O primeiro passo dessa metodologia é selecionar um conjunto de recortes de imagens SAR com classes pré-definidas.

Em seguida, submetemos cada recorte a outro grupo de imagens com classes já conhecidas, a fim de calcular a similaridade estocástica entre eles.

Dessa forma, os recortes vão ser classificados de acordo com cada classe desses conjuntos que já são conhecidos.

A classificação de cada recorte, portanto, será feita com base no maior valor de similaridade estocástica obtido entre as imagens conhecidas e o recorte a ser classificado.

5 RESULTADOS

5.1 Resultados com dados SAR Simulados

Os experimentos de Monte Carlo foram realizados com o R versão 4.1.1, em uma máquina com *CPU* de 2.20 GHz com 4GB de RAM e o tempo de processamento foi de 106,36 segundos.

Utilizando o procedimento de simulação, foram geradas amostras aleatórias da distribuição G_I^0 combinando os seguintes espaços paramétricos: $\alpha \in \{-1.5, -3, -5, -8, -12\}$, $L \in \{1, 3, 5, 8\}$ e sem perdas de generalidades os parâmetros de escala foram escolhidos de forma que $E_{G_I^0}[Z_I] = 1$. Observe que cada combinação representa um cenário, ou seja, 20 cenários foram avaliados. Os passos do experimento de Monte Carlo são descritos a seguir:

- Passo 1: Simular dois vetores aleatórios $(v_{i,1}, v_{i,2})$, de tamanho 100 cada, da distribuição G_I^0 com parâmetros de acordo com 20 cenários.
- Passo 2: Calcular a $d_{AG}(v_{i,1}, v_{i,2})$ e $DoS_{mod}(v_{i,1}, v_{i,2})$
- Passo 3: Repetir os passos 1 e 2 mil vezes.

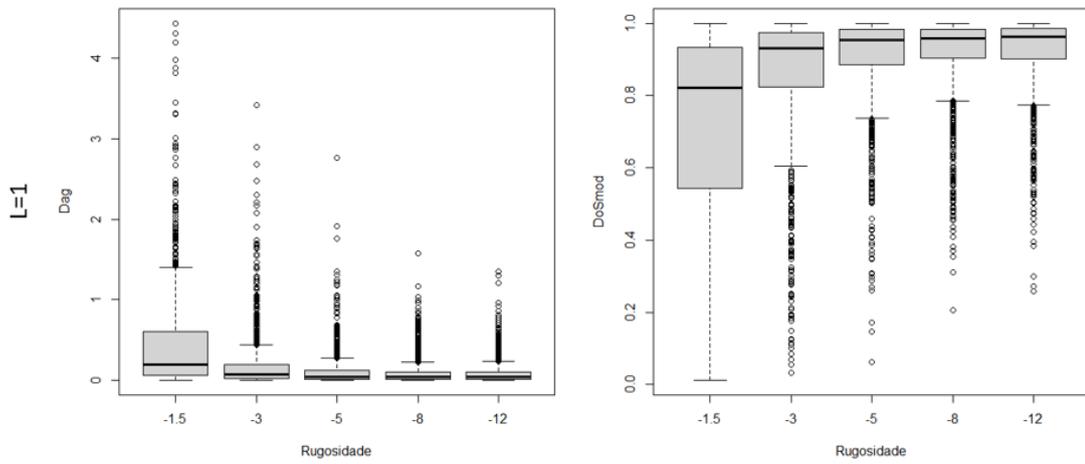
O objetivo do experimento de Monte Carlo, foi verificar a influência da variabilidade intrínseca da própria distribuição de probabilidade na DoS_{mod} . Para representar os resultados desse experimento de Monte Carlo, optamos pelo gráfico de *boxplot* do *software R* com resultados apresentados nas Figuras 7 a 10.

Podemos observar que, de maneira geral, a medida que aumentamos o número de *looks*, ambas, d_{AG} e DoS_{mod} diminuem. Ou seja, a influência do número de *looks* é nítida, evidenciando que trabalharmos com imagens SAR em intensidade com $L = 1$ é mais desafiador. Esse mesmo comportamento é observado em relação a rugosidade de regiões, os resultados mostraram que regiões menos rugosas apresentam um grau de dificuldade menor.

Um aspecto importante que foi constatado no experimento de Monte Carlo, representado nas Figuras 7 a 10, foi a influência que a variabilidade intrínseca da própria distribuição causa na d_{AG} e conseqüentemente na DoS_{mod} . Essa confirmação foi importante para ressaltarmos que o uso tanto da d_{AG} quanto da DoS_{mod} , eventualmente podem ser afetados por esse fator de confundimento.

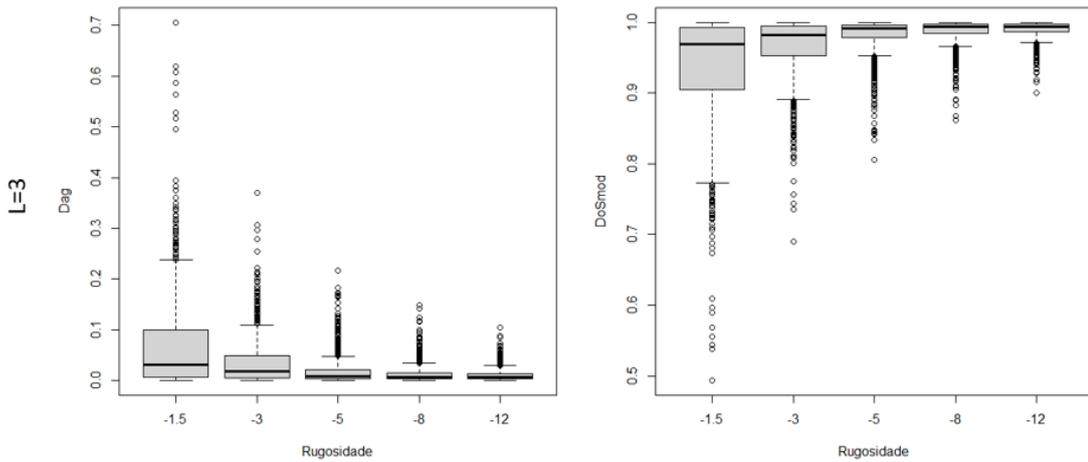
A partir dos resultados do experimento de Monte Carlo, foi possível investigar valores de limiares para DoS_{mod} que permitiram seu uso em algumas aplicações com imagens SAR, que estão apresentadas em seções posteriores. A Tabela 1 apresenta os valores médios de

Figura 7 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 1$



Fonte: elaborada pelo autor (2022).

Figura 8 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 3$



Fonte: elaborada pelo autor (2022).

