



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

**ALCILENE DALÍLIA DE SOUSA**

**ABORDAGEM ESTOCÁSTICA PARA RECUPERAÇÃO DE IMAGENS SAR BASEADA  
EM CONTEÚDO**

**FORTALEZA**

**2023**

ALCILENE DALÍLIA DE SOUSA

ABORDAGEM ESTOCÁSTICA PARA RECUPERAÇÃO DE IMAGENS SAR BASEADA  
EM CONTEÚDO

Tese apresentada ao 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<sup>ª</sup>. Dr<sup>ª</sup>. Fátima N. Sombra de Medeiros.

Coorientador: Prof. Dr. Francisco Alixandre Àvila Rodrigues.

FORTALEZA

2023

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

---

S696a Sousa, Alcilene Dalília de.  
Abordagem estocástica para recuperação de imagens SAR baseada em conteúdo / Alcilene Dalília de Sousa. – 2023.  
59 f. : il.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2023.

Orientação: Profa. Dra. Fátima Nelsizeuma Sombra de Medeiros.

Coorientação: Prof. Dr. Francisco Alixandre Ávila Rodrigues.

1. Imagens SAR . 2. CBIR. 3. Distância Estocástica. 4. Método Rápido de Log-Cumulantes. 5. Método de Máxima Verossimilhança. I. Título.

CDD 621.38

---

ALCILENE DALÍLIA DE SOUSA

ABORDAGEM ESTOCÁSTICA PARA RECUPERAÇÃO DE IMAGENS SAR BASEADA  
EM CONTEÚDO

Tese apresentada ao 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: 31/07/2023.

BANCA EXAMINADORA

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Fátima N. Sombra de  
Medeiros (Orientadora)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Antonio Oséas de Carvalho Filho  
Universidade Federal do Piauí (UFPI)

---

Prof. Dr. Régis Cristiano Pinheiro Marques  
Instituto Federal do Ceará (IFCE)

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Regina Célia Coelho  
Universidade Federal de São Paulo (UNIFESP)

---

Prof. Dr. Pedro Pedrosa Rebouças Filho  
Universidade Federal do Ceará (UFC)

Dedico este trabalho à minha família, pelo apoio e compreensão durante esta jornada e pelas horas roubadas do convívio com todos.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, pelo dom da vida, força, coragem e discernimento que me deu ao longo desta pesquisa. Ao meu esposo, Killson Silva, por todo apoio e compreensão. Agradeço aos meus pais, Dalília Maria da Luz e Adauto Antonio de Sousa, por me apoiarem em todos os momentos da minha vida. À minha irmã Alcileide Dalília por estar sempre comigo. E a todos da minha família que torcem e vibram com cada conquista em nome de vó Maria, Daliete, Marlete, Beatriz, Stella, Tadeuza e Alcenor.

À minha orientadora, Fátima Medeiros, por toda atenção, dedicação e aprendizado que recebi durante este período. Ao meu coorientador, Francisco Alixandre Àvila Rodrigues por me acolher e contribuir com todo o processo.

Aos meus amigos do LABVIS em especial Alan Braga, Brígida Oliveira, Daniel Silva, Deborah Maria, Elizângela Rebouças, Flávio Henrique, José Gerardo, Pedro Henrique, Raphael Pinheiro e Romuere Rodrigues.

Ao PPGETI pela oportunidade de participar deste doutorado e à Universidade Federal do Piauí (UFPI) por ter me liberado para capacitação.

Aos demais amigos Antonio Filho, Ítalo Linhares, Thalisson Oliveira, Lilian Rosalina, Aislan Rafael, Aline do Monte, Nonato Rodrigues, Lucas Sousa, Rayner Gomes, Juliana Oliveira, Leonel Caminha, Lucy Eulália, Railene Alencar, Nilda Ramos, Carminete Rodrigues, Janaína Luz e Maria do Rosário.

À FAPEPI pelo apoio financeiro no final do doutorado.

"O Senhor é o meu pastor e nada me faltará."  
(Salmos, 23:1.)

## RESUMO

Esta tese propõe um sistema de recuperação de imagens baseada em conteúdo (CBIR, do inglês *Content-Based Image Retrieval*) usando distância estocástica para imagens de radar de abertura sintética (SAR, do inglês *Synthetic Aperture Radar*). A metodologia considera a utilização da distribuição  $G_I^0$  para descrever dados SAR em intensidade. Baseada nessa premissa, foram estabelecidas três etapas essenciais para a recuperação de imagens SAR bem como a avaliação dos resultados: i) Estimação dos parâmetros de rugosidade ( $\alpha$ ) e escala ( $\gamma$ ) da distribuição  $G_I^0$ , ou seja, etapa de extração de características das imagens. Para estimar os parâmetros foram testados dois métodos de estimação, o de máxima verossimilhança e uma abordagem rápida do método de log-cumulantes; ii) Utilização da distância estocástica triangular como medida de similaridade. O método avalia a semelhança entre uma imagem de consulta e as demais imagens no banco de dados para fazer a recuperação. A distância estocástica identifica as regiões mais semelhantes conforme as características da imagem que são os parâmetros estimados do modelo de dados; iii) Avaliação da nossa proposta aplicando a medida *Mean Average Precision* (MAP) e considerando recortes de uma imagem de cada sensor de radar, ou seja, UAVSAR, OrbiSAR-2 e ALOS PALSAR. Os resultados com o método CBIR-SAR foram obtidos para imagens sintéticas que alcançaram o maior valor de MAP, recuperando regiões extremamente heterogêneas. Com as imagens SAR reais, o método CBIR-SAR obteve valores de MAP acima de 0,833, para todos os canais de polarização, para amostras de imagens de floresta (UAVSAR) e áreas urbanas (ORBISAR). Nossos resultados confirmaram que o método proposto é sensível à textura presente na imagem e, portanto, depende da qualidade da estimativa dos parâmetros que são entradas na distância estocástica para realização da recuperação efetiva da imagem.

**Palavras-chave:** imagens sar; cbir; distância estocástica; método rápido de log-cumulantes; método de máxima verossimilhança.

## ABSTRACT

This thesis proposes a Content-Based Image Retrieval (CBIR) system using stochastic distance for Synthetic Aperture Radar (SAR) images. The methodology considers the  $G_I^0$  distribution to describe *Synthetic-Aperture Radar* (SAR) data in intensity. Based on this premise, three essential steps were established to retrieve SAR images as well as to evaluate the results: i) Estimation of the roughness ( $\alpha$ ) and scale ( $\gamma$ ) parameters of the distribution  $G_I^0$ , i.e., the image feature extraction step. To estimate the parameters, two estimation methods were tested: the maximum likelihood and a fast approach of the log-cumulant method; ii) The use of the triangular stochastic distance as a similarity measure. The method evaluates the similarity between a query image and the other images in the database to perform the content-based image retrieval. The stochastic distance identifies the most similar regions according to the image characteristics that are the estimated parameters of the data model; iii) Evaluation of our proposal applying the MAP measure and considering clippings of an image from each radar sensor, that is, UAVSAR, OrbiSAR-2 and ALOS PALSAR. The results with the CBIR-SAR method were obtained for synthetic images that achieved the highest MAP value, recovering extremely heterogeneous regions. Using real SAR images, the CBIR-SAR method obtained MAP values above 0.833, for all polarization channels for forest image samples (UAVSAR) and urban areas (ORBISAR). Our results confirmed that the proposed method is sensitive to the texture present in the image and, and thus it relies on the quality of the estimated parameters that are inputs of the stochastic distance to perform the effective image retrieval.

**Keywords:** image sar; cbir; stochastic distance; fast log-cumulants method; maximum likelihood method.

## LISTA DE TABELAS

Tabela 1 – Bandas de frequência utilizadas em sistemas SAR e suas faixas correspondentes de frequência e comprimento de onda. . . . .	14
Tabela 2 – Informações do Radar UAVSAR. . . . .	34
Tabela 3 – Informações do Radar OrbiSAR-2. . . . .	34
Tabela 4 – Informações do Radar ALOS PALSAR. . . . .	34
Tabela 5 – Resultados MAP com a distância triangular para imagens sintéticas e ambos os estimadores. . . . .	37
Tabela 6 – Resultados MAP com a distância aritmética geométrica para imagens sintéticas e ambos os estimadores. . . . .	38
Tabela 7 – Resultados MAP com a distância Hellinger para imagens sintéticas e ambos os estimadores. . . . .	38
Tabela 8 – Resultados MAP com a distância média harmônica para imagens sintéticas e ambos os estimadores. . . . .	38
Tabela 9 – MAP usando a distância triangular, <i>MLE</i> e <i>FLCM</i> na base UAVSAR. . . . .	40
Tabela 10 – MAP usando a distância triangular, <i>MLE</i> e <i>FLCM</i> na base ORBISAR-2. . . . .	40
Tabela 11 – MAP usando a distância triangular, <i>MLE</i> e <i>FLCM</i> na base ALOS PALSAR. . . . .	40

## LISTA DE ABREVIATURAS E SIGLAS

CBIR	<i>Content-Based Image Retrieval</i>
FLCM	<i>Fast Log-Cumulants Method</i>
FN	Falso Negativo
HH	Polarização Horizontal
HV	Polarização Cruzada Horizontal/Vertical
MAP	<i>Mean Average Precision</i>
MLE	<i>Maximum Likelihood Estimation</i>
SAR	<i>Synthetic-Aperture Radar</i>
VH	Polarização Cruzada Vertical/Horizontal
VP	Verdadeiro Positivo
VV	Polarização Vertical

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>1.1</b>	<b>Objetivos</b>	<b>12</b>
<b>1.2</b>	<b>Produção Científica</b>	<b>13</b>
<b>1.3</b>	<b>Organização da Tese</b>	<b>13</b>
<b>2</b>	<b>CONCEITOS DE IMAGENS SAR</b>	<b>14</b>
<b>3</b>	<b>FUNDAMENTOS ESTATÍSTICOS</b>	<b>19</b>
<b>3.1</b>	<b>Modelo Estatístico para Dados SAR em Intensidade</b>	<b>19</b>
<b>3.2</b>	<b>Estimação dos Parâmetros da Distribuição <math>G_I^0</math></b>	<b>22</b>
<b>3.2.1</b>	<i>Método de Máxima Verossimilhança</i>	<b>22</b>
<b>3.2.2</b>	<i>Método Log-Cumulantes Rápido</i>	<b>23</b>
<b>3.3</b>	<b>Distâncias Estocásticas</b>	<b>24</b>
<b>4</b>	<b>RECUPERAÇÃO DE IMAGENS BASEADA EM CONTEÚDO</b>	<b>27</b>
<b>4.1</b>	<b>Arquitetura dos Sistemas de Recuperação de Imagens Baseada em Conteúdo</b>	<b>27</b>
<b>5</b>	<b>METODOLOGIA PROPOSTA</b>	<b>31</b>
<b>5.1</b>	<b>Base de Dados SAR Sintéticos</b>	<b>32</b>
<b>5.2</b>	<b>Base de Dados SAR Reais</b>	<b>33</b>
<b>5.3</b>	<b>Extração de Características</b>	<b>35</b>
<b>5.4</b>	<b>Sistema CBIR-SAR</b>	<b>35</b>
<b>5.5</b>	<b>Métrica de Avaliação dos Resultados</b>	<b>35</b>
<b>6</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>37</b>
<b>6.1</b>	<b>Experimentos com Imagens SAR Sintéticas</b>	<b>37</b>
<b>6.2</b>	<b>Experimentos com Imagens SAR Reais</b>	<b>39</b>
<b>7</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>42</b>
	<b>REFERÊNCIAS</b>	<b>44</b>
	<b>ANEXO A - PRODUÇÃO CIENTÍFICA</b>	<b>49</b>

## 1 INTRODUÇÃO

A recuperação de imagens baseada em conteúdo (CBIR, do inglês *Content-Based Image Retrieval*) é uma importante área de pesquisa em visão computacional e recuperação de informações. Essa metodologia permite que os usuários pesquisem imagens com base em seu conteúdo visual, em vez de depender de descrições ou metadados baseados em texto. Os sistemas CBIR usam recursos extraídos de imagens para calcular a similaridade entre uma imagem de referência e outras imagens em um banco de dados. No caso de imagens de radar de abertura sintética (SAR, do inglês *Synthetic Aperture Radar*), pode ser um desafio maior a aplicação de sistemas *Content-Based Image Retrieval* (CBIR) devido às propriedades únicas dos dados, como ruído *speckle*, número de visadas, polarização e resolução espacial.

Os sistemas SAR oferecem vantagens, pois não dependem da luz solar ou das condições atmosféricas para fazer o imageamento e capturar as informações necessárias da superfície alvo (Argenti *et al.*, 2013; Nobre *et al.*, 2016; Zhang *et al.*, 2023; Narayanan *et al.*, 2023). No entanto, a análise de imagens SAR é desafiadora devido ao aspecto granular causado pelo ruído *speckle*, que resulta da interferência de ondas eletromagnéticas. Embora filtros possam ser aplicados para reduzir esse efeito, em contrapartida, isso pode reduzir também a qualidade da imagem. A presença do *speckle*, em imagens SAR, é um grande desafio para as técnicas clássicas de processamento de imagens. Portanto, é possível utilizarmos modelagem estocástica para descrever estatisticamente o processo aleatório da formação de um pixel em uma imagem SAR, ou seja, técnicas de modelagem estatística são usadas para processar e interpretar essas imagens. Aqui, a distribuição  $G_I^0$  foi adotada para modelar os dados SAR em intensidade (Frery *et al.*, 1997; Gambini *et al.*, 2015; Rodrigues *et al.*, 2020), nos permitindo extrair informações relevantes da imagem e assim desenvolver nossa proposta de CBIR aplicada a imagens SAR.

Em geral, os sistemas CBIR disponíveis na literatura utilizam medidas de similaridade as quais não se aplicam à discriminação de regiões da imagem com base na modelagem estatística dos dados e em parâmetros estimados do modelo, ou seja, não consideram a natureza estocástica do processo de formação da imagem. De fato, é possível entender uma imagem como um conjunto de regiões que podem ser descritas por diferentes leis de probabilidade (Nascimento *et al.*, 2010). Assim, é possível usar distâncias estocásticas para mapear regiões distintas para fins de recuperação de imagens SAR. Na literatura, existem diferentes técnicas para realizar CBIR usando imagens SAR (Krishna; Prakash, 2021; Alshehri, 2020; Zhang *et al.*, 2018; Tang

*et al.*, 2017; Jiao *et al.*, 2015; Tang; Jiao, 2017; Schroder *et al.*, 2000).

O objetivo desta tese é avançar no estado da arte quanto ao uso de distâncias estocásticas em sistemas CBIR e superar as limitações da abordagem CBIR clássica em lidar com imagens SAR contaminadas com ruído *speckle*. Para alcançar esse objetivo, utilizamos as distâncias estocásticas para quantificar a similaridade entre regiões com diferentes ou similares níveis de rugosidade ou textura com base nos parâmetros da distribuição  $G_I^0$ .