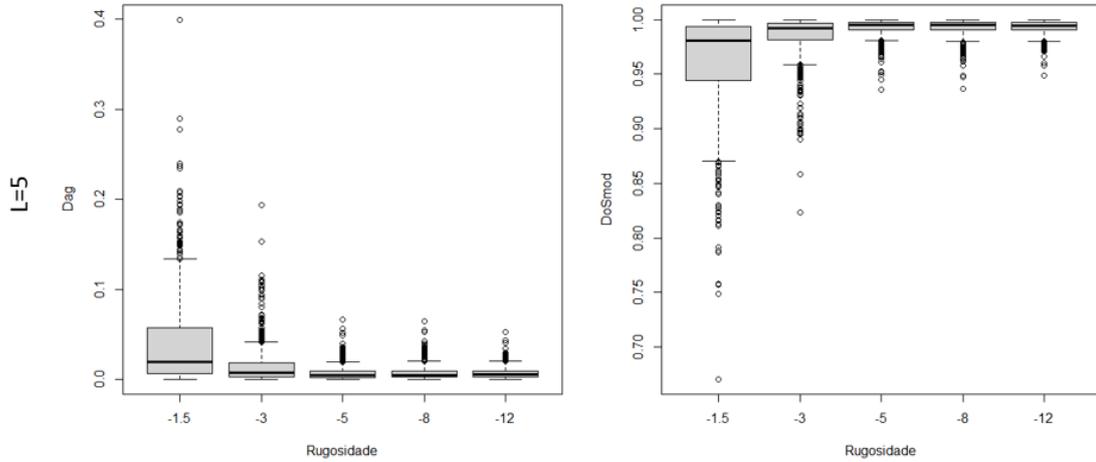
DoS_{mod} bem como os desvios padrão para cada cenário.

Tabela 1 – Valores médio e desvios padrão para DoS_{mod} advindos do experimento de Monte Carlo.

α	$L = 1$	$L = 3$	$L = 5$	$L = 8$
-1,5	(0,7292 ± 0,2645)	(0,9349 ± 0,0857)	(0,9614 ± 0,0466)	(0,9719 ± 0,0335)
-3,0	(0,8643 ± 0,1706)	(0,9664 ± 0,0414)	(0,9865 ± 0,0175)	(0,9911 ± 0,0091)
-5,0	(0,8920 ± 0,1474)	(0,9804 ± 0,0252)	(0,9924 ± 0,0082)	(0,993 ± 0,0063)
-8,0	(0,9099 ± 0,1218)	(0,9873 ± 0,0165)	(0,9931 ± 0,0063)	(0,9925 ± 0,0069)
-12,0	(0,9165 ± 0,1205)	(0,9888 ± 0,0134)	(0,9928 ± 0,0068)	(0,9935 ± 0,0056)

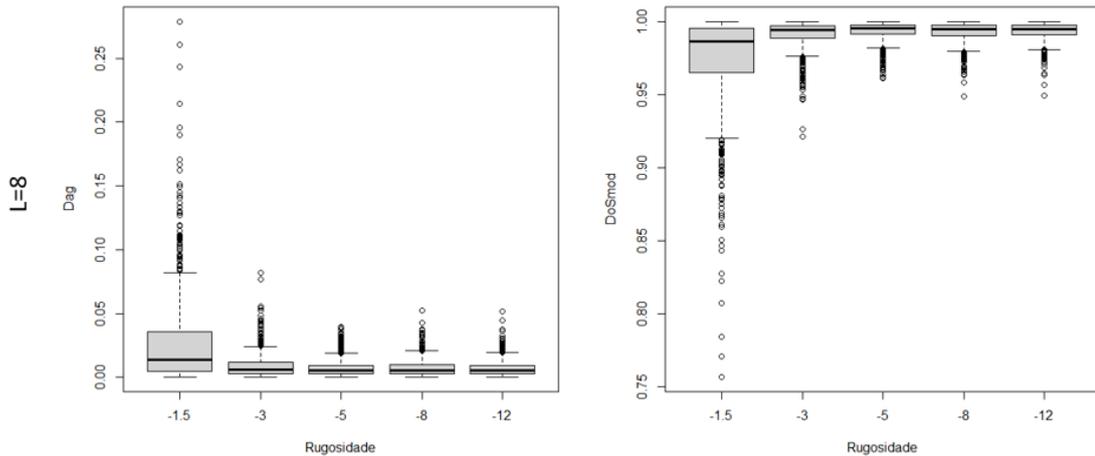
Um aspecto importante que foi observado, e que está presente na tabela 1, é que

Figura 9 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 5$



Fonte: elaborada pelo autor (2022).

Figura 10 – Resultados dos experimentos de Monte Carlo para d_{AG} e DoS_{mod} ; $L = 8$



Fonte: elaborada pelo autor (2022).

quanto maior o número de *looks* menos variação ocorre nas simulações. Isso faz com que a DoS_{mod} média se aproxime de 1 e consequentemente os desvios padrão reduzam, deixando a escolha de um limiar mais intuitiva.

Uma vez que o experimento representa uma grande gama de cenários com imagens SAR, pode-se utilizar o valor de DoS_{mod} médio para aplicações em limiarização. Por exemplo, utilizar tal valor para guiar a segmentação da matriz de DoS_{mod} .

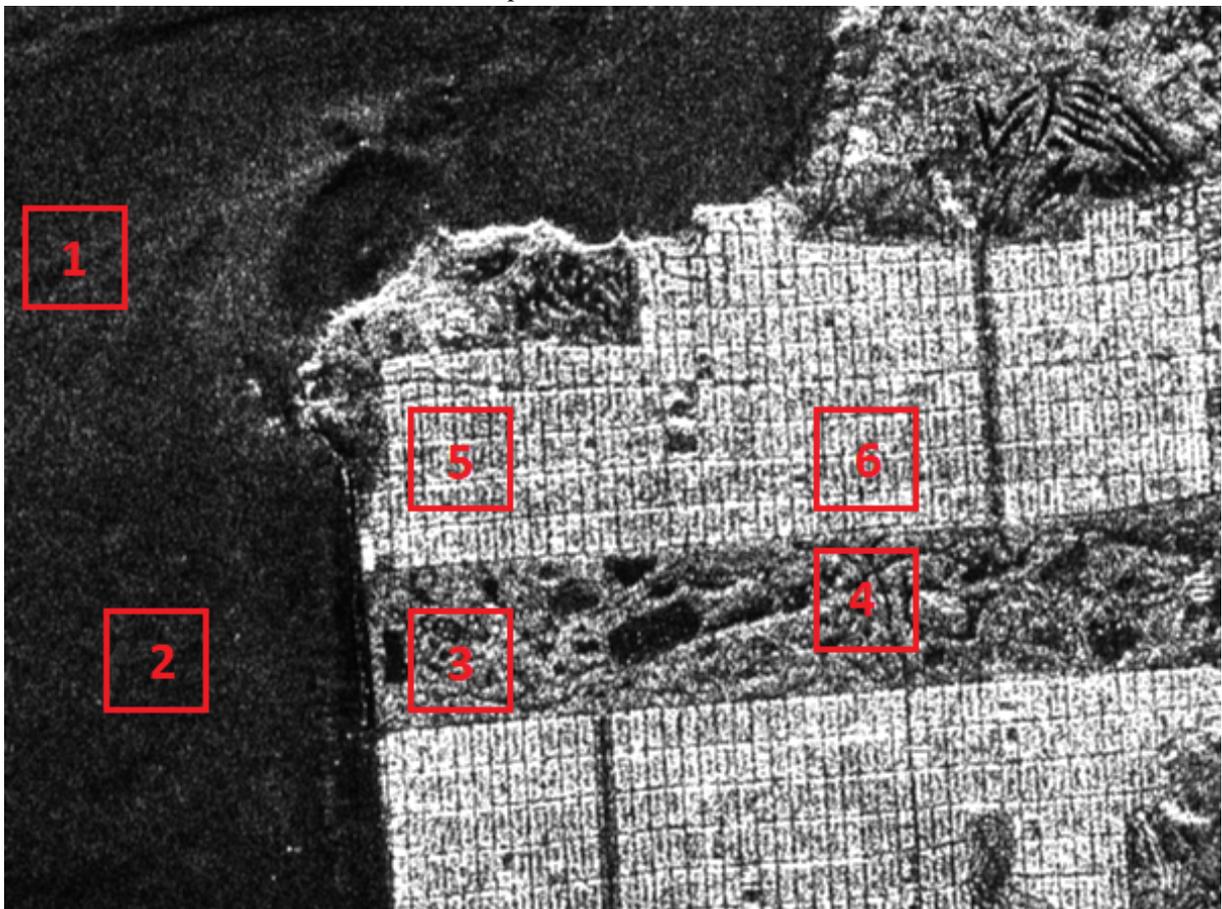
Outra aplicação possível para os valores médios constantes na Tabela 1 seria a utilização dos valores em experimentos de classificação em imagens SAR, evidenciando as regiões que possuem características iguais com a imagem sob análise.

5.2 Resultados com Imagens SAR Reais

5.2.1 Aplicação 01: Avaliação de contrastes

Para verificar a capacidade da medida de similaridade estocástica em avaliar contrastes, obtivemos recortes de uma imagem SAR real em intensidade (Figura 11) que foi obtida pelo sensor AIRSAR, canal de polarização HH com 3 looks. A imagem apresenta 3 tipos distintos de textura: i) homogênea (recortes 1 e 2, correspondentes a água); ii) heterogêneo (recortes 3 e 4, vegetação); e iii) extremamente heterogêneo (recortes 5 e 6, área urbana).

Figura 11 – Imagem Sar Real - Bahia de São Francisco (EUA), com recortes 50x50 pixels.



Fonte: elaborada pelo autor (2022).

Para cada par de recortes, foi calculada a DoS e a DoS_{mod} e seus valores estão apresentados nas tabelas 2 e 3. Esse experimento foi interessante para verificar como as medidas se comportam quando aplicadas para diferentes cenários de regiões em imagens SAR reais em intensidade. Podemos observar que os resultados para a DoS_{mod} são mais intuitivos de interpretação, já que $DoS \in (0, \infty)$ e $DoS_{mod} \in [0, 1]$. Por exemplo, para avaliarmos os contrastes

entre cada par de recortes (1 ; 2) e (1 ; 6) temos $DoS(1,2) = 4.0850$ e $DoS_{mod}(1,2) = 0.7828$, $DoS(1,6) = 0.3367$ e $DoS_{mod}(1,6) = 0.0513$, ou seja, usando a medida de similaridade estocástica fica mais evidente que o contraste entre as regiões 1 (água) e 2 (água) é bem menor que entre as regiões 1 (água) e 6 (área urbana).

Tabela 2 – Valores para a Dificuldade de Segmentação (DoS). * significa indefinição matemática.

Regions	1	2	3	4	5	6
1	*					
2	4.0850	*				
3	0.8130	0.4246	*			
4	0.9727	0.4633	0.0081	*		
5	0.3581	0.2365	5.0813	3.3761	*	
6	0.3367	0.2299	4.1408	2.8035	277.7778	*

Tabela 3 – Valores para a medida de similaridade estocástica (DoS_{mod}).

Regions	1	2	3	4	5	6
1	1.0000					
2	0.7828	1.0000				
3	0.2921	0.0949	1.0000			
4	0.3577	0.1155	0.9920	1.0000		
5	0.0612	0.0145	0.8214	0.7437	1.0000	
6	0.0513	0.0129	0.7854	0.6999	0.9963	1.0000

Vale ressaltar que, apesar de parecer uma análise simples, avaliar contrastes em imagens SAR se torna mais desafiador se for utilizada medidas de distâncias tradicionais, tais como a distância Euclidiana. Essa dificuldade se deve, principalmente, a presença do ruído speckle.

A Tabela 4 apresenta os resultados após a substituição da distância estocástica na DoS_{mod} pela distância euclidiana. É fácil perceber que essa mudança afeta bastante a análise de contraste. Por exemplo, avaliando os recortes 1 e 2 e os recortes 1 e 4, podemos observar que não fica evidente os contrastes entre água e vegetação, pois apresentou valores de 0.9965 entre as regiões 1 (água) e 2 (água) e 0,9640 entre as regiões 1 (água) e 4 (vegetação).

Tabela 4 – Valores para a medida de similaridade aplicada a Distância Euclidiana

Regions	1	2	3	4	5	6
1	1.0000					
2	0.9965	1.0000				
3	0.9542	0.9509	1.0000			
4	0.9640	0.9606	0.9899	1.0000		
5	0.8337	0.8308	0.8737	0.8649	1.0000	
6	0.8138	0.8109	0.8528	0.8442	0.9761	1.0000

5.2.2 Aplicação 02: Detecção de mudanças

Aplicando a DoS_{mod} em uma imagem SAR real multitemporal com dois cenários, o resultado é uma matriz que apresenta as diferenças que ocorreram com o passar do tempo. Denominada aqui por matriz indicadora de mudanças (MIM), essa matriz é capaz de evidenciar pequenas e grandes mudanças. Ou seja, pixels que apresentarem valores de DoS_{mod} próximos de 0 (zero), significa grandes mudanças, o contrário, pixels que apresentarem valores de DoS_{mod} próximos de 1 significa pequenas mudanças.

As Figuras 12(a) e 12(b) apresentam duas imagens SAR da mesma região, mas em momentos distintos, obtidas pelo sensor RADARSAT, com 4 *looks* e canal de polarização HH. Podemos verificar o surgimento de uma mancha de óleo, mas que não é perceptível a nível de pixels (devido ao ruído *speckle*), ver Figuras 12(c) e 12(d).

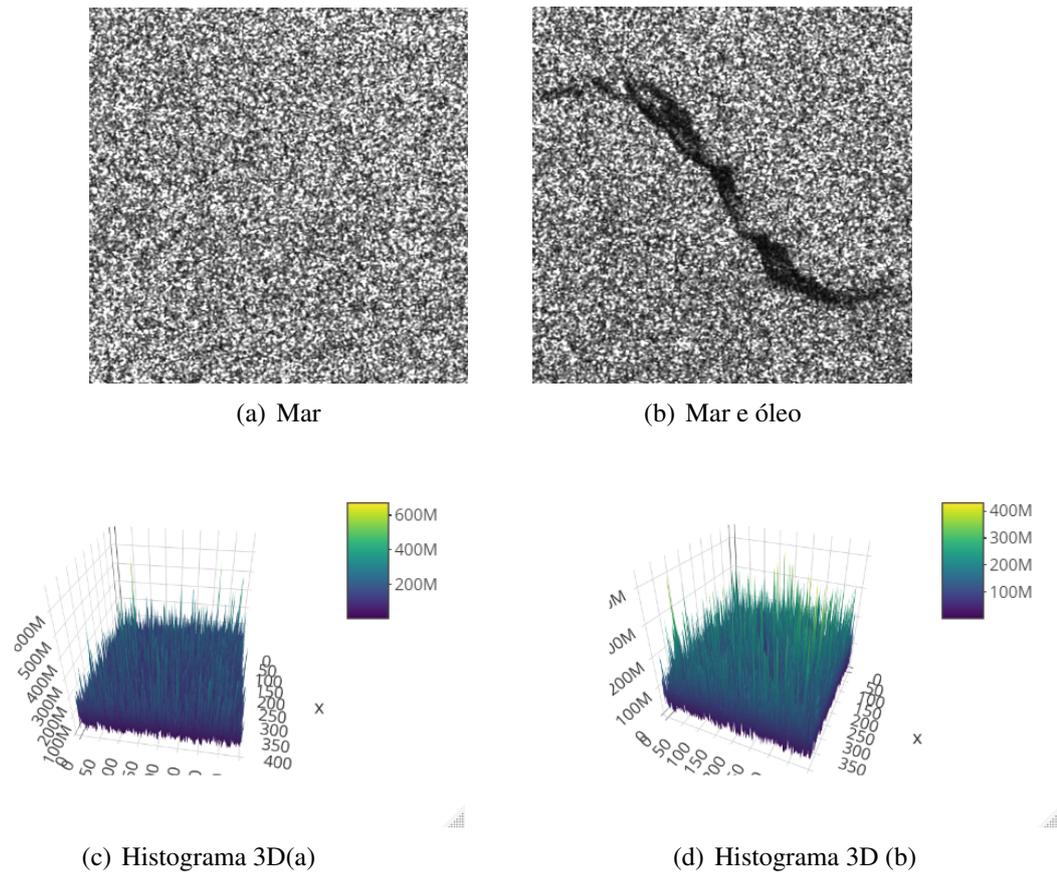
A partir do cálculo *pixel a pixel* da distância estocástica Aritmética-Geométrica entre as imagens em questão, foi possível obter a matriz de d_{AG} apresentada na Figura 13 (a). Paralelamente, foi possível obter a matriz de DoS_{mod} apresentada na Figura 13 (b), que exhibe pixels com valores iguais a $1 - DoS_{mod}$, significando que os valores mais claros mostram maiores similaridades estocástica. Podemos observar claramente a mancha de óleo em evidência (região mais clara).