Para estimar os parâmetros do modelo  $G_I^0$ , o método de máxima verossimilhança (*MLE*, do inglês *Maximum Likelihood Estimation*) (Casella; Berger, 2021) e a abordagem rápida do método log-cumulantes (*FLCM*, do inglês *Fast Log-Cumulants Method*) (Rodrigues *et al.*, 2020) são aplicados às imagens em intensidade. Ao utilizar parâmetros de rugosidade e escala como atributos estimados a partir da distribuição  $G_I^0$ , podemos aplicá-los a sistemas CBIR. Adicionalmente, uma medida de similaridade estocástica usa os parâmetros estimados (Nascimento *et al.*, 2010; Braga *et al.*, 2022), que são as características da imagem SAR, para distinguir as regiões da imagem. Após a obtenção das distâncias, elas são dispostas em ordem crescente para gerar uma lista de *ranking* ou classificação das regiões da imagem. Em seguida, o desempenho do sistema de recuperação de informação é avaliado usando a média das precisões médias (MAP, do inglês *Mean Average Precision*) (Wang *et al.*, 2015).

As principais contribuições deste trabalho são: (a) Desenvolvimento e disponibilização de um sistema CBIR reproduzível baseado no modelo de dados SAR em intensidade que avalia dois métodos de estimação de parâmetros como extratores de características de imagem; (b) Desenvolvimento de uma metodologia de recuperação de informação baseada em conhecimento inspirada em distâncias estocásticas e modelagem de dados que é extensível a outros modelos estatísticos e outras distâncias estocásticas.

## 1.1 Objetivos

O objetivo geral desse trabalho é desenvolver e validar um sistema CBIR com base em distâncias estocásticas para dados SAR, visando melhorar a precisão e a eficácia na recuperação de imagens SAR, empregando métodos estatísticos para analisar e interpretar as características únicas dessas imagens.

Os objetivos específicos podem ser delineados da seguinte forma:

- Modelar estatisticamente dados SAR em intensidade aplicando a distribuição  $G_I^0$  para descrever com precisão as propriedades estatísticas destes dados;

- Estimar parâmetros da distribuição  $G_l^0$  com o Método de Máxima Verossimilhança (*MLE*) e o Método Log-Cumulantes Rápido (*FLCM*);
- Construir um sistema CBIR para imagens SAR que incorpore distâncias estocásticas como métrica para avaliar a similaridade entre imagens;
- Empregar a medida Mean Average Precision (MAP) para avaliar o desempenho do sistema CBIR-SAR proposto, utilizando conjuntos de dados de diferentes sensores SAR (como UAVSAR, OrbiSAR-2, e ALOS PALSAR).

## 1.2 Produção Científica

A produção científica oriunda desta tese resultou na publicação de um artigo de revista da base ISI (*Institute for Scientific Information*), que está em anexo no final desta tese e destacado a seguir:

1. **SILVA, A.D.**; SILVA, P.H.d.S.; SILVA, R.R.V.; RODRIGUES, F.A.À.; MEDEIROS, F.N.S.. *CBIR-SAR System Using Stochastic Distance*. *Sensors*, v. 23, n. 6080, julho, 2023.

## 1.3 Organização da Tese

A estrutura desta tese está organizada da seguinte forma:

- **Capítulo 2:** apresenta os fundamentos das imagens de radar de abertura sintética.
- **Capítulo 3:** apresenta a modelagem estatística dos dados das imagens de radar de abertura sintética.
- **Capítulo 4:** contextualiza a recuperação baseada em conteúdo.
- **Capítulo 5:** apresenta a metodologia proposta a ser utilizada na recuperação baseada em conteúdo de imagens SAR utilizando distância estocástica.
- **Capítulo 6:** detalha os experimentos com imagens sintéticas e reais e exhibe e discute os resultados obtidos para recuperação de imagens utilizando distâncias estocásticas.
- **Capítulo 7:** resume as principais conclusões e achados do trabalho bem como suas limitações e possibilidades de melhorias.

## 2 CONCEITOS DE IMAGENS SAR

O foco das pesquisas em sensoriamento remoto está na extração de informações de imagens adquiridas por satélites em órbita (Peral *et al.*, 2018; Zhang *et al.*, 2023; Narayanan *et al.*, 2023). Nos últimos anos, houve um notável avanço na utilização de satélites com sensores inovadores em missões orbitais civis. Um exemplo é a incorporação de sensores imageadores ativos conhecidos como Synthetic Aperture Radar - SAR. Esses sistemas operam na faixa de microondas, proporcionando diversas vantagens em relação aos sistemas ópticos tradicionais, como a capacidade de operar independentemente da iluminação solar e das condições climáticas, além de possuir uma maior capacidade de penetração na cobertura vegetal da superfície observada (Horta, 2009). Por meio do processamento dessas imagens pode-se, por exemplo, detectar manchas de óleo na superfície do mar ou danos causados por terremotos em prédios (Genovez *et al.*, 2017; Yu *et al.*, 2018; Chen; Wang, 2022; Rao *et al.*, 2023).

A geração de imagens SAR é baseada no uso de ondas eletromagnéticas na faixa de microondas, conferindo a esses sistemas vantagens em relação aos sistemas ópticos. Essas vantagens incluem a capacidade de operar independentemente da luz solar, superar obstáculos como cobertura de nuvens e condições climáticas adversas. A Tabela 1 fornece uma lista das bandas de frequência comumente utilizadas em sistemas SAR, juntamente com as faixas correspondentes de frequência e comprimento de onda.

Tabela 1 – Bandas de frequência utilizadas em sistemas SAR e suas faixas correspondentes de frequência e comprimento de onda.

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

Fonte: Moreira *et al.* (2013)

Diversos aspectos, como a banda de frequência e o comprimento de onda eletromagnética, exercem influência sobre o processo de geração de imagens SAR (Dabboor; Brisco, 2018). O comprimento de onda desempenha um papel crucial na interação entre o sinal eletromagnético emitido e a superfície a ser imageada, afetando a penetração do sinal com possíveis variações de maior ou menor alcance (Marques *et al.*, 2012).

As antenas de radar têm a capacidade de ser configuradas para transmitir e receber sinais com Polarização Horizontal (HH) ou Polarização Vertical (VV), onde o campo elétrico é alinhado na mesma direção do sinal transmitido e recebido, seja na direção horizontal ou vertical,

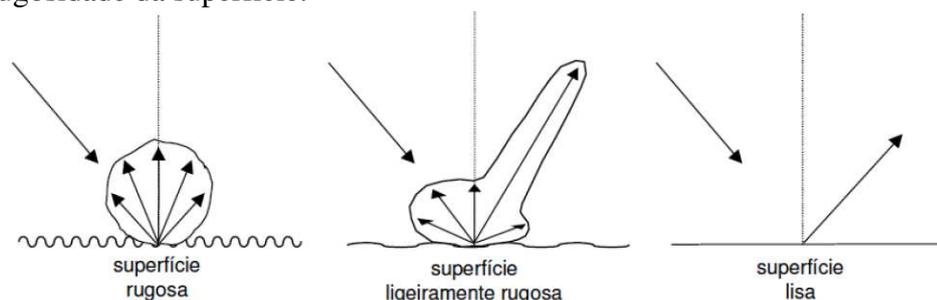
respectivamente. Por outro lado, a polarização cruzada ocorre quando o sinal é transmitido e recebido em direções ortogonais, resultando em Polarização Cruzada Horizontal/Vertical (HV) ou Polarização Cruzada Vertical/Horizontal (VH) ((Bentz, 2006).

De forma simplificada, um sistema de imageamento por radar consiste em um transmissor e receptor de microondas, juntamente com uma antena. Esse sistema é montado em uma plataforma, como um avião ou um satélite, e emite pulsos eletromagnéticos em direção ao alvo. Ao atingir a superfície, a energia do pulso é dispersa em várias direções. Uma parte dessa energia é refletida de volta ao sensor (retroespalhamento), onde é medida e processada para gerar uma imagem do alvo (Marques, 2004).

O radar de abertura sintética é uma implementação específica de sistemas de imageamento por radar que utiliza o movimento da plataforma do radar e técnicas avançadas de processamento de sinais para gerar imagens de alta resolução. Antes da descoberta do radar de abertura sintética, os radares de imageamento operavam com o princípio de abertura física e eram conhecidos como radares aerotransportados de visada lateral (*Side-Looking Airborne Radars - SLAR*) (Zyl; Kim, 2011).

O sinal retroespalhado, também conhecido como sinal de retorno, é influenciado pela rugosidade da superfície que está sendo imageado (Lee; Pottier, 2009). Superfícies mais rugosas tendem a produzir um maior retroespalhamento do sinal de retorno em comparação com superfícies menos rugosas. Conforme relatado por (Marques, 2011), superfícies lisas, como lagos e rios, não geram um retorno significativo, pois a radiação incidente não é refletida na direção da antena, resultando em regiões escuras na imagem. Por outro lado, superfícies extremamente rugosas, como áreas urbanas, podem apresentar pontos de alto retroespalhamento, resultando em regiões mais claras na imagem. O efeito do retroespalhamento do sinal em diferentes tipos de superfícies é apresentado na Figura 1.

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

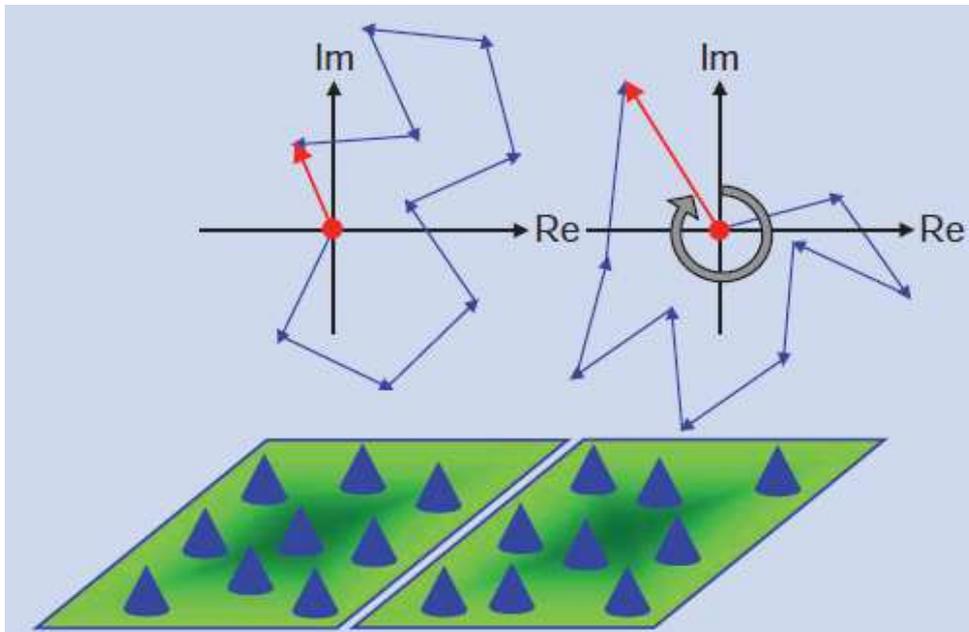


Fonte: Moreira *et al.* (2013)

Quando a rugosidade da superfície imageada tem magnitude semelhante ao comprimento de onda, ocorre a interferência das diversas componentes difusas, resultando em um ruído conhecido como *speckle*. Esse efeito causa variações nas intensidades dos pixels, gerando um padrão granular na imagem SAR e dificultando sua interpretação (Lee; Pottier, 2009).

Cada pixel em uma imagem SAR possui uma intensidade determinada pelo sinal de retorno dentro de uma célula de resolução. Esse sinal é composto pelas ondas refletidas por vários elementos refletoras elementares e representa a soma dos sinais refletidos dentro da célula de resolução. A Figura 2 mostra dois exemplos distintos de células de resolução. A seta vermelha na Figura 2 representa a soma dos sinais refletidos dentro de cada célula.

Figura 2 – Exemplos de dispersores em células de resolução com a respectiva soma dos sinais refletidos.



Fonte: Moreira *et al.* (2013)

Como mostra a Figura 2, o vetor resultante ou fasor, 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 trabalhar com a amplitude ( $A$ ) do vetor  $S$ , dada por (Lee; Pottier, 2009; Frery *et al.*, 1997):

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

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; Pottier, 2009), ambos sinais  $A$  e  $I$  podem ser considerados aleatórios.

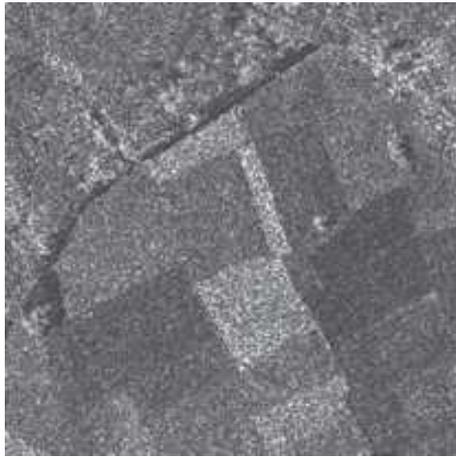
A aplicação de técnicas de processamento e análise de imagens SAR desempenha um papel fundamental na detecção de desastres ambientais, como desmatamento e derramamentos de óleo nos oceanos e rios. Além disso, essas técnicas são essenciais para o monitoramento e vigilância de águas territoriais, o acompanhamento do avanço urbano sobre áreas de proteção ambiental e reservas biológicas. Por meio dessas abordagens, é possível obter informações valiosas para ações de preservação ambiental e tomada de decisões relacionadas à gestão do meio ambiente. Porém, a interpretação e análise de imagens SAR enfrentam um desafio significativo devido à presença de um tipo de ruído multiplicativo conhecido como *speckle*. Esse ruído adiciona granularidade às imagens, dificultando a identificação de detalhes importantes (Frery *et al.*, 1997; Gao, 2010).

O ruído *speckle* está presente de forma natural no processo de formação das imagens SAR, sendo resultado da aleatoriedade dos espalhadores presentes na superfície que está sendo imageada. Estes espalhadores decompõem o sinal enviado pelo sistema, em vários fasores com amplitude e fase aleatórias. As múltiplas contribuições construtivas e destrutivas resultam em um aspecto granular na imagem, afetando a qualidade visual e dificultando a análise precisa dos detalhes (Rodrigues, 2017).