Comparando os diagramas 3D das matrizes (Figuras 13 (c) e 13(d)) percebemos que a DoS_{mod} possui um maior contraste em relação à d_{AG} , isso pode ser confirmado observando-se a superfície 3D das duas imagens onde $1 - DoS_{mod}$ apresenta maiores intensidade de pixels na região onde houve a diferença de mancha de óleo quando comparado com a que não teve mudança (continuou mar no instante posterior).

Após a realização dos resultados, aferiu-se o tempo computacional consumido para

a obtenção da matriz indicadora de Mudanças. Sabe-se que esse processo demanda o tempo de cada uma das etapas presentes no fluxograma (Figura 4). Esse experimento foi realizado com o R versão 4.1.1, em uma máquina com *CPU* de 2.20 GHz com 4GB de RAM e o tempo de processamento foi de 135,5 segundos.

Figura 12 – Imagem SAR multi-temporal real.



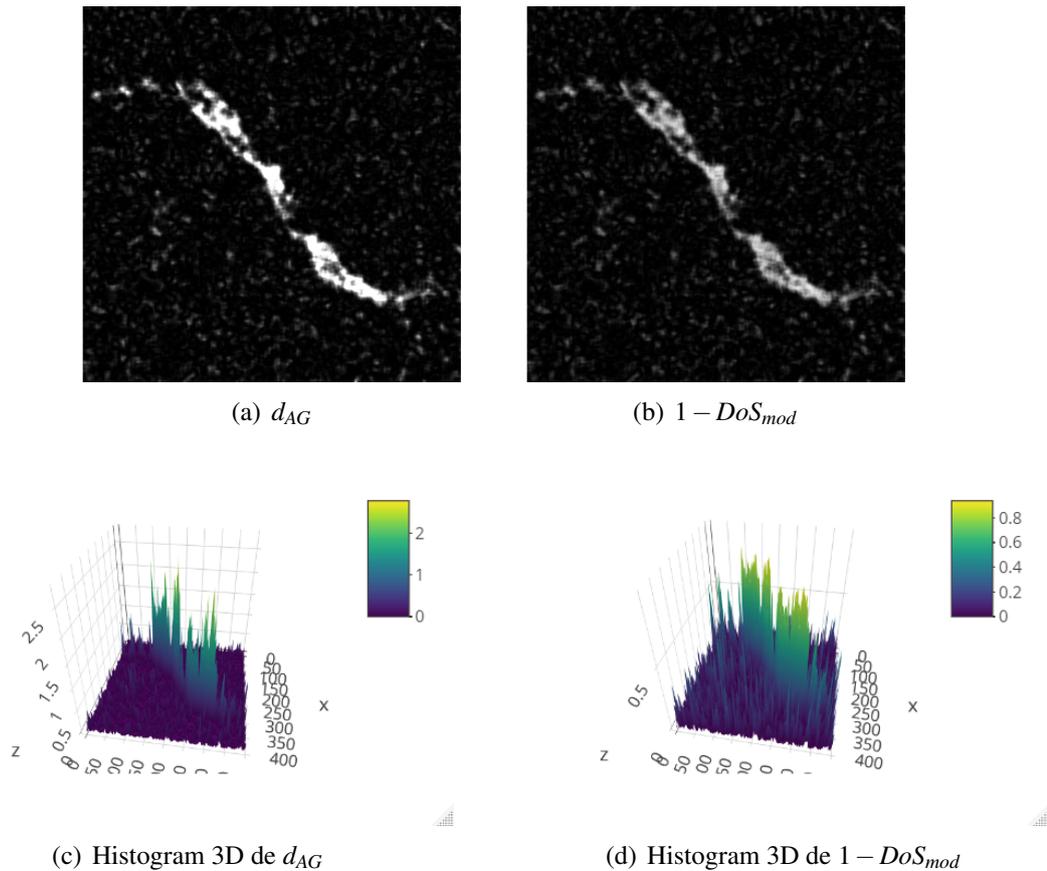
Fonte: elaborada pelo autor (2022).

Segmentamos a matriz indicadora de mudanças utilizando mais de um limiar a fim de se verificar a sensibilidade das medidas, bem como o limiar correspondente a medida de d_{AG} . O resultado mostrou que as segmentações ocorreram de forma semelhante, uma vez que DoS_{mod} é função da d_{AG} .

Os resultados, entretanto, são interessantes para observar que ao passo que se aproxima o limiar para valores próximos de 1 a segmentação tende a buscar valores de DoS_{mod} referentes a mancha de óleo no mar até chegar a uma situação onde a mancha quase desaparece, mostrando pontos onde provavelmente se tenha maiores concentrações de óleo.

A fim de comparar nossa medida realizamos o cálculo da MIM usando a Matriz de distâncias euclidianas *pixels a pixels* entre as intensidades de cada imagem. Os resultados estão

Figura 13 – Matrizes Indicadoras de Mudanças



Fonte: Elaborada pelo autor (2022).

expressos nas Figuras 16(a) 16(b) bem como os histogramas 3D das mesmas.

A partir da análise das MIM's verifica-se um baixo contraste entre as regiões analisadas, por vezes confundida como região de mar mesmo próximo à mancha de óleo. Isso pode ser confirmado a partir dos histogramas 3D (Figura 15) das imagens, os quais mostram intensidades que praticamente não variam ou se confundem, acompanhando o padrão granular de uma imagem SAR convencional.