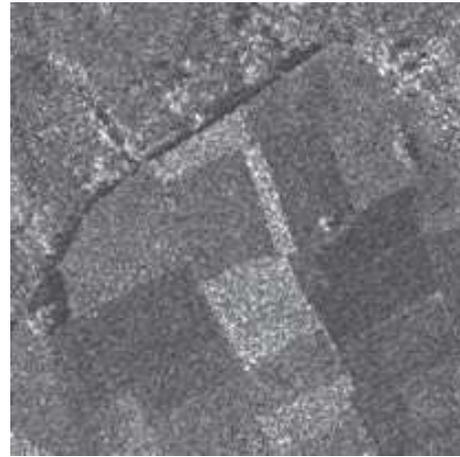
Uma abordagem eficaz para reduzir significativamente o ruído *speckle* é o uso do processamento em múltiplas visadas, também conhecido como *multilooks*. Nesse método, a abertura sintética da antena é dividida em aberturas menores e adjacentes, resultando em  $L$  visadas independentes, conforme mencionado por (Bentz, 2006). Durante esse processo, o retorno é obtido pela média das  $L$  observações. O valor de  $L$  é conhecido como o número de visadas, sendo que uma imagem com uma única visada é representada por  $L = 1$  (*single look*), enquanto imagens com múltiplas visadas são representadas por  $L > 1$  (*multilooks*). Geralmente, o processamento em múltiplas visadas reduz o ruído *speckle* em troca de uma diminuição na resolução da imagem. A Figura 3 apresenta imagens SAR com diferentes números de *looks*.

Outra alternativa para reduzir o ruído presente na imagem é aplicar métodos de filtragem. No entanto, é importante considerar que, embora a filtragem do ruído *speckle* possa auxiliar na interpretação e análise da imagem, ela também pode resultar na degradação de detalhes relevantes. Portanto, é necessário encontrar um equilíbrio entre a redução do ruído e a

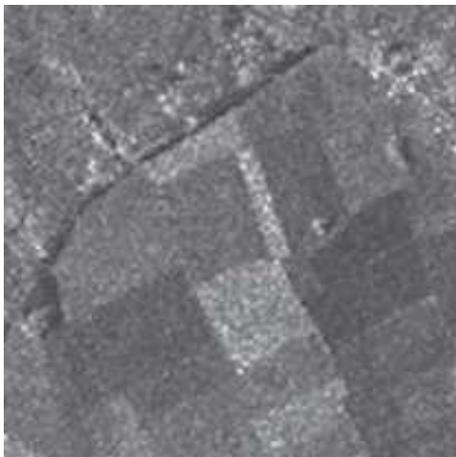
Figura 3 – Imagens SAR com diferentes números de *looks*.



(a) 1 *look*



(b) 2 *looks*.



(c) 4 *looks*.



(d) 8 *looks*.

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

preservação dos detalhes importantes durante o processo de filtragem (Torres *et al.*, 2014).

No estudo realizado por Gao (2010) é apresentada uma revisão bibliográfica abrangente das distribuições utilizadas para modelar os dados SAR. Dentre as diversas distribuições analisadas, destacam-se as distribuições da família  $G^0$ , propostas por Frery *et al.* (1997). Essas distribuições têm se destacado na literatura devido à sua capacidade de modelar de forma adequada regiões com diferentes níveis de homogeneidade, heterogeneidade e extrema heterogeneidade em imagens SAR. Essa abordagem é essencial para obter uma representação mais precisa e fiel das características presentes nas imagens, permitindo uma melhor interpretação e análise dos dados.

### 3 FUNDAMENTOS ESTATÍSTICOS

Neste capítulo apresentamos as principais ferramentas e técnicas implementadas nesta tese. Apresentamos os fundamentos do modelo estatístico para imagens SAR em intensidade, ou seja, a distribuição  $G_I^0$ , os métodos de estimação de parâmetros e as distâncias estocásticas.

#### 3.1 Modelo Estatístico para Dados SAR em Intensidade

Adotamos a distribuição  $G_I^0$  para modelar os dados SAR em intensidade. A função de densidade de probabilidade da  $G_I^0$  é definida como (Frery *et al.*, 1997):

$$f_z(z; \alpha, \gamma, L) = \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{L-1} (\gamma + Lz)^{\alpha-L}, \quad (3.1)$$

com  $-\alpha, \gamma, L, z > 0$ . Os parâmetros  $\alpha$  e  $\gamma$  correspondem à rugosidade e escala, respectivamente, e  $\Gamma(\cdot)$  é a função gama definida por (Arfken; Weber, 1995):

$$\Gamma(w) = \frac{1}{w e^{\tau w} \prod_{k=1}^{\infty} \left(1 + \frac{w}{k}\right) e^{-\frac{w}{k}}}, \quad (3.2)$$

com  $w > 0$  e  $L$  como o número de *looks*, que representa o parâmetro de controle do *speckle*. A influência dos parâmetros  $(\alpha, \gamma, L)$  na forma da distribuição  $G_I^0$  pode ser vista nas Figuras 4, 5 e 6.

Para adicionar as equações dos momentos, média e variância para a distribuição  $G_I^0$  modelando dados SAR em intensidade, consideramos a definição da função de densidade de probabilidade  $f_z(z; \alpha, \gamma, L)$  conforme apresentado. Dada a complexidade do modelo, a expressão direta para a média e variância não é trivial, mas pode ser derivada com base nas propriedades da distribuição.

O  $n$ -ésimo momento de uma distribuição é definido como a expectativa de  $Z^n$ , que pode ser representada para a distribuição  $G_I^0$  como:

$$E[Z^n] = \int_0^{\infty} z^n f_z(z; \alpha, \gamma, L) dz. \quad (3.3)$$

A média ( $\mu$ ) de uma distribuição  $G_I^0$  é o primeiro momento da distribuição, ou seja,  $E[Z]$ . Portanto, a média pode ser expressa em função dos parâmetros da distribuição:

$$\mu = E[Z] = \frac{\gamma \Gamma(L - \alpha + 1)}{L \Gamma(L - \alpha)}. \quad (3.4)$$

Esta equação assume que  $L - \alpha > 0$ , garantindo que a média seja definida.

A variância ( $\sigma^2$ ) de uma distribuição  $G_I^0$  é calculada pela diferença entre o segundo momento e o quadrado do primeiro momento (média), isto é:

$$\sigma^2 = E[Z^2] - (E[Z])^2. \quad (3.5)$$

Para a distribuição  $G_I^0$ , o segundo momento,  $E[Z^2]$ , pode ser expresso como:

$$E[Z^2] = \frac{\gamma^2 \Gamma(L - \alpha + 2)}{L^2 \Gamma(L - \alpha)}. \quad (3.6)$$

Substituindo as equações 3.4 e 3.6 na equação 3.5, obtemos a variância em função dos parâmetros da distribuição  $G_I^0$ :

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

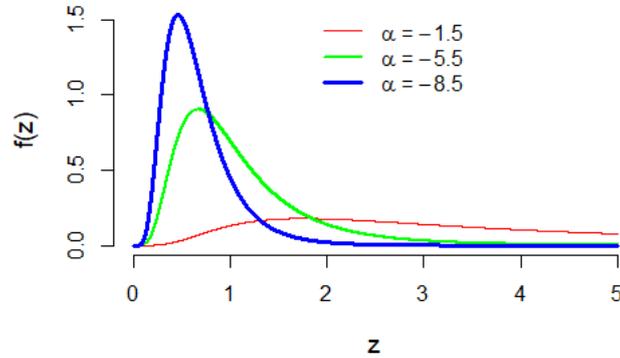
Essas expressões para a média e variância são fundamentais para caracterizar completamente a distribuição  $G_I^0$  e suas propriedades estatísticas, permitindo uma análise mais aprofundada dos dados SAR em intensidade.

A Figura 4 mostra o efeito da variação de  $\alpha$  para o mesmo  $L = 8$  e  $\gamma = 5$ . Observe que quando o valor de  $\alpha$  diminui a função de densidade de probabilidade tende a ter a cauda mais longa, representando regiões da imagem que são mais homogêneas como, por exemplo, regiões de culturas de milho, arroz. A Figura 5 mostra o efeito da variação de  $\gamma$  para o mesmo  $\alpha = -5.5$  e  $L = 8$ . Em (Bustos *et al.*, 2002),  $\gamma$  está relacionado com a luminosidade da cena.

Finalmente, a Figura 6 mostra o efeito do número de *looks*, ou seja, variando  $L$  para o mesmo  $\alpha = -5.5$  e  $\gamma = 5$ . Também mostra que o número de *looks* afeta principalmente a distribuição de valores muito pequenos. Observe que quando  $L$  diminui, a distribuição  $G_I^0$  atribui mais probabilidade a valores menores do retorno  $z$ , gerando imagens de menor contraste (Frery *et al.*, 2022) e, conseqüentemente, imagens mais desafiadoras para processamento.

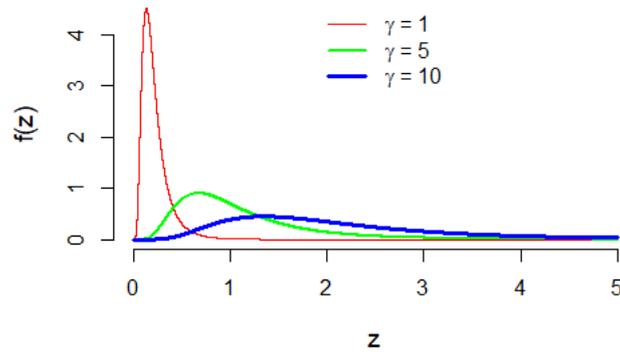
A grande vantagem de usar a distribuição  $G_I^0$  é que ela pode modelar com precisão regiões homogêneas, heterogêneas e extremamente heterogêneas de uma imagem SAR em

Figura 4 – Densidades da distribuição  $G_I^0$  com diferentes parâmetros:  $\alpha \in \{-1.5, -5.5, -8.5\}, L = 8, \gamma = 5$ .



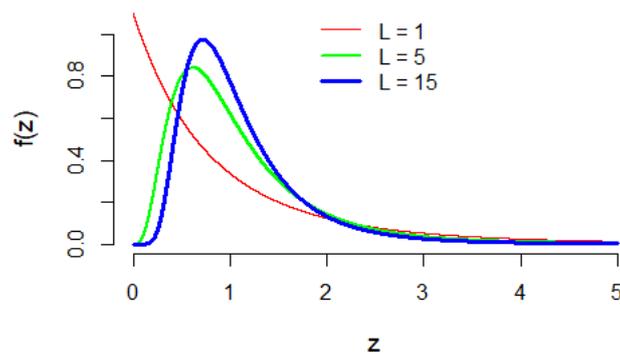
Fonte: Elaborada pelo autor.

Figura 5 – Densidades da distribuição  $G_I^0$  com diferentes parâmetros:  $\gamma \in \{1, 5, 10\}, L = 8, \alpha = -5.5$ .



Fonte: Elaborada pelo autor.

Figura 6 – Densidades da distribuição  $G_I^0$  com diferentes parâmetros:  $L \in \{1, 5, 15\}, \alpha = -5.5, \gamma = 5$ .



Fonte: Elaborada pelo autor.

intensidade (Frery *et al.*, 1997). Essa flexibilidade tem motivado algumas aplicações importantes, como a segmentação de imagens SAR guiada pela entropia de Shannon para a  $G_I^0$  (Ferreira; Nascimento, 2020), processo de média móvel autorregressiva para dados com ruído *speckle* (Junior; Nascimento, 2021), etc.

### 3.2 Estimação dos Parâmetros da Distribuição $G_I^0$

Para estimar os parâmetros da distribuição  $G_I^0$  (Frery *et al.*, 1997), dois métodos foram selecionados: o Estimador de Máxima Verossimilhança (*MLE*) (Nascimento *et al.*, 2010) e a abordagem rápida do método log-cumulantes (*FLCM*) (Rodrigues *et al.*, 2020), tais métodos foram escolhidos devido às suas boas propriedades como consistência, normalidade assintótica, eficiência e velocidade de estimação. Aqui, o número de *looks*,  $L$ , é considerado conhecido. O parâmetro  $L$  é geralmente um número inteiro fornecido pelo sensor SAR e neste trabalho é uma informação conhecida a priori. Porém, na ausência dela, o número de *looks* pode ser estimado a partir de dados SAR reais e, portanto, é interessante designá-lo como número equivalente de *looks* (Marques *et al.*, 2012).

#### 3.2.1 Método de Máxima Verossimilhança

Considere uma variável aleatória  $Z$  com uma função de densidade de probabilidade  $f(z, \theta)$ , em que  $\theta$  é o vetor de parâmetros a serem estimados e  $(z_1, z_2, \dots, z_n)$  uma amostra aleatória de tamanho  $n$  da variável  $Z$ . A função de verossimilhança  $L(\theta; z_1, z_2, \dots, z_n)$  é definida por (Casella; Berger, 2021):

$$L(\theta; z_1, z_2, \dots, z_n) = \prod_{i=1}^n f(z_i, \theta), \quad (3.8)$$

interpretado como uma função de  $\theta$ . O *Maximum Likelihood Estimation* (MLE) de  $\theta$  será aquele que maximiza  $L(\theta; z_1, z_2, \dots, z_n)$ .

Para a distribuição  $G_I^0$ , a função de verossimilhança é dada por (Nascimento *et al.*, 2010):

$$L_{G_I^0}(\alpha, \gamma, L; z) = \left( \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} \right)^n \prod_{i=1}^n z_i^{L-1} (\gamma + L z_i)^{\alpha-L}. \quad (3.9)$$

em que os valores de  $\alpha$  e  $\gamma$  que maximizam a Equação (3.9) podem ser obtidos encontrando-se a solução do seguinte sistema de equações não lineares.

$$\begin{cases} n [-\psi^0(L - \hat{\alpha}) - \log(\hat{\gamma}) + \psi^0(-\hat{\alpha})] + \sum_{i=1}^n \log(\hat{\gamma} + Lz_i) = 0 \\ -\frac{n\hat{\alpha}}{\hat{\gamma}} + (\hat{\alpha} - \hat{L}) \sum_{i=1}^n \frac{1}{\hat{\gamma} + Lz_i} = 0, \end{cases} \quad (3.10)$$

em que  $\Psi(\cdot)^0$  é a função digamma (Arfken; Weber, 1995; Abramowitz; Stegun, 1964) e  $\hat{\alpha}$  e  $\hat{\gamma}$  são os *MLE* para  $\alpha$  e  $\gamma$ , respectivamente. Dado que não há funções inversas viáveis para  $\psi^0(\cdot)$ , o sistema não linear na Equação (3.10) não pode ser resolvido explicitamente e, portanto, requer procedimentos iterativos. Na verdade, é uma tarefa difícil, principalmente em áreas sem textura (Frery *et al.*, 2022).

Para resolver o problema de encontrar a solução para o sistema de equações não lineares, aplicamos uma rotina numérica baseada no algoritmo Broyden–Fletcher–Goldfarb–Shanno (*BFGS*), implementado no software R através da função *maxLik*. Uma boa solução consiste em usar estimativas obtidas com o método dos momentos (Frery *et al.*, 1997) como estimativa inicial para o algoritmo *BFGS*. O algoritmo *BFGS* começa com estimativas iniciais para os valores ótimos de  $\hat{\alpha}$  e  $\hat{\gamma}$  e prossegue iterativamente para buscar melhores estimativas em cada estágio.

### 3.2.2 Método Log-Cumulantes Rápido

O *Fast Log-Cumulants Method* (FLCM), abordagem rápida do método log-cumulantes, apresenta expressões analíticas para estimar a rugosidade ( $\alpha$ ) e a escala ( $\gamma$ ) da distribuição  $G_I^0$ . Usando *FMLC*, o parâmetro de rugosidade pode ser estimado pela seguinte expressão (Rodrigues *et al.*, 2020):

$$\hat{\alpha} = \begin{cases} -\left| \sqrt{\frac{1}{\tilde{k}_2 - \Psi^1(L)}} \right|, \text{ if } \tilde{k}_2 - \Psi^1(L) < 0 \\ -\sqrt{\frac{1}{\tilde{k}_2 - \Psi^1(L)}}, \text{ if } \tilde{k}_2 - \Psi^1(L) > 0, \end{cases} \quad (3.11)$$

em que  $|\cdot|$  representa o operador de módulo,  $\Psi^1(\cdot)$  é a função trigamma (Arfken; Weber, 1995) e  $\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2$  é o log-cumulante da ordem 2. Normalmente,  $(\tilde{m}_1, \tilde{m}_2)$  devem ser substituídos

pelos correspondentes log-momentos de amostra de ordem  $\nu = 1$  e  $\nu = 2$ , respectivamente, que pode ser calculado por (Nicolas, 2002):

$$\widehat{m}_\nu = \frac{1}{n} \sum_{i=1}^n \ln z_i^\nu, \quad (3.12)$$

com  $z_i$ ,  $i \in \{1, 2, \dots, n\}$ , sendo uma amostra de uma variável aleatória  $Z$ . Após obter  $\widehat{\alpha}$ ,  $\gamma$  pode ser estimado por:

$$\widehat{\gamma} = \exp \left[ \widetilde{k}_1 - \Psi^0(L) + \Psi^0(-\widehat{\alpha}) \right] L, \quad (3.13)$$

em que  $\widetilde{k}_1 = \widetilde{m}_2$  e  $\Psi^0(\cdot)$  é a função digamma (Arfken; Weber, 1995).

### 3.3 Distâncias Estocásticas

Análise de contraste normalmente aborda o problema de quantificar a dissimilaridade de duas regiões de uma imagem. Neste sentido, a necessidade de uma distância é implícita. É possível entender uma imagem como um conjunto de regiões que podem ser descritas por diferentes leis de probabilidade (Nascimento *et al.*, 2010).

Nascimento *et al.* (2010) apresentaram a formulação teórica de medidas de distâncias obtidas a partir da classe de divergências  $(h-\phi)$ , a qual foi introduzida em (Salicrú *et al.*, 1994).

Considere duas variáveis aleatórias  $X$  e  $Y$  no mesmo espaço de probabilidade, em que  $f_X(x, \theta_1)$  e  $f_Y(x, \theta_2)$  são suas respectivas funções de densidade de probabilidade e  $\theta_1$  e  $\theta_2$  são vetores com seus parâmetros. Assumindo que ambas as densidades compartilham um suporte comum  $I \subset \mathbb{R}$ .

A divergência  $D_\phi^h$  entre  $f_X(x, \theta_1)$  e  $f_Y(x, \theta_2)$  é dada por:

$$D_\phi^h(X, Y) = h \left( \int_I \phi \left( \frac{f_X(x, \theta_1)}{f_Y(x, \theta_2)} \right) f_Y(x, \theta_2) dx \right), \quad (3.14)$$

em que  $\phi : (0, \infty) \rightarrow [0, \infty)$  é uma função convexa,  $h : (0, \infty) \rightarrow [0, \infty)$  é uma função estritamente crescente com  $h(0) = 0$ .

Medidas de divergências são ferramentas adequadas para comparar distribuições de variáveis aleatórias (Aviyente, 2003). A partir de uma escolha criteriosa das funções  $h$  e  $\phi$  pode-se obter várias medidas de divergências conhecidas. Em (Nascimento *et al.*, 2010), os autores

apresentaram oito medidas, a saber: 1-Kullback-Leibler; 2-Rényi de ordem  $\beta$ ; 3-Hellinger; 4-Bhattacharyya; 5-Jensen-Shannon; 6-aritmética-geométrica; 7-triangular; e 8-média harmônica. Algumas das medidas derivadas a partir da Equação (3.14) não apresentam a propriedade de simetria. Para solucionar esta questão, Nascimento *et al.* (Nascimento *et al.*, 2010) introduziram uma nova medida  $d_\phi^h$  dada por

$$d_\phi^h(X, Y) = \frac{D_\phi^h(X, Y) + D_\phi^h(Y, X)}{2}. \quad (3.15)$$

A partir da Equação (3.15) as versões simétricas das medidas de divergências são chamadas de distâncias.

Das oito medidas apresentadas, quatro já apresentavam a propriedade de simetria e foram consideradas distâncias, a saber Hellinger, Bhattacharyya, triangular e média harmônica. Assim, apenas quatro restantes foram aplicadas na Equação (3.15). A seguir são apresentadas as fórmulas das oito distâncias estocásticas (Nascimento *et al.*, 2010):

a) Distância de Kullback-Leibler:

$$d_{KL}(X, Y) = \frac{1}{2} \int (f_X - f_Y) \log \left( \frac{f_X}{f_Y} \right). \quad (3.16)$$

b) Distância de Rényi de ordem  $\beta$ :

$$d_R^\beta(X, Y) = \frac{1}{\beta - 1} \log \left( \frac{\int f_X^\beta f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^\beta}{2} \right). \quad (3.17)$$

c) Distância de Hellinger:

$$\begin{aligned} d_H(X, Y) &= 1 - \int \sqrt{f_X f_Y} \\ &= 1 - \exp \left( -\frac{1}{2} d_R^{\frac{1}{2}}(X, Y) \right). \end{aligned} \quad (3.18)$$

d) Distância de Bhattacharyya:

$$\begin{aligned} d_B(X, Y) &= -\log \left( \int \sqrt{f_X f_Y} \right) \\ &= -\log(1 - d_H(X, Y)). \end{aligned} \quad (3.19)$$

e) Distância de Jensen-Shannon:

$$d_{JS}(X, Y) = \frac{1}{2} \left[ \int f_X \log \left( \frac{2f_X}{f_Y + F_X} \right) + \int f_Y \log \left( \frac{2f_Y}{f_Y + F_X} \right) \right]. \quad (3.20)$$

f) Distância aritmética-geométrica:

$$d_{AG}(X, Y) = \frac{1}{2} \int (f_X + f_Y) \log \left( \frac{f_X + f_Y}{2\sqrt{f_X f_Y}} \right). \quad (3.21)$$

g) Distância triangular:

$$d_T(X, Y) = \int \left( \frac{(f_X - f_Y)^2}{f_X + f_Y} \right). \quad (3.22)$$

h) Distância média harmônica:

$$\begin{aligned} d_{MH}(X, Y) &= -\log \left( \int \frac{2f_X f_Y}{f_Y + f_X} \right) \\ &= -\log \left( 1 - \frac{d_T(X, Y)}{2} \right). \end{aligned} \quad (3.23)$$

A análise de contraste costuma ser usada para resolver o problema de quantificar o quão distinguíveis são duas regiões da imagem uma da outra (Nascimento *et al.*, 2010) e uma métrica de distância desempenha um papel crucial para realizá-la. Da mesma forma, os sistemas CBIR dependem da similaridade do conteúdo da imagem e requerem métricas de distância. Devido às propriedades estatísticas dos dados SAR e às propriedades de aleatoriedade do ruído *speckle*, os sistemas CBIR requerem distâncias adequadas. De fato, as distâncias estocásticas são ferramentas apropriadas e relevantes para a análise de imagens SAR, pois são capazes de avaliar diferenças entre regiões em uma cena.

## 4 RECUPERAÇÃO DE IMAGENS BASEADA EM CONTEÚDO

O avanço dos sistemas de hardware embarcado, capazes de coletar, armazenar e compartilhar imagens digitais em redes de computadores, tem impulsionado a demanda por aplicações de visão computacional em diversos setores, como medicina, indústria, segurança e biologia. Nesse contexto, a necessidade de ferramentas eficientes para gerenciamento de informações multimídia tornou-se evidente, pois elas facilitam a organização e a busca automática desse tipo de conteúdo. Essas ferramentas desempenham um papel fundamental ao fornecer mecanismos efetivos para lidar com a abundância de dados visuais disponíveis, otimizando, assim, a análise e a utilização dessas informações em diversas áreas de aplicação.

Os Sistemas de Recuperação de Imagens Baseados em Conteúdo são projetados para realizar buscas em bases de imagens utilizando características visuais das imagens (Kato, 1992), (Hirata; Kato, 1992). Esses sistemas visam recuperar imagens de interesse do usuário com base em um padrão de consulta especificado por uma imagem. Em vez de depender apenas de metadados ou anotações textuais, o CBIR utiliza propriedades como cor, textura, forma e composição, para realizar as buscas. Dessa forma, o usuário pode encontrar imagens semelhantes ou relacionadas àquela especificada na consulta, proporcionando uma forma efetiva e intuitiva de recuperar imagens de acordo com suas preferências visuais.

Os sistemas de busca de imagens em grandes bases de dados têm se tornado um serviço essencial nos sistemas de gerenciamento de informações atuais (Donatelli *et al.*, 2015). O método tradicional para fornecer esse serviço é por rotulação textual por palavras-chave. No entanto, devido à imensa quantidade de informação multimídia disponível e à ausência de rótulos, essa abordagem tornou-se inviável. Além disso, a descrição textual é imprecisa e suscetível a erros, uma vez que diferentes indivíduos tendem a interpretar e descrever uma mesma imagem usando palavras-chave diferentes. Para superar essas dificuldades, foram propostos os sistemas CBIR.

### 4.1 Arquitetura dos Sistemas de Recuperação de Imagens Baseada em Conteúdo

Os sistemas CBIR utilizam o conteúdo visual das imagens para criar uma base de dados composta por vetores de características. Nesses sistemas, a busca é realizada quando o usuário fornece uma imagem ou figura de consulta, que também é representada como um vetor. Pela avaliação da similaridade entre as representações da imagem de consulta e as imagens da

base de dados, o sistema procura retornar ao usuário as imagens que sejam do seu interesse.

O padrão de consulta, que é uma imagem fornecida pelo usuário, pode assumir diferentes formas, dependendo das características específicas da aplicação. Pode ser um esboço, um modelo ou uma cópia exata do objeto desejado. O sistema compara essa imagem de consulta com as representações vetoriais das imagens da base de dados, procurando por similaridades e correspondências nas características visuais.

Essa abordagem permite que o sistema CBIR localize imagens relevantes com base no conteúdo visual, independentemente de rótulos textuais ou descrições prévias. Ao utilizar representações vetoriais e técnicas de avaliação de similaridade, o sistema é capaz de realizar buscas eficientes e retornar ao usuário as imagens que correspondam ao seu interesse. Isso torna o processo de busca mais intuitivo e preciso, proporcionando uma experiência aprimorada na recuperação de imagens.

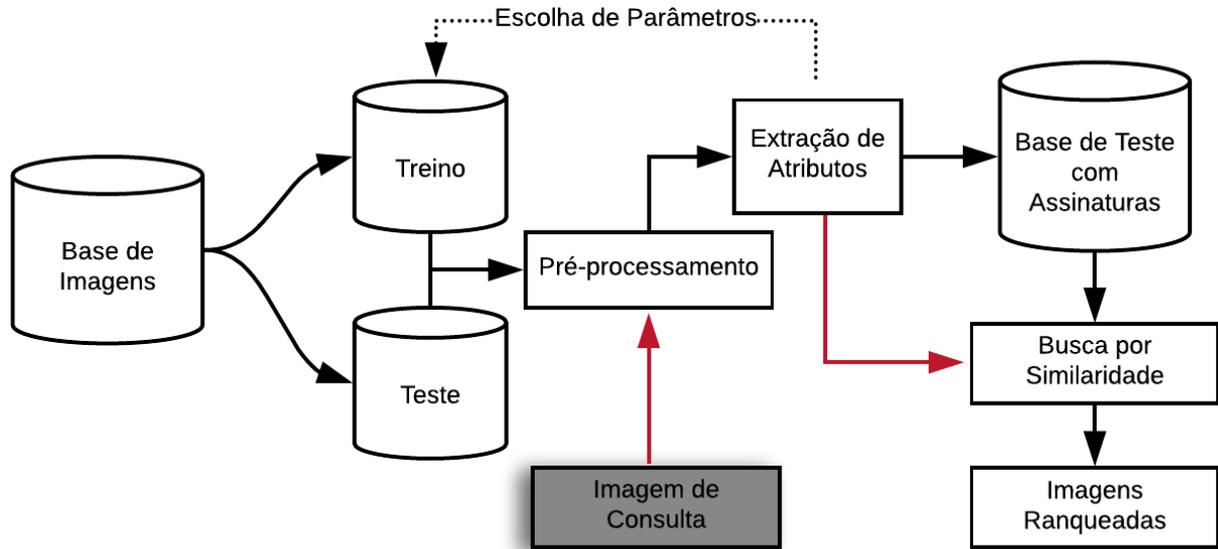
A Figura 7 apresenta a arquitetura de um sistema *CBIR* clássico. A partir de uma base de imagens, são criados conjuntos de treinamento e teste. A base de treinamento serve para obter o melhor conjunto de parâmetros. Para isso, várias metodologias podem ser empregadas, como, por exemplo, algoritmos evolucionários (Souza *et al.*, 2016). Por outro lado, a base de teste é utilizada para que as buscas por similaridade sejam feitas. Os passos de pré-processamento e extração de atributos são aplicados nas bases de teste e treino para criação da base de assinaturas.

Ao realizar uma busca, uma imagem de consulta passa pelos mesmos passos de pré-processamento e extração de atributos. A partir do vetor de características obtido, é realizada uma busca na base de assinaturas de teste, procurando pelas assinaturas mais similares àquela calculada para a imagem de consulta. A similaridade entre as assinaturas pode ser calculada utilizando funções de distância, como a euclidiana, cosseno ou Manhattan, por exemplo.

Por fim, o sistema retorna as imagens da base de dados de teste, ranqueadas ou classificadas por ordem de similaridade em relação aos atributos que as representam. Dessa forma, o usuário pode visualizar as imagens que possuem maior correspondência visual com a imagem de consulta, facilitando a busca por conteúdo visualmente semelhante.

Neste trabalho, são enfatizados os procedimentos de extração de características e avaliação de similaridade em experimentos CBIR. A extração de características das imagens é um componente crucial dos sistemas CBIR, envolvendo operações de processamento de imagens para obter informações semanticamente relevantes a partir dos atributos da imagem. Essas informações são essenciais para realizar buscas de conteúdo por similaridade. Os atributos

Figura 7 – Arquitetura de um sistema *CBIR*. A partir de uma base de imagens, dividida em conjuntos de treino e teste, é feito o pré-processamento e a extração de atributos, gerando a base de assinaturas. Com isso, é possível buscar imagens com conteúdo similar ao de uma imagem de referência e ranquear o resultado por nível de similaridade. As setas vermelhas mostram o fluxo da imagem de consulta.