5.2.3 Aplicação 03: Classificação supervisionada 01

A fim de verificar a eficácia da nossa medida aplicada a classificação de imagens SAR, realizamos um experimento com recortes de imagens do radar de abertura sintética ALOS PALSAR com polarização HV, *single look*, da cidade de Nova Iorque. A localização e a delimitação da imagem completa da cidade mencionada está expressa na Figura 16. Três regiões com características bem definidas foram selecionadas na imagem original a fim de obter os resultados do experimento, são elas: 10 recortes de região de mar, 10 de área urbana e 10 de

vegetação. Os mesmos estão apresentadas na Figura 17.

Para se classificar os recortes, foi selecionado um recorte de imagem de água dentre as dez da Figura 17 (a) a fim de ser usado em todas as classificações. A ideia é verificar cada imagem dos recortes quanto a similaridade em relação à água. Uma vez que se trata de um recorte de região conhecida, pode-se, a partir da DoS_{mod} entre esse recorte de água e um que se deseja classificar, verificar a similaridade.

Para classificar os recortes, é necessário escolher um valor de limiar de DoS_{mod} para guiar a classificação das imagens. A escolha de um limiar foi guiado a partir da Tabela 1. Dessa forma, como se trata de uma imagem com características de água, ela pode ser considerada como uma região homogênea ($\alpha = -8, 0$), além disso, se trata de uma imagem *single look* ($L = 1$), logo, escolheu-se o valor de limiar igual a 0,9099.

Nesse sentido, para classificar os recortes, neste caso, utilizamos a seguinte relação:

$$Classificação = \begin{cases} \text{Região de Água se: } DoS_{mod} \geq 0,9099 \\ \text{Outra região (O.R.) se: } DoS_{mod} < 0,9099. \end{cases} \quad (5.1)$$

A Tabela 5 se refere aos resultados da classificação supervisionada para um limiar de 0,9009. Dessa maneira, mostram que o valor de DoS_{mod} conseguiu classificar corretamente todas os 30 recortes (taxa de acerto igual a 100%) de imagens SAR usando o limiar de classificação obtido nas simulações que tem características de água.

Tabela 5 – Classificação Supervisionada usando DoS_{mod} . Limiar Igual a 0,9009.

Regiões Analisadas	Recorte 1	Recorte 2	Recorte 3	Recorte 4	Recorte 5	Recorte 6	Recorte 7	Recorte 8	Recorte 9	Recorte 10
DoS_{mod} entre IC e Recortes de água	1,0000	0,9374	0,9525	0,9488	0,9999	0,9162	0,9999	0,9410	0,9360	1,0000
Classificação	Água									
DoS_{mod} entre IC e recortes de Vegetação	0,0276	0,0312	0,0254	0,0291	0,0318	0,0214	0,0234	0,0263	0,0258	0,0254
Classificação	O.R.									
DoS_{mod} entre IC e recortes de Área Urbana	0,0002	0,0003	0,0004	0,0003	0,0005	0,0005	0,0003	0,0010	0,0009	0,0020
Classificação	O.R.									

Um aspecto importante, que vale ser ressaltado, é que a depender da escolha do limiar, a classificação se torna mais ou menos exigente. Por exemplo, usando um limiar próximo de 1, os recortes que serão classificados terão características muito semelhantes a classe controle. Em outras palavras o classificador se torna mais sensível a pequenas mudanças.

A fim de verificar essa sensibilidade, usando a Tabela 6, escolhemos um valor de limiar para DoS_{mod} próximo de 1. Nesse sentido, escolhemos o valor de 0,9930, correspondente

a $L = 8$ e $\alpha = -5,0$ (Tabela 1). A relação a seguir foi aplicada para classificar os recortes a partir do recorte de água.

$$Classificação = \begin{cases} \text{Região de Água se: } DoS_{mod} \geq 0,9930 \\ \text{Outra região (O.R.) se: } DoS_{mod} < 0,9930. \end{cases} \quad (5.2)$$

Tabela 6 – Classificação Supervisionada usando DoS_{mod} . Limiar Igual a 0,9930.

Regiões Analisadas	Recorte 1	Corte 2	Recorte 3	Recorte 4	Recorte 5	Recorte 6	Recorte 7	Recorte 8	Recorte 9	Recorte 10	T.A.
DoS_{mod} entre IC e Recortes de água Classificação	1,0000	0,9374	0,9525	0,9488	0,9999	0,9162	0,9999	0,9410	0,9360	1,0000	-
	Água	O.R.	O.R.	O.R.	Água	O.R.	Água	O.R.	O.R.	Água	40%
DoS_{mod} entre IC e recortes de Vegetação Classificação	0,0276	0,0312	0,0254	0,0291	0,0318	0,0214	0,0234	0,0263	0,0258	0,0254	-
	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	100%
DoS_{mod} entre IC e recortes de Área Urbana Classificação	0,0002	0,0003	0,0004	0,0003	0,0005	0,0005	0,0003	0,0010	0,0009	0,0020	-
	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	O.R.	100%

Os resultados da Tabela 6 mostram que quando se aumenta o limiar deixa-se mais exigente a classificação dos recortes como água, reduzindo a taxa e acerto para 40%.

Por fim, aplicamos a metodologia para classificação supervisionada 01 usando como medida de similaridade a distância Euclidiana para comparar comparação com os resultados da medida proposta. Ou seja,

$$DoS_{modeuclid.} = 1 / \exp(d_{euclid.}) \quad (5.3)$$

A classificação será feita conforme a equação 5.4.

$$Classificação = \begin{cases} \text{Região de Água se: } DoS_{modeuclid.} \geq 0,9930 \\ \text{Outra região (O.R.) se: } DoS_{modeuclid.} < 0,9930. \end{cases} \quad (5.4)$$

Os resultados com essa medida está apresentado na Tabela 7. Mesmo com Taxas de acerto próximas, a análise e comparação com os resultados da DoS_{mod} utilizando d_{AG} revela que a distância Euclidiana dificulta a confiabilidade da classificação uma vez que apresenta valores que extrapolam os limites classificatórios. Isso pode ser percebido, por exemplo, por meio de valores de DoS_{mod} iguais a 0,9999 ou muito próximos de 1 com imagens do mesmo tipo de região (água). Fato contraditório, uma vez que as regiões mesmo com características diferentes ainda apresentam características diferentes, como direções de ondas do mar e coloração da água por exemplo.

Tabela 7 – Classificação Supervisionada usando $DoS_{mod\ euclid.}$ Limiar Igual a 0,9930.

Regiões Analisadas	Recorte 1	Recorte 2	Recorte 3	Recorte 4	Recorte 5	Recorte 6	Recorte 7	Recorte 8	Recorte 9	Recorte 10	T.A.
DoS_{mod} entre IC e Recortes de água	1,0000	0,9999	0,9999	0,9999	0,9998	0,9999	0,9999	0,9999	0,9999	0,9999	-
Classificação	Água	Água	Água	Água	100%						
DoS_{mod} entre IC e recortes de Vegetação	$1,7353 \times 10^{-64}$	$3,1314 \times 10^{-15}$	$1,2910 \times 10^{-11}$	$5,5104 \times 10^{-07}$	$1,1113 \times 10^{-48}$	$1,7453 \times 10^{-13}$	$5,1333 \times 10^{-08}$	0,0019	0,0016	0,0052	-
Classificação	O.R.	O.R.	O.R.	O.R.	100%						
DoS_{mod} entre IC e recortes de Área Urbana	0,9131	0,8917	0,3531	0,7709	0,8518	0,7122	0,8051	0,8147	0,8422	0,8107	-
Classificação	O.R.	O.R.	O.R.	O.R.	100%						

A mesma ainda apresentou valores próximos a 1 quando analisados com as regiões de água e vegetação, apresentando classificações altas para regiões com características muito diferentes que a depender de um limiar menos exigente seria classificado como de água, para o experimento em questão.

5.2.4 Aplicação 04: Classificação supervisionada 02

Aplicando a classificação supervisionada 02, metodologia apresentada no fluxograma da Figura 6, obtivemos os resultados expostos na Tabela 8. Os maiores valores de DoS_{mod} em cada situação estão destacados na Tabela 8.

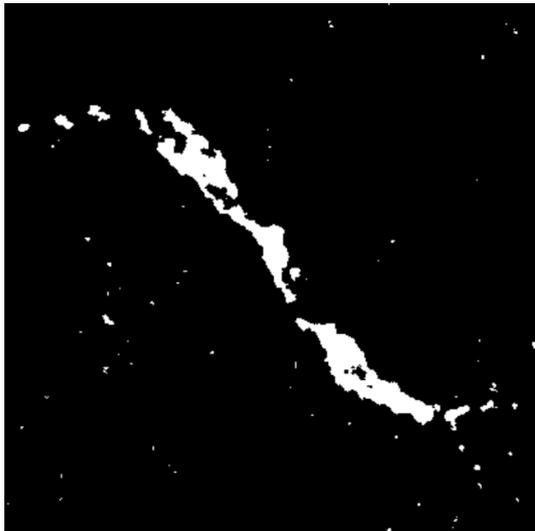
Tabela 8 – Classificação Supervisionada usando DoS_{mod} .

Regiões Analisadas	IC	Corte 1	Corte 2	Recorte 3	Recorte 4	Recorte 5	Recorte 6	Recorte 7	Recorte 8	Recorte 9	Recorte 10	T.A.
DoS_{mod} entre IC e Recortes de água	Água	1,0000	0,9461	0,9588	1,0000	0,9471	0,9490	0,9449	1,0000	0,9585	0,9320	100%
	Área Urbana	0,0003	0,1020	0,0909	0,0044	0,0000	0,0000	0,0000	0,0042	0,9064	0,1149	
	Vegetação	0,0362	0,0000	0,3371	0,0938	0,3694	0,3543	0,3749	0,0968	0,3414	0,0000	
DoS_{mod} entre IC e Recortes de Área Urbana	Água	0,0003	0,0007	0,0002	0,0004	0,0022	0,0040	0,0023	0,0008	0,0009	0,0055	
	Área Urbana	1,0000	0,8337	0,9838	0,7512	0,8235	0,6528	0,8334	0,8491	0,9825	0,9966	100%
	Vegetação	0,0269	0,0345	0,0143	0,0140	0,1065	0,4930	0,0573	0,0378	0,0636	0,0397	
DoS_{mod} entre IC e Recortes de vegetação	Água	0,0363	0,0435	0,0372	0,0389	0,0408	0,0402	0,0447	0,0333	0,0329	0,0499	
	Área Urbana	0,0269	0,5830	0,5891	0,2887	0,5852	0,5884	0,5844	0,2382	0,4776	0,5686	
	Vegetação	1,0000	0,8124	0,8160	0,9766	0,8132	0,8100	0,8022	0,9779	0,9213	0,8216	100%

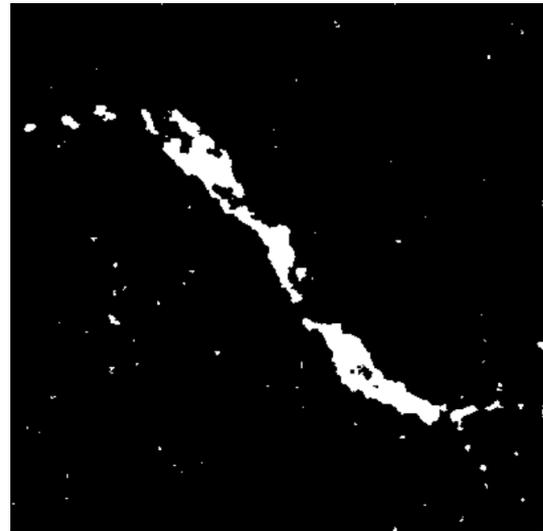
Em termos de taxa de acerto, com esta metodologia, foi classificado corretamente todos os dez recortes para todas as regiões de imagens adotadas, ou seja taxa de acerto de 100% em todas as observações.

Esses resultados evidenciam que a medida de similaridade proposta possui um potencial alto e preciso em termos de classificação supervisionada para imagens SAR reais.

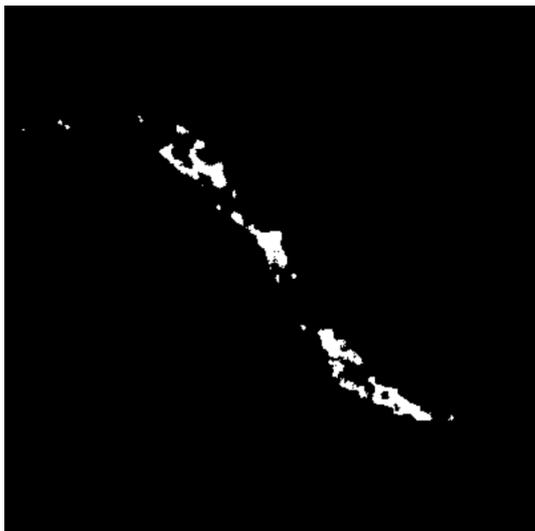
Figura 14 – Segmentação da MIM usando DoS_{mod} à esquerda e d_{AG} à direita com diferentes limiares de segmentação para DoS_{mod} e seu correspondente d_{AG} .