Fonte: Silva (2018)

frequentemente utilizados nesse processo incluem cor, textura, forma e localização espacial dos elementos presentes na imagem.

A utilização de atributos de textura é valiosa tanto na recuperação de imagens de satélites quanto na busca de documentos digitalizados (Smeulders A. W. M.; Worring, 2000). A textura é definida como padrões formados por grupos de pixels que aparecem na imagem com certa periodicidade ou aleatoriedade (Gonzalez; Woods, 2006). Um método amplamente utilizado para descrever características de texturas é a matriz de co-ocorrência proposta por (Haralick R. M.; Shanmugam, 1973). No entanto, métodos baseados em transformações *wavelet* também têm sido empregados, especialmente a transformada *wavelet* de Gabor (Liu X.; You, 2009). Além disso, a dimensão fractal multiescala tem sido explorada como uma técnica para descrever texturas na atualidade (Florindo J. B.; Bruno, 2013).

A cor é o atributo mais comumente utilizado na extração de características em *CBIR*, devido à sua capacidade de discriminar uma ampla variedade de imagens. No entanto, ao utilizar esse atributo, é importante considerar que a representação da cor em uma imagem pode variar significativamente devido à orientação da superfície capturada, a posição da câmera, a iluminação e como a luz interage com os objetos presentes na imagem (Smeulders A. W. M.; Worring, 2000). Além disso, a percepção humana da cor é um assunto complexo que ainda não está completamente compreendido (Smeulders A. W. M.; Worring, 2000). As técnicas de descrição

de cor podem ser divididas em duas principais categorias, dependendo se a informação de cor é codificada correlacionada com a sua distribuição espacial ou não (Torres R. S.; Falcão, 2006).

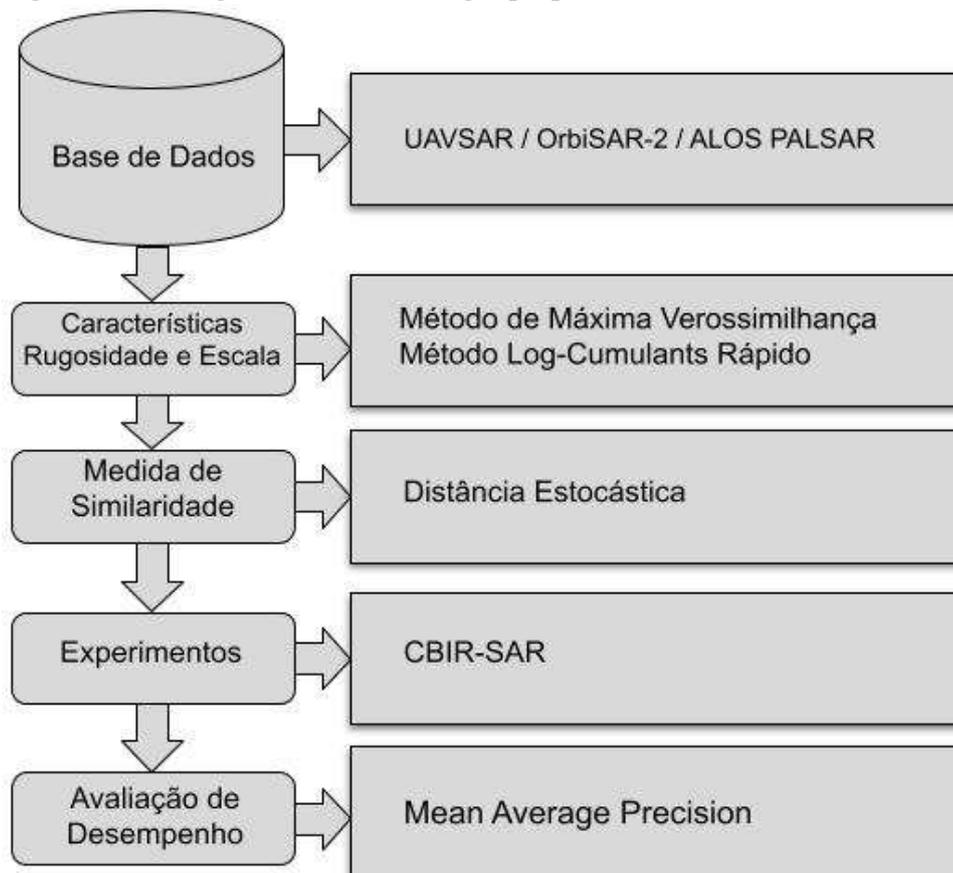
A forma é uma característica intrínseca das imagens que desempenha um papel fundamental no sistema visual dos primatas para o reconhecimento de objetos. Avanços significativos têm sido feitos no desenvolvimento de sistemas CBIR com base nesse atributo (Smeulders A. W. M.; Worring, 2000), (Liu *et al.*, 2007). Entre as abordagens utilizadas para obter representações das formas, a mais popular é aquela que as representa por meio de vetores de características invariantes (ULLMAN, 1995). Essa representação permite que a similaridade entre as formas seja avaliada por medidas de distância entre os vetores. No entanto, a representação por vetores de características, por si só, é pouco discriminativa (ULLMAN, 1995), dependendo da qualidade da segmentação dos objetos, limitando sua aplicação em CBIR a problemas específicos.

Na representação estrutural, as formas são decompostas em um conjunto de partes constituintes, sendo cada parte representada individualmente por meio de vetores de características. O descritor é construído a partir desses vetores e da relação entre as partes, que pode ser representada por estruturas de dados como grafos, árvores ou cadeias de caracteres. Esses métodos comparam as formas com base em suas estruturas, o que resulta em uma boa precisão, porém com um alto custo computacional.

## 5 METODOLOGIA PROPOSTA

O sistema CBIR proposto é baseado no conhecimento oriundo do modelo estatístico de imagens SAR. Este sistema nomeado CBIR-SAR utiliza imagens em intensidade adquiridas de sensores SAR. O banco de dados reais consiste de 25 recortes de imagens de cada região (por exemplo, água, derramamento de óleo, floresta) do sensor UAVSAR e 25 imagens de cada região (por exemplo, água, área urbana e floresta) dos sensores OrbiSAR-2 e ALOS PALSAR. Os métodos de estimação *MLE* e *FLCM* são usados para estimar os parâmetros de rugosidade e escala para cada região da imagem. O número de *looks* fornecidos pelos sensores SAR utilizados é igual a 1. As Tabelas 2,3 e 4 apresentam as informações dos radares. A razão para lidar com imagens *single – look* é que elas são marcadamente afetadas pelo ruído *speckle* e representam desafios potenciais para o algoritmo. Assim, todos os testes são realizados com imagens *single – look*.

Figura 8 – Fluxograma da metodologia proposta.



Fonte: Elaborada pelo autor.

A Figura 8 descreve o fluxograma geral do sistema CBIR-SAR proposto. Ele mostra

que para o banco de dados de imagens SAR, os parâmetros da distribuição  $G_l^0$  para cada região da imagem são estimados usando os métodos *MLE* e *FLCM*. A principal razão para usar esses métodos de estimação de parâmetros é avaliar o desempenho do algoritmo proposto em cada parâmetro.

As estimativas e a medida de similaridade são inseridas no CBIR-SAR para calcular a distância estocástica triangular entre cada imagem de consulta e as outras amostras. Finalmente, o sistema gera distâncias que fornecem uma lista de classificação das amostras recuperadas de água, derramamento de óleo, floresta e área urbana. Em seguida, a medida MAP avalia os resultados. Quanto maior o valor da medida MAP, melhor o desempenho do CBIR-SAR.

### 5.1 Base de Dados SAR Sintéticos

Inspirada por Marques *et al.* (2012), a simulação dos dados SAR sintéticos em intensidade foi realizada utilizando a Equação 5.1.

$$S = -\frac{\gamma}{\alpha} \Upsilon_{2L, -2\alpha}^{-1}(U), \quad (5.1)$$

em que  $S$  representa a imagem simulada,  $\Upsilon_{2L, -2\alpha}^{-1}$  é a função inversa da distribuição  $F$ -Snedecor, com  $2L$  e  $-2\alpha$  sendo os graus de liberdade e  $U$  sendo uma variável aleatória com distribuição uniforme no intervalo  $(0, 1)$ . Para gerar imagens SAR a partir da Equação (5.1), são necessários os seguintes passos:

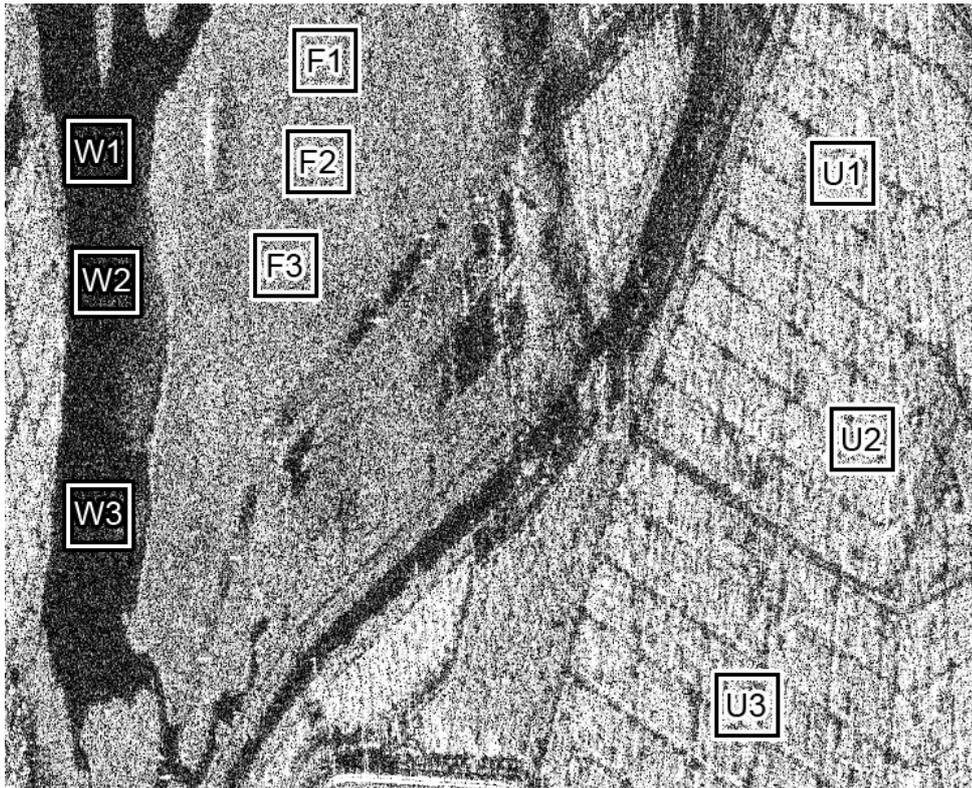
- i) Parâmetros  $(\alpha, \gamma, L)$  devem ser definidos.
- ii)  $U$  deve ser gerado com tamanho desejável, a partir da distribuição uniforme ao longo do intervalo  $(0, 1)$ .
- iii)  $U$  é colocado na Equação (5.1). Isso resultará em uma imagem SAR sintética em intensidade, com parâmetros definidos na etapa (i).

Três conjuntos diferentes de imagens SAR em intensidade  $(S_1, S_2, S_3)$  foram simulados usando a Equação (5.1), com cada conjunto compreendendo 25 amostras de imagens de  $100 \times 100$  pixels, totalizando 75 imagens. As simulações consideraram valores de  $\alpha$  referentes a regiões extremamente heterogêneas (áreas urbanas) no intervalo  $\alpha \in -0,35, -1,52$  para  $S_1$ , bem como regiões heterogêneas (áreas florestais) no intervalo  $\alpha \in -10,14, -23,75$  para  $S_2$  e regiões homogêneas (água, óleo) no intervalo  $\alpha \in -55,79, -71,08$  para  $S_3$ . Com relação aos demais parâmetros, foram adotados valores de  $\gamma$  no intervalo  $\gamma \in (1, 7)$  e  $L = 1$ .

## 5.2 Base de Dados SAR Reais

A base de dados SAR reais foi adquirida a partir de três imagens provenientes de radares aéreos diferentes, imagens *single – look*, são eles: *Uninhabited Aerial Vehicle Synthetic Aperture Radar* (UAVSAR), da *National Aeronautics and Space Administration* (NASA); OrbiSAR-2 da BRADAR; e *ALOS Phased Array-type L-band Synthetic Aperture Radar* (ALOS PALSAR) da *National Aeronautics and Space Administration* (NASA). Para criar o banco de dados, cada imagem foi cortada manualmente e categorizada em três regiões conforme a área de abrangência. O conjunto de amostras compreendeu 25 *patches* de  $100 \times 100$  pixels para cada região de cada canal de polarização do radar, ou seja, HH, HV, VH e VV. O canal VH do ALOS PALSAR estava indisponível.

Figura 9 – Imagem OrbiSAR-2 SAR: amostras selecionadas de água (W), floresta (F) e áreas urbanas (U).



Fonte: Elaborada pelo autor.

A Figura 9 exhibe amostras, em que  $W1, W2$  e  $W3$  correspondem a água,  $F1, F2$  e  $F3$  são regiões florestais e  $U1, U2$  e  $U3$  são áreas urbanas. As Tabelas 2, 3 e 4 apresentam informações físicas importantes sobre os três radares que adquiriram as imagens SAR reais.

Tabela 2 – Informações do Radar UAVSAR.

Lugar da Imagem		New Orleans, USA
Informação Física	Altura (km)	265,26
	Largura (km)	16,49
	Área (km <sup>2</sup> )	4374,14
Parâmetros do Radar	Sensor	SAR
	Polarização	HH, HV, VH, VV
	Banda	L Banda
Informação de Dados	Formato do Produto	SLC
	Número de Linhas	442106
	Número de Colunas	9900
	Número de <i>Looks</i>	1

Fonte: Elaborada pelo autor.

Tabela 3 – Informações do Radar OrbiSAR-2.

Lugar da Imagem		Santos, Brazil
Informação Física	Altura (km)	15,83
	Largura (km)	18,68
	Área (km <sup>2</sup> )	295,70
Parâmetros do Radar	Sensor	SAR
	Polarização	HH, HV, VH, VV
	Banda	P Banda
Informação de Dados	Formato do Produto	SLC
	Número de Linhas	26616
	Número de Colunas	8192
	Número de <i>Looks</i>	1

Fonte: Elaborada pelo autor.

Tabela 4 – Informações do Radar ALOS PALSAR.

Lugar da Imagem		San Francisco, USA
Informação Física	Altura (km)	65,92
	Largura (km)	28,57
	Área (km <sup>2</sup> )	1883,33
Parâmetros do Radar	Sensor	SAR
	Polarização	HH, HV, VV
	Banda	L Banda
Informação de Dados	Formato do Produto	CEOS
	Número de Linhas	18432
	Número de Colunas	1248
	Número de <i>Looks</i>	1

Fonte: Elaborada pelo autor.