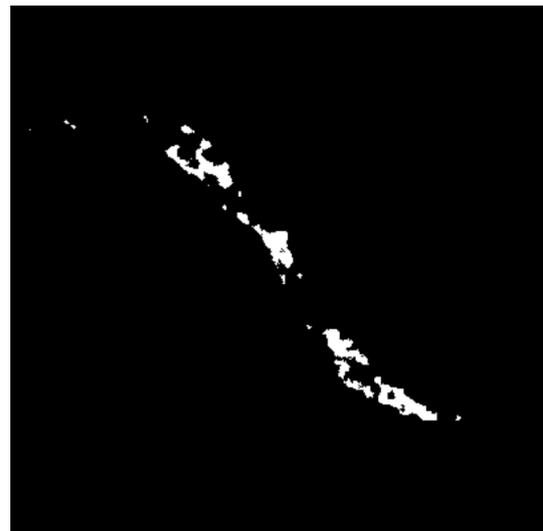
(a) $1-DoS_{mod}$, limiar 0.3



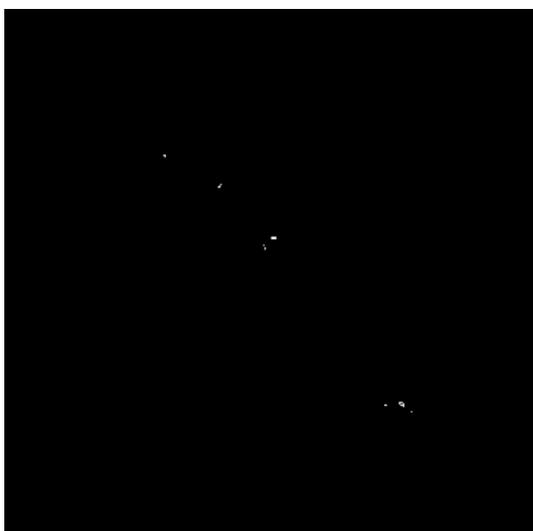
(b) d_{ag} , limiar 0.35



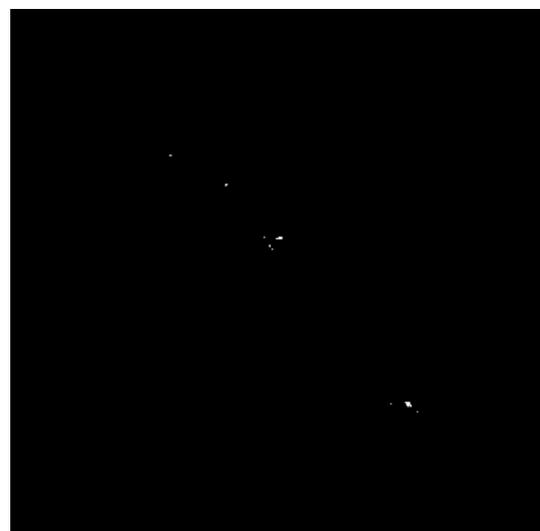
(c) $1-DoS_{mod}$, limiar 0.6



(d) d_{ag} , limiar 0.92

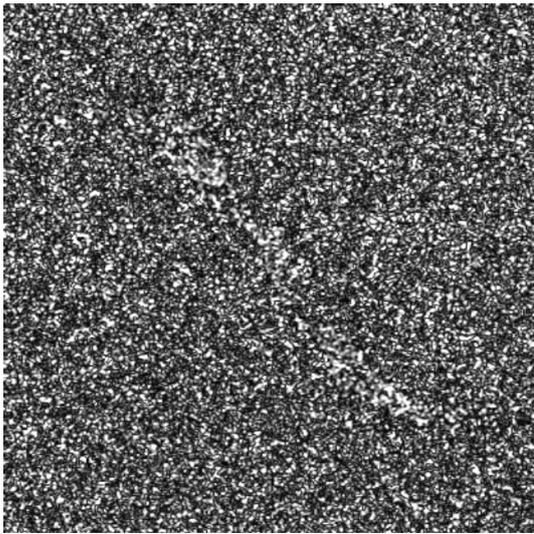


(e) $1-DoS_{mod}$, limiar 0.9

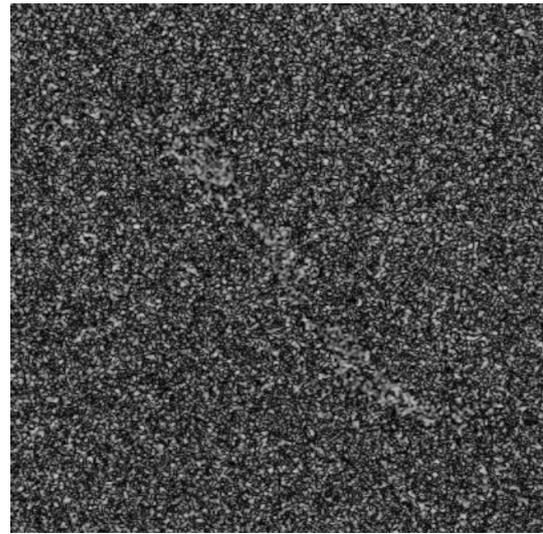


(f) d_{ag} , limiar 2.3

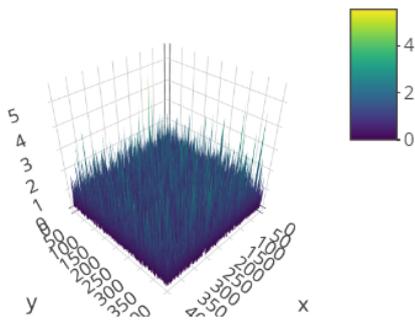
Figura 15 – Matrizes Indicadoras de Mudanças - Distância Euclidiana



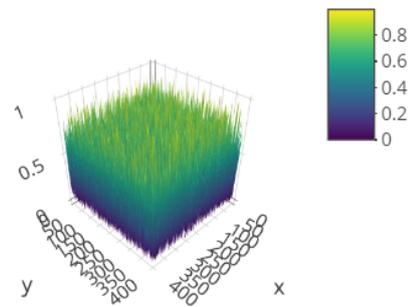
(a) $d_{euclidiana}$



(b) $1 - DoS_{modeuclid}$.



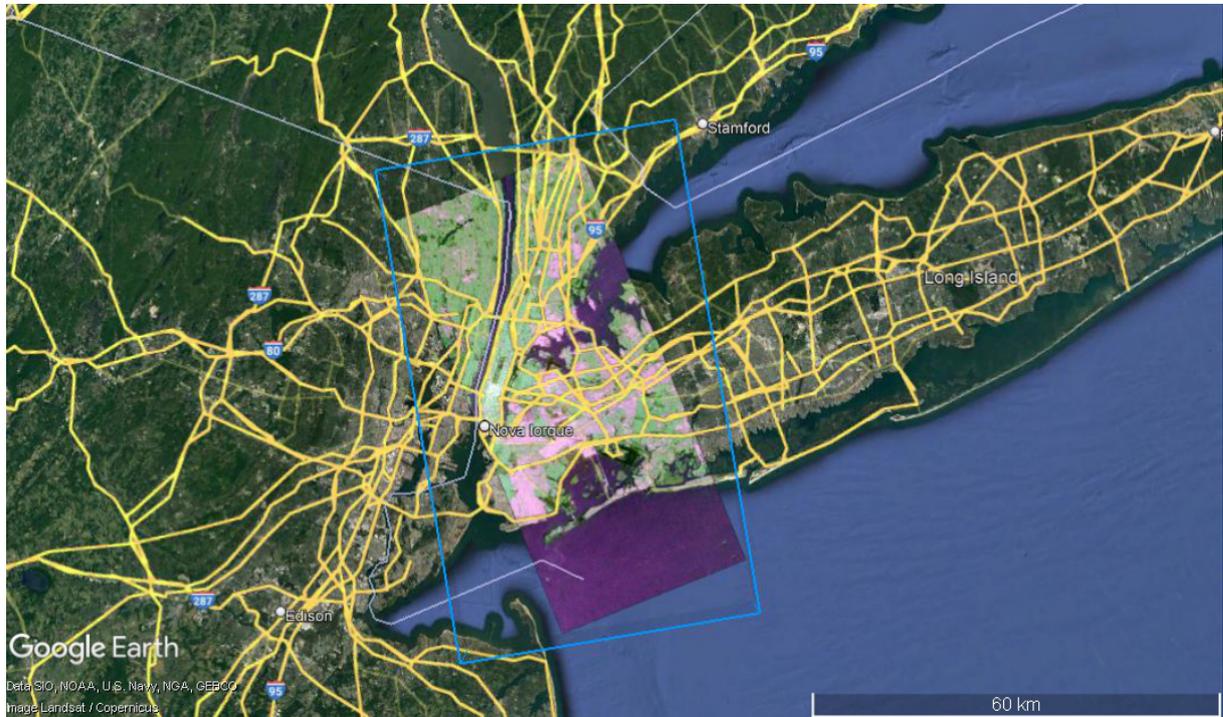
(c) Histogram 3D de d_{euclid} .



(d) Histogram 3D de $1 - DoS_{modeuclid}$.