### 5.3 Extração de Características

Nesta tese, os métodos *MLE* e *FLCM* estimam os parâmetros de rugosidade e escala do modelo  $G_I^0$  para cada imagem de amostra. Em termos de CBIR-SAR, a estimação de parâmetros extrai informações estatísticas das imagens, correspondendo à etapa de extração de características do sistema CBIR. Finalmente, as estimativas dos parâmetros são inseridas na distância estocástica ou medida de similaridade. Dada uma imagem de entrada apresentada em consulta, o CBIR-SAR calcula a distância entre ela e todas as imagens do banco de dados. Dessa forma os parâmetros estimados carregam as informações necessárias para guiar o sistema de busca e recuperação proposto.

### 5.4 Sistema CBIR-SAR

Os sistemas CBIR procuram imagens semelhantes em um banco de dados avaliando a semelhança entre a imagem de referência e as outras imagens no banco de dados (Liu *et al.*, 2007). Ele usa recursos de imagens visuais para calcular distâncias e as organiza em ordem crescente para gerar uma lista de classificação de imagens ou ranqueamento das mesmas. Nesta tese, as características visuais são os parâmetros de rugosidade ( $\hat{\alpha}$ ) e escala ( $\hat{\gamma}$ ) do modelo  $G_I^0$ .

O sistema CBIR proposto com base em uma abordagem estocástica reconhece e recupera regiões de imagens SAR, como água, floresta, áreas urbanas e derramamentos de óleo, representando o modelo  $G_I^0$  e a distância estocástica entre as mesmas distribuições, possivelmente indexadas por parâmetros diferentes. Em seguida, o CBIR-SAR realiza a recuperação de imagens combinando amostras por similaridade estatística.

### 5.5 Métrica de Avaliação dos Resultados

O CBIR-SAR possui como métrica de avaliação de desempenho o *Mean Average Precision* (Wang *et al.*, 2015), que avalia a qualidade da recuperação de imagens.

Para calcular o MAP, a precisão média  $AP(Q)$  é calculada para cada imagem de consulta  $Q$ :

$$AP(Q) = \frac{\sum_{n=1}^M (P(n) \times f(n))}{N}, \quad (5.2)$$

e,

$$P(n) = \frac{VP}{VP + FN}, \quad (5.3)$$

em que o símbolo  $\times$  representa o produto escalar,  $P(n)$  é a precisão até a posição  $n$  do ranqueamento,  $f(n)$  é igual a 1 se a imagem  $n$  do ranqueamento pertence à mesma classe da imagem de referência, e 0 caso contrário.  $M$  é o número de imagens no ranqueamento e  $N$  é o número de imagens da mesma classe obtidas no ranqueamento, Verdadeiro Positivo (VP) e Falso Negativo (FN). O MAP é obtido pela média da  $AP$  em todas as imagens do ranqueamento. Quanto mais próximo de 1 o valor do MAP melhor o desempenho.

É viável calcular o MAP tanto para o conjunto de dados completo quanto para cada classe individualmente, permitindo a avaliação do desempenho do sistema em diferentes categorias.

## 6 RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados e discussões com base nos experimentos realizados com o sistema CBIR-SAR aplicado a imagens SAR sintéticas e reais adquiridas de três sensores SAR diferentes. O ambiente computacional estatístico utilizado para a realização dos experimentos foi a linguagem R (R Core Team, 2021), versão 4.1.2, em uma máquina com CPU de até 4,20 GHz e 16 GB de memória RAM.

### 6.1 Experimentos com Imagens SAR Sintéticas

Utilizando a base de dados SAR sintéticos, a metodologia CBIR foi aplicada usando a distância triangular, aritmética geométrica, Hellinger e, média harmônica apresentadas na Seção 3.3. A Tabela 5 apresenta os resultados dos experimentos com a distância triangular. Esta tabela evidencia um desempenho superior do *FLCM* em comparação com o *MLE* para regiões extremamente heterogêneas, com um MAP de 0,997 contra 0,817. Isso pode ser atribuído à maior precisão do *FLCM* em capturar a complexidade e a variabilidade das características em regiões com alta heterogeneidade. Nas regiões heterogêneas e homogêneas, os resultados são semelhantes entre os dois métodos, sugerindo que ambos são eficazes em ambientes de menor complexidade.

Tabela 5 – Resultados MAP com a distância triangular para imagens sintéticas e ambos os estimadores.

Região	<i>MLE</i>	<i>FLCM</i>
Extremamente Heterogênea	0,817	0,997
Heterogênea	0,845	0,847
Homogênea	0,820	0,859

Fonte: Elaborada pelo autor.

Os resultados mostram a relevância do grau de textura e estimativa de parâmetros para obter valores MAP próximos de 1. Quanto maior o grau de textura, melhor o desempenho do CBIR-SAR. *FLCM* obteve melhores resultados que *MLE*, porque o último encontrou um problema de convergência numérica no processo. No entanto, a medida MAP alcançou valores acima de 0,81 para todos os cenários.

Os resultados da Tabela 6 destacam uma discrepância notável no desempenho dos métodos em regiões homogêneas, onde o *MLE* alcançou um MAP de apenas 0,201, significativa-

Tabela 6 – Resultados MAP com a distância aritmética geométrica para imagens sintéticas e ambos os estimadores.

Região	<i>MLE</i>	<i>FLCM</i>
Extremamente Heterogênea	1,000	0,999
Heterogênea	0,778	0,845
Homogênea	0,201	0,868

Fonte: Elaborada pelo autor.

Tabela 7 – Resultados MAP com a distância Hellinger para imagens sintéticas e ambos os estimadores.

Região	<i>MLE</i>	<i>FLCM</i>
Extremamente Heterogênea	0,999	0,998
Heterogênea	0,852	0,844
Homogênea	0,870	0,867

Fonte: Elaborada pelo autor.

Tabela 8 – Resultados MAP com a distância média harmônica para imagens sintéticas e ambos os estimadores.

Região	<i>MLE</i>	<i>FLCM</i>
Extremamente Heterogênea	0,998	0,998
Heterogênea	0,846	0,843
Homogênea	0,855	0,866

Fonte: Elaborada pelo autor.

mente inferior ao 0,868 do *FLCM*. Este resultado pode ser devido a dificuldades de convergência do *MLE* em contextos com baixa variabilidade de textura, enquanto o *FLCM*, com sua abordagem algébrica direta, mantém uma performance consistente. Para regiões extremamente heterogêneas, ambos os métodos apresentam desempenhos muito bons, indicando sua eficácia em capturar a diversidade de características nessas áreas.

Na Tabela 7 observam-se resultados elevados e comparáveis para ambos os métodos em todas as categorias, com valores de MAP próximos a 1. Isso sugere que a distância Hellinger é particularmente robusta e eficaz na discriminação de regiões SAR, independentemente do método de estimação utilizado ou do grau de heterogeneidade das regiões.

Os resultados da Tabela 8 mostram um desempenho consistente de ambos os métodos em regiões extremamente heterogêneas, e um equilíbrio próximo no desempenho em regiões heterogêneas e homogêneas. Isso reitera a capacidade da distância média harmônica de funcionar bem em uma variedade de contextos de heterogeneidade, especialmente quando combinada com estimativas precisas dos parâmetros da distribuição  $G_I^0$ .

Nesta tese, a distância triangular foi selecionada para os testes com imagens reais devido às suas propriedades favoráveis, como não exigir esforço computacional extremo e ser eficaz tanto para regiões extremamente heterogêneas quanto para regiões homogêneas em imagens SAR (Rey *et al.*, 2022). Da mesma forma que Nascimento *et al.* (2010), lidamos com distâncias entre distribuições semelhantes, e, assim, apenas seus parâmetros são relevantes.

## 6.2 Experimentos com Imagens SAR Reais

Neste estudo, a abordagem proposta foi avaliada utilizando três imagens reais do banco de dados SAR, e 25 recortes das respectivas regiões de tamanho  $100 \times 100$  foram criados a partir de cada imagem original, resultando em um total de 75 imagens para cada banco de dados. Os parâmetros de rugosidade e escala foram estimados usando *MLE* e *FLCM*. Em seguida, calculamos a lista de classificação com base nas distâncias estocásticas obtidas, levando em consideração as propriedades estatísticas da imagem, e nos valores das medidas MAP para cada região da imagem. Os resultados obtidos mostram que este método pode fornecer ganhos significativos em diversos cenários, incluindo regiões homogêneas e heterogêneas, e diferentes polarizações.

Os resultados obtidos dos estimadores *MLE* e *FLCM* no banco de dados do radar UAVSAR de banda *L* são apresentados na Tabela 9. Apesar das regiões deste banco de dados serem relativamente homogêneas (com baixa rugosidade), o que dificulta a diferenciação, o método identificou com eficiência regiões homogêneas com resultados consistentes, especialmente para polarização VV. Essa polarização proporciona melhor contraste entre a mancha de óleo e o oceano, indicando que é um canal adequado para detectar variações de rugosidade e brilho da superfície do mar, como as causadas por derramamentos de óleo.

No canal HV, o estimador *MLE* não obteve bom resultado, principalmente na região do derramamento de óleo. Isso se deve à necessidade do estimador ter um método numérico e um palpite ou estimativa inicial para realizar sua convergência, neste caso específico houve o surgimento de *outliers* para valores de rugosidade em quantidades significativas. Como consequência, a distância triangular não obteve resultado, impactando em um baixo valor de MAP, devido à inconsistência nas distâncias calculadas. O *FLCM*, que faz uso de operações algébricas com fórmula fechada, obteve melhores resultados neste caso.

As Tabelas 10 e 11 apresentam os resultados obtidos utilizando os estimadores *MLE* e *FLCM* para as bases de dados OrbiSAR-2 e ALOS PALSAR. Ambos apresentam as mesmas

Tabela 9 – MAP usando a distância triangular, *MLE* e *FLCM* na base UAVSAR.

		UAVSAR			
		HH	HV	VH	VV
Água	<i>MLE</i>	0,751	0,620	0,713	<b>0,880</b>
	<i>FLCM</i>	0,949	0,959	0,947	<b>0,904</b>
Mancha de Óleo	<i>MLE</i>	0,854	0,302	0,956	<b>0,934</b>
	<i>FLCM</i>	0,943	0,978	0,938	<b>0,990</b>
Floresta	<i>MLE</i>	0,995	0,988	1,000	<b>0,833</b>
	<i>FLCM</i>	1,000	0,994	1,000	<b>0,856</b>

Em negrito estão os melhores resultados.

Fonte: Elaborada pelo autor.

Tabela 10 – MAP usando a distância triangular, *MLE* e *FLCM* na base ORBISAR-2.

		ORBISAR-2			
		HH	HV	VH	VV
Água	<i>MLE</i>	0,791	0,694	0,593	0,860
	<i>FLCM</i>	0,926	0,686	0,930	0,864
Área Urbana	<i>MLE</i>	<b>1,000</b>	<b>0,984</b>	<b>0,919</b>	<b>0,959</b>
	<i>FLCM</i>	<b>1,000</b>	<b>0,985</b>	<b>0,919</b>	<b>0,957</b>
Floresta	<i>MLE</i>	0,845	0,429	0,583	0,573
	<i>FLCM</i>	0,863	0,545	0,627	0,615

Em negrito estão os melhores resultados.

Fonte: Elaborada pelo autor.

Tabela 11 – MAP usando a distância triangular, *MLE* e *FLCM* na base ALOS PALSAR.

		ALOS PALSAR			
		HH	HV	VH	VV
Água	<i>MLE</i>	0,940	0,987	-	0,833
	<i>FLCM</i>	0,781	0,897	-	0,820
Área Urbana	<i>MLE</i>	<b>0,889</b>	<b>0,931</b>	-	0,618
	<i>FLCM</i>	<b>0,877</b>	<b>0,953</b>	-	0,617
Floresta	<i>MLE</i>	0,904	0,980	-	0,555
	<i>FLCM</i>	0,821	0,972	-	0,560

- dados indisponíveis para este canal.

Em negrito estão os melhores resultados.

Fonte: Elaborada pelo autor.

regiões imageadas, mas estes radares são de bandas diferentes, P e L, respectivamente.

Os experimentos com OrbiSAR-2 alcançaram os maiores valores de MAP para áreas urbanas, para todos os canais. Por outro lado, valores de MAP em torno de 0,5 indicaram que o CBIR-SAR considerou incorretamente amostras de água e floresta com textura semelhante. Tanto o *MLE* quanto o *FLCM* forneceram boas estimativas, com valores de MAP acima de 0,88 para amostras de água no canal VV. O canal HH obteve o melhor resultado para regiões de

florestas.

Os resultados com ALOS PALSAR para HH e HV foram superiores ao VV, principalmente em regiões extremamente heterogêneas. Por outro lado, VV apresentou os melhores resultados para a água. No geral, o CBIR-SAR teve melhor desempenho em regiões homogêneas para ambos os sensores da banda L. Os piores resultados para VV referem-se a regiões heterogêneas, ou seja, florestas.

A polarização é um fator importante nas imagens SAR, pois esta pode afetar a intensidade e a qualidade dos ecos do radar que retornam da superfície. Geralmente, a polarização paralela (HH ou VV) produz ecos mais fortes em comparação com a polarização cruzada (HV ou VH) (Avery; Berlin, 1992). No entanto, a escolha da polarização também depende das características do alvo e do ambiente. Por exemplo, em alguns casos, a polarização cruzada pode fornecer melhor contraste para certas características, como a detecção de derramamentos de óleo em superfícies de água.

Este estudo considerou as propriedades estatísticas da imagem SAR, que é complexa devido à interação das micro-ondas com a superfície. Os resultados com MAP mostram que a metodologia proposta obtém ganhos significativos em diversos cenários, incluindo os diferentes sensores, canais de polarização, bandas e os estimadores empregados.

A ausência de uma comparação direta do presente trabalho com outras pesquisas da literatura pode ser atribuída a abordagem adotada neste estudo, que representa uma contribuição original e distinta na área de processamento de imagens SAR. Dada a natureza inovadora e a especificidade dos métodos aplicados, existe uma limitação em relação à disponibilidade de estudos diretamente comparáveis que empreguem técnicas similares para a recuperação de imagens SAR. A proposta deste trabalho também se concentra na avaliação dos parâmetros de rugosidade e escala da distribuição  $G_1^0$ , que é particularmente adequada para a descrição de dados SAR em intensidade. Esta especificidade dos parâmetros considerados contribui para a singularidade da abordagem e, conseqüentemente, para a dificuldade em encontrar estudos que façam uso de metodologias comparáveis em termos de precisão e aplicabilidade.

## 7 CONCLUSÕES E TRABALHOS FUTUROS

O método proposto é baseado em modelagem estatística de dados e distâncias estocásticas para realizar recuperação baseada em conteúdo em imagens SAR. As imagens SAR de 1 visada (*single look*) são mais desafiadoras devido à presença marcante do ruído *speckle*. A distribuição  $G_I^0$  modela os dados SAR em intensidade e seus parâmetros são estimados por dois métodos de estimação, ou seja, o estimador de máxima verossimilhança e a abordagem rápida por log-cumulantes. As características de entrada do sistema CBIR compreendem os parâmetros estimados da região da imagem e a distância triangular compara a similaridade entre as regiões da imagem. Esses parâmetros estimados representam as características de rugosidade e brilho médio que discriminam as regiões da imagem. Vale ressaltar que a distância estocástica utilizada como medida de similaridade é dependente da qualidade da estimativa dos parâmetros. Ambos os métodos de estimação foram testados, *MLE* devido às suas boas propriedades como consistência, normalidade assintótica, eficiência e o *FLCM* devido à sua velocidade de estimação.

Os experimentos realizados demonstraram a eficácia do método proposto com imagens SAR sintéticas e imagens SAR reais. Para ambos os estimadores, o CBIR-SAR obteve os maiores valores de MAP para regiões extremamente heterogêneas. Esses resultados confirmaram que o método proposto é capaz de recuperar regiões de textura semelhante com base no parâmetro de rugosidade; portanto, é bastante dependente da textura da região. No entanto, obteve resultados satisfatórios para regiões homogêneas e foi capaz de revelar diferenças sutis de textura entre derramamentos de óleo e água. Os resultados de dados SAR sintéticos e reais suportam que o CBIR-SAR proposto fornece uma solução eficaz para superar os desafios impostos pelo ruído *speckle* na recuperação de imagens SAR. O modelo estatístico de dados, os métodos de estimativa e distância estocástica foram avaliados no desenvolvimento de um sistema especialista que pode organizar e consultar regiões de imagens SAR de forma mais eficiente. Testes com outras distâncias utilizando imagens reais e dados estocásticos podem estender o método para outros cenários e aplicações, como detecção e classificação de mudanças.

Dentre as vantagens da metodologia proposta podemos listar a capacidade do sistema CBIR-SAR em recuperar diferentes regiões da imagem com base nos parâmetros do modelo  $G_I^0$ , que são características da imagem incorporadas na distância triangular estocástica; nossa abordagem lida com dados brutos e, portanto, não requer uma etapa de pré-processamento devido à presença do ruído *speckle*; a metodologia apresentou resultados promissores ao empregar dois diferentes métodos de estimação de parâmetros. Vale ressaltar que os resultados do sistema

CBIR-SAR podem auxiliar outras técnicas de processamento de imagem, como segmentação e classificação de imagens SAR. Uma desvantagem da metodologia adotada diz respeito ao método *MLE* que requer a utilização de técnicas numéricas.

## REFERÊNCIAS

- ABRAMOWITZ, M.; STEGUN, I. A. **Handbook of Mathematical Functions with Formulas, Graphs, and Mathematical Tables**. 9. ed. New York: Dover, 1964.
- ALSHEHRI, M. A content-based image retrieval method using neural network-based prediction technique. **Arabian Journal for Science and Engineering**, Springer, v. 45, n. 4, p. 2957–2973, 2020.
- ARFKEN, G. B.; WEBER, H. J. **Mathematical Methods for Physicists**. San Diego, United States of America: AAPT, 1995.
- ARGENTI, F.; LAPINI, A.; BIANCHI, T.; ALPARONE, L. A tutorial on speckle reduction in synthetic aperture radar images. **IEEE Geoscience and Remote Sensing Magazine**, IEEE, v. 1, n. 3, p. 6–35, 2013.
- AVERY, T.; BERLIN, G. **Fundamentals of Remote Sensing and Airphoto Interpretation**. [S. l.]: Macmillan, 1992. (Prentice Hall series in geographic information science). ISBN 9780023050350. Disponível em: <https://books.google.com.br/books?id=5WYZAQAAIAAJ>. Acesso em: 21 set. 2022.
- AVIYENTE, S. Divergence measures for time-frequency distributions. *In*: IEEE. **Signal Processing and Its Applications, 2003. Proceedings. Seventh International Symposium on**. [S. l.], 2003. v. 1, p. 121–124.
- BENTZ, C. M. **Reconhecimento Automático de Eventos Ambientais Costeiros e Oceânicos em Imagens de Radares Orbitais**. Tese (Doutorado em Engenharia Civil) – Programa de Pós-graduação de Engenharia da Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.
- BRAGA, I. H. T.; SACRAMENTO, V. P.; OLIVEIRA, L. C. C.; MEDEIROS, F. N. S.; RODRIGUES, F. A. Á. Ocean surface change detection from remote sensing image based on stochastic similarity measure. **Brazilian Journal of Water Resources**, SciELO Brasil, v. 27, 2022.
- BUSTOS, O. H.; LUCINI, M. M.; FRERY, A. C. M-estimators of roughness and scale for  $g_a^0$ -modelled SAR imagery. **EURASIP Journal on Applied Signal Processing**, v. 1, p. 105–114, 2002.
- CASELLA, G.; BERGER, R. L. **Statistical inference**. [S. l.]: Cengage Learning, 2021.
- CHEN, Y.; WANG, Z. Marine oil spill detection from SAR images based on attention u-net model using polarimetric and wind speed information. **International Journal of Environmental Research and Public Health**, v. 19, n. 19, 2022. ISSN 1660-4601. Disponível em: <https://www.mdpi.com/1660-4601/19/19/12315>. Acesso em: 13 dez. 2022.
- DABBOOR, M.; BRISCO, B. Wetland monitoring and mapping using synthetic aperture radar. **Wetlands Management: Assessing Risk and Sustainable Solutions**, v. 1, p. 13, 2018.
- DONATELLI, J.; HARANCZYK, M.; HEXEMER, A.; KRISHNAN, H.; LI, X.; LIN, L.; MAIA, F.; MARCHESINI, S.; PARKINSON, D.; PERCIANO, T.; SHAPIRO, D.; USHIZIMA, D.; YANG, C.; SETHIAN, J. Camera: The center for advanced mathematics for energy research applications. **Synchrotron Radiation News**, v. 28, n. 2, p. 4–9, 2015.

FERREIRA, J. A.; NASCIMENTO, A. D. C. Shannon entropy for the  $G_7^0$  model: A new segmentation approach. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 2547–2553, 2020.

FLORINDO J. B.; BRUNO, O. M. Multiscale fractal descriptors applied to texture classification. **Journal of Physics: Conference Series**, IOP Publishing Ltd, n. 1, p. 012022, 2013.

FRERY, A. C.; MULLER, H.-J.; YANASSE, C. C. F.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 35, n. 3, p. 648–659, 1997.

FRERY, A. C.; WU, J.; GOMEZ, L. **SAR Image Analysis—A Computational Statistics Approach**. New Jersey: Wiley, 2022.

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, 2015.

GAO, G. Statistical modeling of SAR images: A survey. **Sensors**, v. 10, n. 1, p. 775–795, 2010.

GENOVEZ, P.; EBECKEN, N.; FREITAS, C.; BENTZ, C.; FREITAS, R. Intelligent hybrid system for dark spot detection using SAR data. **Expert Systems with Applications**, Elsevier, v. 81, p. 384–397, 2017.

GONZALEZ, R. C.; WOODS, R. **Digital Imaging Processing**. 3 ed.. ed. [S. l.]: Upper Saddle River, NJ, USA: Prentice Hall, 2006.

HARALICK R. M.; SHANMUGAM, K. D. I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, IEEE, v. 3, n. 6, p. 610 – 621, 1973.

HIRATA, K.; KATO, T. Query by visual example - content based image retrieval. *In: Proceedings of the 3rd International Conference on Extending Database Technology: Advances in Database Technology*. London, UK: Springer-Verlag, 1992. (EDBT '92), p. 56–71. ISBN 3-540-55270-7.

HORTA, M. M. **Modelos de mistura de distribuições na segmentação de imagens SAR polarimétricas multi-look**. Tese (Doutorado em Física) – Instituto de Física de São Carlos, Universidade de São Paulo, São Paulo, 2009.

JIAO, L.; TANG, X.; HOU, B.; WANG, S. SAR images retrieval based on semantic classification and region-based similarity measure for earth observation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 8, p. 3876–3891, 2015.

JUNIOR, P. M. A.; NASCIMENTO, A. D. C.  $g_i^0$  arma process for speckled data. **Journal of Statistical Computation and Simulation**, v. 91, n. 15, p. 3125–3153, 2021.

KATO, T. Database architecture for content-based image retrieval. *In: Proc. of SPIE Image Storage and Retrieval Systems*. San Jose, CA, USA: [S. n.], 1992. v. 1662, p. 112–123.

KRISHNA, G. S.; PRAKASH, N. Deep learning for efficient and multi-labelled classification of synthetic aperture radar images. **Evolving Systems**, Springer, v. 12, n. 3, p. 741–754, 2021.

LEE, J.-S.; POTTIER, E. **Polarimetric radar imaging: from basics to applications**. [S. l.]: CRC Press, 2009.

LIU X.; YOU, X. C. Y. Texture image retrieval using non-separable wavelets and local binary patterns. **International Conference on Computational Intelligence and Security**, IEEE, v. 1, p. 287 – 291, 2009.

LIU, Y.; ZHANG, D.; LU, G.; MA, W.-Y. A survey of content-based image retrieval with high-level semantics. **Pattern Recognition**, Elsevier, v. 40, n. 1, p. 262–282, 2007.

MARQUES, R. C. P. **Filtragem de Ruído Speckle em Imagens de Radar de Abertura Sintética e Avaliação dos Efeitos sobre a Segmentação**. Dissertação (Mestrado em Engenharia de Teleinformática) – Programa de Pós-graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Ceará, 2004.

MARQUES, R. C. P. **Caracterização de regiões em imagens da radar de abertura sintética com aplicações por segmentação por Level Set**. Tese (Doutorado em Engenharia de Teleinformática) – Programa de Pós-graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, 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 Transactions 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.

NARAYANAN, R. M.; WOOD, N. S.; LEWIS, B. P. Assessment of various multimodal fusion approaches using synthetic aperture radar (SAR) and electro-optical (EO) imagery for vehicle classification via neural networks. **Sensors**, MDPI, v. 23, n. 4, p. 2207, 2023.

NASCIMENTO, A. D. C.; CINTRA, R. J.; FRERY, A. C. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 48, n. 1, p. 373–385, 2010.

NICOLAS, J.-M. Introduction aux statistiques de deuxième espèce: Applications des logs-moments et des logs-cumulants à l’analyse des lois d’images radar. **TS. Traitement du Signal**, Lavoisier, v. 19, n. 3, p. 139–167, 2002.

NOBRE, R. H.; RODRIGUES, F. A. A.; MARQUES, R. C. P.; NOBRE, J. S.; NETO, J. F. S. R.; MEDEIROS, F. N. S. SAR Image Segmentation With Renyi’s Entropy. **IEEE Signal Processing Letters**, v. 23, n. 11, p. 1551–1555, 2016.

PERAL, E.; IM, E.; WYE, L.; LEE, S.; TANELLI, S.; RAHMAT-SAMII, Y.; HORST, S.; HOFFMAN, J.; YUN, S.-H.; IMKEN, T. *et al.* Radar technologies for earth remote sensing from cubesat platforms. **Proceedings of the IEEE**, IEEE, v. 106, n. 3, p. 404–418, 2018.

R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2021. Disponível em: <https://www.R-project.org/>. Acesso em: 10 mar. 2022.

RAO, A.; JUNG, J.; SILVA, V.; MOLINARIO, G.; YUN, S.-H. Earthquake building damage detection based on synthetic-aperture-radar imagery and machine learning. **Natural Hazards and Earth System Sciences**, Copernicus GmbH, v. 23, n. 2, p. 789–807, 2023.

REY, A.; SARMIENTO, N. R.; FRERY, A. C.; DELRIEUX, C. Automatic delineation of water bodies in SAR images with a novel stochastic distance approach. **Remote Sensing**, v. 14, n. 22, 2022. ISSN 2072-4292. Disponível em: <https://www.mdpi.com/2072-4292/14/22/5716>. Acesso em: 22 dez. 2022.

RODRIGUES, F. A. A.; NOBRE, J. S.; VIGÉLIS, R.; LIESENBERG, V.; MARQUES, R. C. P.; MEDEIROS, F. N. S. A fast approach for the log-cumulants method applied to intensity SAR image processing. *In: Proceedings of the 1st IEEE Latin American GRSS and ISPRS Remote Sensing Conference (LAGIRS)*. Santiago, Chile: IEEE, 2020. p. 494–498.

RODRIGUES, F. A. Ávila. **Método de Log-cumulantes em Processamento de Imagens SAR**. Tese (Doutorado em Engenharia de Teleinformática) – Programa de Pós-graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Ceará, 2017.

SALICRÚ, M.; MORALES, D.; MENÉNDEZ, M.; PARDO, L. On the applications of divergence type measures in testing statistical hypotheses. **Journal of Multivariate Analysis**, Elsevier, v. 51, n. 2, p. 372–391, 1994.

SCHRODER, M.; REHRAUER, H.; SEIDEL, K.; DATCU, M. Interactive learning and probabilistic retrieval in remote sensing image archives. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 38, n. 5, p. 2288–2298, 2000.

SILVA, R. R. V. e. **Detecção Automática de Células Cervicais com Base em Atributos Radiais**. Tese (Doutorado em Engenharia de Teleinformática) – Programa de Pós-graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Ceará, 2018.

SMEULDERS A. W. M.; WORRING, M. S. S. G. A. J. R. Content-based image retrieval at the end of the early years. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, p. 1349 – 1380, 2000.

SOUZA, M. M. de; MEDEIROS, F. N.; RAMALHO, G. L.; JR., I. C. de P.; OLIVEIRA, I. N. Evolutionary optimization of a multiscale descriptor for leaf shape analysis. **Expert Systems with Applications**, v. 63, p. 375 – 385, 2016.

TANG, X.; JIAO, L. Fusion similarity-based reranking for SAR image retrieval. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 2, p. 242–246, 2017.

TANG, X.; JIAO, L.; EMERY, W. J. SAR image content retrieval based on fuzzy similarity and relevance feedback. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 5, p. 1824–1842, 2017.

TORRES, L.; SANT’ANNA, S. J. S.; COSTA, C. F. da; FRERY, A. C. Speckle reduction in polarimetric SAR imagery with stochastic distances and nonlocal means. **Pattern Recognition**, v. 47, n. 1, p. 141–157, 2014.

TORRES R. S.; FALCÃO, A. X. Content-based image retrieval: Theory and applications. **Revista de Informática Teórica e Aplicada**, Universidade Federal do Rio Grande do Sul, v. 13, n. 2, p. 161–185, 2006.

ULLMAN, S. **High-level vision**. 3 ed.. ed. [S. l.]: Cambridge, Massachusetts, USA: MIT Press, 1995.

WANG, B.; BROWN, D.; GAO, Y.; SALLE, J. L. March: Multiscale-arch-height description for mobile retrieval of leaf images. **Information Sciences**, Elsevier, v. 302, p. 132–148, 2015.