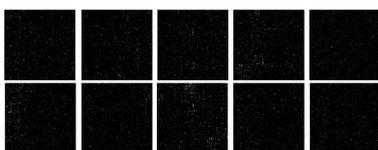
Fonte: Elaborada pelo autor (2022).

Figura 16 – Localização da Imagem SAR real completa da cidade de Nova Iorque.

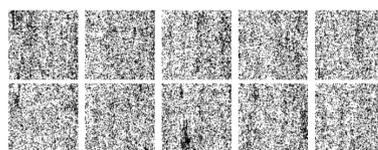


Fonte: Google. Acesso em Outubro de 2021.

Figura 17 – Recortes (100x100) de imagens SAR da Cidade de Nova Iorque, Canal HV, $L = 1$.



(a) 10 Recortes de água



(b) 10 Recortes de vegetação



(c) 10 Recortes de área urbana

Fonte: ALOS-PALSAR.

6 CONCLUSÕES

Neste trabalho, apresentamos uma medida de similaridade estocástica, denominada DoS_{mod} , com resultados promissores para uso em processamentos de imagens SAR. A proposta foi utilizada com resultados satisfatórios em 1 aplicação com imagens SAR simuladas e 3 aplicações com imagens SAR reais.

Os experimentos com imagens SAR simuladas revelaram que a DoS_{mod} é sensível a pequenas flutuações aleatórias, principalmente para imagens SAR *single look* que tenham características de regiões extremamente heterogênea. Essa interferência, eventualmente, pode resultar, por exemplo, em classificações erradas. Por outro lado, essa situação pode ser contornada em parte se utilizarmos valores de DoS_{mod} próximos de 1.

Em relação à avaliação de contrastes, foi possível analisar a capacidade da DoS_{mod} quanto ao quesito proposto. Constatamos, todavia, que a medida de similaridade proposta conseguir distinguir bem contrastes entre regiões com diferentes características entre si. Além disso a medida apresentada possui a vantagem de apresentar um intervalo de variação que facilita a análise de contraste.

Os resultados de DoS_{mod} para a detecção de mudanças mostraram que a matriz indicadora de mudanças, utilizando DoS_{mod} em cada *pixel*, apresentou ganhos em termos de contraste entre regiões que apresentaram mudanças significativas entre os cenários propostos. Além do mais, graças as características de variação da medida é possível setar um limiar para segmentar regiões que apresentaram mudanças entre cenários, entretanto, tal aplicação necessita de mais estudos para ser escolhido um limiar de forma mais racional.

A medida de similaridade apresentou resultados satisfatórios em termos de classificação supervisionada, com taxas de acerto máximas com a metodologia 02 desse estudo. Logo, a medida é uma boa alternativa para a proposta de classificação supervisionada, uma vez que os resultados envolveram situações entre regiões bastante diferentes que envolveram cenários reais da superfície da terra.

6.1 Trabalhos futuros

A partir da pesquisa desenvolvida nessa dissertação, outras aplicações podem ser feitas com a DoS_{mod} a fim de monitorar processos dinâmicos na Terra, a seguir cita-se algumas:

- Estudos mais aprofundados na escolha do limiar de segmentação para a DoS_{mod} ;

- Medir a intensidade e extensão da evolução de impactos ambientais;
- Quantificação e monitoramento do desmatamento da floresta amazônica;
- Localização de destroços de embarcações e aviões perdidos no mar.

Estudos mais aprofundados na classificação de imagens SAR podem ser empreendidos a fim de ratificar o poder que a DoS_{mod} tem em classificar processos dinâmicos da superfície da terra.

REFERÊNCIAS

- 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.
- BRASIL. Lei nº 9.433, de 8 de janeiro de 1997. institui a política nacional de recursos hídricos, cria o sistema nacional de gerenciamento de recursos hídricos, regulamenta o inciso xix do art. 21 da constituição federal, e altera o art. 1º da lei nº 8.001, de 13 de março de 1990, que modificou a lei nº 7.990, de 28 de dezembro de 1989. **Diário Oficial da União**, p. 470–470, 1997.
- 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.
- FRERY, A. C.; CRIBARI-NETO, F.; SOUZA, M. O. D. Analysis of minute features in speckled imagery with maximum likelihood estimation. **EURASIP Journal on Advances in Signal Processing**, Springer, v. 2004, n. 16, p. 375370, 2004.
- FRERY, 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.
- 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.
- IVANOV, A. Y.; ERMOSHKIN, I. S. Mapping oil spills in the caspian sea using ers-1/ers-2 sar image quick-looks and gis. **Gayana (Concepción)**, Universidad de Concepción. Facultad de Ciencias Naturales y Oceanográficas., v. 68, n. 2, p. 297–304, 2004.
- 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.
- JESUS, J. B. d.; KUPLICH, T. M. Applications of sar data to estimate forest biophysical variables in brazil. **Cerne**, SciELO Brasil, v. 26, n. 1, p. 88–97, 2020.
- KASISCHKE, E. S.; MELACK, J. M.; DOBSON, M. C. The use of imaging radars for ecological applications—a review. **Remote sensing of environment**, Elsevier, v. 59, n. 2, p. 141–156, 1997.
- 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.

- LEE, J.-S.; POTTIER, E. **Polarimetric radar imaging: from basics to applications**. [S.l.]: CRC press, 2009.
- LUCINI, B. O. H.; MAGDALENA, M.; ALEJANDRO, C. F. M-estimators of roughness and scale for g_0 a-modelled sar imagery. **EURASIP Journal on Applied Signal Processing**, 2002.
- MARQUES, R. C. P. **Caracterização de regiões em imagens da radar de abertura sintética com aplicações por segmentação por Level Set**. Tese (Doutorado) — Federal University of Ceará, 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.
- MOREIRA, A.; PRATS-IRAOLA, P.; YOUNIS, M.; KRIEGER, G.; HAJNSEK, I.; PAPANASSIOU, K. P. A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, IEEE, v. 1, n. 1, p. 6–43, 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.
- NGO, K. D.; LECHNER, A. M.; VU, T. T. Land cover mapping of the mekong delta to support natural resource management with multi-temporal sentinel-1a synthetic aperture radar imagery. **Remote Sensing Applications: Society and Environment**, Elsevier, v. 17, p. 100272, 2020.
- 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.
- ONU. Objetivos de desenvolvimento sustentável. c2021.
- PERUZZO, J. S.; PEREIRA, M. C. dos S.; SILVA, L. D. R. da; OLIVEIRA, B. S. de; SILVINO, G. da S. Sensoriamento remoto aplicado ao monitoramento ambiental da bacia do alto piranhas, semiárido nordestino (brasil). **Revista Brasileira de Meio Ambiente**, v. 7, n. 3, 2019.
- RODRIGUES, F. A. Á. **Método de log-cumulantes em processamento de imagens SAR**. Tese (Doutorado) — Federal University of Ceará, Fortaleza, Brazil, 2017.
- RODRIGUES, F. A. Á. Método de log-cumulantes em processamento de imagens sar. 2017.
- SANTOS, V. dos; POLIDORI, L.; SILVEIRA, O.; JR., A. 3 1 , 2 , 4. **Brazilian Journal of Geophysics**, v. 27, p. 39–55, 2009.
- 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.
- 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.

WATER, U. Status report on the application of integrated approaches to water resources management. **United Nations Environment Programme: Nairobi, Kenya, 2012.**