YU, X.; ZHANG, H.; LUO, C.; QI, H.; REN, P. Oil spill segmentation via adversarial  $f$ -divergence learning. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, 2018.

ZHANG, K.; LI, B.; TAO, R. Sar image retrieval based-on fly algorithm. *In: Proceedings of the 10th International Conference on Advanced Computational Intelligence (ICACI)*. Xiamen, China: IEEE, 2018. p. 502–507. Trabalho apresentado no 10th International Conference on Advanced Computational Intelligence (ICACI), 2018, Xiamen, China.

ZHANG, T.; ZENG, T.; ZHANG, X. **Synthetic Aperture Radar (SAR) Meets Deep Learning**. [S. l.]: Multidisciplinary Digital Publishing Institute, 2023. 303 p.

ZYL, J. van; KIM, Y. **Synthetic aperture radar polarimetry**. [S. l.]: John Wiley & Sons, 2011. v. 2.

**ANEXO A - PRODUÇÃO CIENTÍFICA**

# CBIR-SAR System Using Stochastic Distance

Alcilene Dalíia Sousa <sup>1,2,\*</sup> , Pedro Henrique dos Santos Silva <sup>3</sup>, Romuere Rodrigues Veloso Silva <sup>1</sup> , Francisco Alexandre Ávila Rodrigues <sup>4</sup>  and Fatima Nelsizeuma Sombra Medeiros <sup>2</sup>

<sup>1</sup> Informatics Systems, Federal University of Piauí, Picos 64607-825, Piauí, Brazil; romuere@ufpi.edu.br

<sup>2</sup> Teleinformatics Engineering, Federal University of Ceará, Fortaleza 60455-970, Ceará, Brazil; fsombraufc@gmail.com

<sup>3</sup> Computer Engineering, Federal University of Ceará, Fortaleza 60455-970, Ceará, Brazil; pedrosantossilva05@alu.ufc.br

<sup>4</sup> Computational Mathematics, Federal University of Cariri, Juazeiro do Norte 63048-080, Ceará, Brazil; alixandre.avila@ufca.edu.br

\* Correspondence: alcilene@ufpi.edu.br

**Abstract:** This article proposes a system for Content-Based Image Retrieval (CBIR) using stochastic distance for Synthetic Aperture Radar (SAR) images. The methodology consists of three essential steps for image retrieval. First, it estimates the roughness ( $\hat{\alpha}$ ) and scale ( $\hat{\gamma}$ ) parameters of the  $G_1^0$  distribution that models SAR data in intensity. The parameters of the model were estimated using the Maximum Likelihood Estimation and the fast approach of the Log-Cumulants method. Second, using the triangular distance, CBIR-SAR evaluates the similarity between a query image and images in the database. The stochastic distance can identify the most similar regions according to the image features, which are the estimated parameters of the data model. Third, the performance of our proposal was evaluated by applying the Mean Average Precision (MAP) measure and considering clippings from three radar sensors, i.e., UAVSAR, OrbiSar-2, and ALOS PALSAR. The CBIR-SAR results for synthetic images achieved the highest MAP value, retrieving extremely heterogeneous regions. Regarding the real SAR images, CBIR-SAR achieved MAP values above 0.833 for all polarization channels for image samples of forest (UAVSAR) and urban areas (ORBISAR). Our results confirmed that the proposed method is sensitive to the degree of texture, and hence, it relies on good estimates. They are inputs to the stochastic distance for effective image retrieval.

**Keywords:** SAR; CBIR; stochastic distance; fast log-cumulants method; maximum likelihood estimation



**Citation:** Sousa, A.D.; Silva, P.H.d.S.; Silva, R.R.V.; Rodrigues, F.A.Á.; Medeiros, F.N.S. CBIR-SAR System Using Stochastic Distance. *Sensors* **2023**, *23*, 6080. <https://doi.org/10.3390/s23136080>

Academic Editor: Ram M. Narayanan

Received: 22 May 2023

Revised: 27 June 2023

Accepted: 29 June 2023

Published: 1 July 2023



**Copyright:** © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction

Content-Based Image Retrieval (CBIR) is an important research area in computer vision and information retrieval. It enables users to search for images based on their visual content rather than relying on text-based descriptions or metadata. CBIR systems use features extracted from images to compute the similarity between a reference image and other samples in a database. In the case of SAR images, CBIR can be challenging due to the unique properties of the data, such as the speckle noise, number of looks and spatial resolution to name a few. In the literature, there are different techniques to perform CBIR using SAR images [1–7].

SAR systems offer advantages as they are not dependent on solar light and atmospheric conditions [8,9]. However, analyzing SAR images is difficult due to the multiplicative granulation caused by speckle, which results from the interference of electromagnetic waves. Although filters can be applied to reduce this effect, it may come at the cost of reduced image quality. Therefore, statistical modeling techniques are used to process and interpret these images. Here, the  $G_1^0$  distribution was adopted to model intensity SAR data [10–12] and to develop the CBIR-SAR.

In general, the CBIR systems available in the literature use similarity measures that do not consider that image regions can be discriminated using the estimated parameters of the

image model. In fact, it is possible to understand an image as a set of regions that can be described by different probability laws [13]. Thus, it is possible to use stochastic distances to statistically discriminate distributions for SAR image retrieval purposes.

Thus, the aim of this paper is to advance the state-of-the-art on the use of a stochastic distance to overcome the limitation of the classic CBIR to deal with SAR images due to the speckle noise. To achieve this goal, the triangular stochastic distance measures the similarity between regions with different roughness levels or textures based on the parameters of the  $G_I^0$  distribution to develop the CBIR-SAR.

To estimate the parameters of the  $G_I^0$  model, the Maximum Likelihood Estimation (MLE) [14] and the Fast Log-Cumulants Method (FLCM) [12] are applied to the intensity images. Additionally, a stochastic similarity measure uses the estimated parameters [13,15], which are the SAR image features, to distinguish image regions. After obtaining the distances, they are arranged in the ascending order and generate a ranking list of image regions. Then, the performance of the information retrieval system is evaluated by using the Mean Average Precision (MAP) [16].

The main contributions of this work are as follows: (a) development of a reproducible CBIR system based on the intensity SAR data model that evaluates two estimation parameter methods as image feature extractors; and (b) establishment of a knowledge-based information retrieval inspired by stochastic distances and data modeling extensible to other statistical models and stochastic distances.

This paper unfolds as follows: Section 2 describes the fundamental background required to develop the proposed approach. Section 3 introduces a system for content-based SAR image retrieval using a stochastic distance. Section 4 shows the results and discussions, and Section 5 summarizes our findings and conclusions.

## 2. Background on SAR Data Modeling

This section presents the statistical model for intensity SAR images, i.e., the  $G_I^0$  distribution, the parameter estimation methods, and the stochastic distance.

### 2.1. Statistical Model for Intensity SAR Data

Here, the  $G_I^0$  distribution was adopted to model SAR data in intensity. The probability density function of the  $G_I^0$  is defined as [10]:

$$f_z(z; \alpha, \gamma, L) = \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{L-1} (\gamma + Lz)^{\alpha-L}, \quad (1)$$

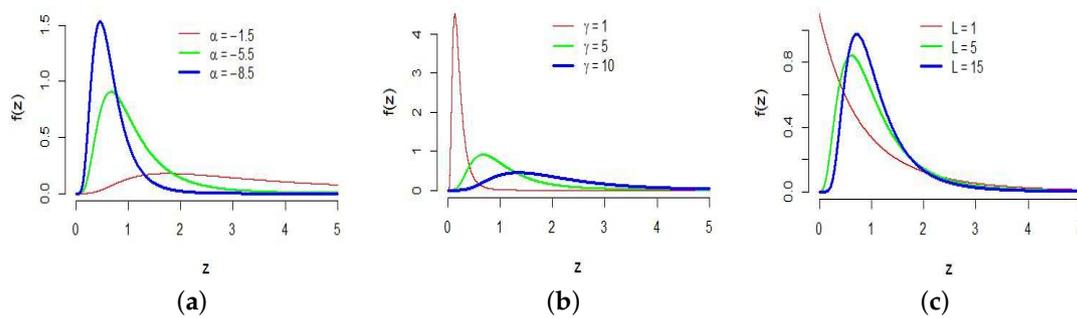
with  $-\alpha, \gamma, L, z > 0$ . The parameters  $\alpha$  and  $\gamma$  correspond to the roughness and scale, respectively,  $\Gamma(\cdot)$  is the gamma function defined as [17]:

$$\Gamma(w) = \frac{1}{w e^{\tau w} \prod_{k=1}^{\infty} (1 + \frac{w}{k}) e^{-\frac{w}{k}}}, \quad (2)$$

with  $w > 0$  and the  $L$  parameter is known as the number of looks, which represents the speckle control parameter. The influence of the parameters  $(\alpha, \gamma, L)$  in the shape of the  $G_I^0$  distribution can be seen in Figure 1.

Figure 1a shows the effect of varying the parameter  $\alpha$  for the same  $L = 8$  and  $\gamma = 5$ . Notice that when the value of  $\alpha$  decreases, the probability density function tends to be more homogeneous, representing image regions that are more homogeneous. Figure 1b shows the effect of varying the parameter  $\gamma$  for the same  $\alpha = -5.5$  and  $L = 8$ . In [18], the  $\gamma$  parameter is related to the brightness of the scene.

Finally, Figure 1c shows the effect of the number of looks, i.e., varying the parameter  $L$  for the same  $\alpha = -5.5$  and  $\gamma = 5$ . It also exhibits that the number of looks has an effect mostly on the distribution of very small values. Notice that when  $L$  decreases, the  $G_I^0$  distribution assigns more probability to small values of the return  $z$ , yielding less contrasted images [19] and consequently more challenging images.



**Figure 1.** Densities of the  $G_I^0$  distribution with different parameters. (a)  $\alpha \in \{-1.5, -5.5, -8.5\}$ ,  $L = 8$ ,  $\gamma = 5$ , (b)  $\gamma \in \{1, 5, 10\}$ ,  $L = 8$ ,  $\alpha = -5.5$  and (c)  $L \in \{1, 5, 15\}$ ,  $\alpha = -5.5$ ,  $\gamma = 5$ .

The great advantage of using the  $G_I^0$  distribution is that it can accurately model homogeneous, heterogeneous and extremely heterogeneous regions of an intensity SAR image [10]. This flexibility has motivated some important applications, such as SAR image segmentation driven by the  $G_I^0$  Shannon entropy [20] and autoregressive moving average process for speckled data [21], among others.

## 2.2. Parameter Estimation for the $G_I^0$ Distribution

To estimate the parameters of the  $G_I^0$  distribution [10], two methods were selected: the Maximum Likelihood Estimation [13] and the Fast Log-Cumulants Method [12]. Here, the number of looks,  $L$ , is considered known. The  $L$  parameter is generally an integer provided by the SAR sensor, and in this paper, it is a priori information. However, in the absence of it, the number of looks can be estimated from real SAR data, and it is therefore interesting to call the equivalent number of looks [22].

### 2.2.1. Maximum Likelihood Estimation (MLE)

Consider a random variable  $Z$  with probability density function  $f(z, \theta)$ , where  $\theta$  is the vector of parameters to be estimated and  $(z_1, z_2, \dots, z_n)$  is a random sample of size  $n$  from the variable  $Z$ . The likelihood function  $L(\theta; z_1, z_2, \dots, z_n)$  is defined by [14]:

$$L(\theta; z_1, z_2, \dots, z_n) = \prod_{i=1}^n f(z_i, \theta), \quad (3)$$

which is interpreted as a function of  $\theta$ . The maximum likelihood estimator of  $\theta$  will be the one that maximizes  $L(\theta; z_1, z_2, \dots, z_n)$ .

For the  $G_I^0$  distribution, the likelihood function is given by [13]:

$$L_{G_I^0}(\alpha, \gamma, L; z) = \left( \frac{L^L \Gamma(L - \alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} \right)^n \prod_{i=1}^n z_i^{L-1} (\gamma + Lz_i)^{\alpha-L}. \quad (4)$$

The values of  $\alpha$  and  $\gamma$  that maximize Equation (4) can be obtained by finding the solution of the following system of nonlinear equations.

$$\begin{cases} n \left[ -\psi^0(L - \hat{\alpha}) - \log(\hat{\gamma}) + \psi^0(-\hat{\alpha}) \right] + \sum_{i=1}^n \log(\hat{\gamma} + Lz_i) = 0 \\ -\frac{n\hat{\alpha}}{\hat{\gamma}} + (\hat{\alpha} - L) \sum_{i=1}^n \frac{1}{\hat{\gamma} + Lz_i} = 0, \end{cases} \quad (5)$$

where  $\Psi(\cdot)^0$  is the digamma function [17,23] and  $\hat{\alpha}$  and  $\hat{\gamma}$  are the maximum likelihood estimators for  $\alpha$  and  $\gamma$ , respectively. Given that there are no feasible inverse functions for  $\psi^0(\cdot)$ , the nonlinear system in Equation (5) cannot be solved explicitly, and therefore, it requires iterative procedures. In fact, it is a difficult task, in particular in textureless areas [19].

In order to solve this problem here, we applied a numerical routine based on the Broyden–Fletcher–Goldfarb–Shanno algorithm (*BFGS*), which was implemented in R software through the *maxLik* function. A good solution consists of using estimates obtained with the Method of Moments [10] as the initial guess for the *BFGS* algorithm. The algorithm *BFGS* starts at initial estimates for the optimal values of  $\hat{\alpha}$  and  $\hat{\gamma}$  and proceeds iteratively to search for better estimates at each stage.

### 2.2.2. Fast Log-Cumulants Method (*FLCM*)

This method presents analytical expressions for estimating the roughness ( $\alpha$ ) and scale ( $\gamma$ ) parameters of the  $G_T^0$  distribution. Using *FMLC*, the roughness parameter can be estimated by the following expression [12]:

$$\hat{\alpha} = \begin{cases} -\left| \sqrt{\frac{1}{\tilde{k}_2 - \Psi^1(L)}} \right|, & \text{if } \tilde{k}_2 - \Psi^1(L) < 0 \\ -\sqrt{\frac{1}{\tilde{k}_2 - \Psi^1(L)}}, & \text{if } \tilde{k}_2 - \Psi^1(L) > 0, \end{cases} \quad (6)$$

where  $|\cdot|$  stands for the modulus operator,  $\Psi(\cdot)^1$  is the trigamma function [17] and  $\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2$  is the log-cumulant of order 2. Usually,  $(\tilde{m}_1, \tilde{m}_2)$  must be replaced by the corresponding sample log-moment of order  $v = 1$  and  $v = 2$ , respectively, which can be calculated as [24]:

$$\hat{m}_v = \frac{1}{n} \sum_{i=1}^n \ln z_i^v, \quad (7)$$

with  $z_i, i \in \{1, 2, \dots, n\}$  being a sample of a random variable  $Z$ . After obtaining  $\hat{\alpha}$ , the  $\gamma$  parameter can be estimated by:

$$\hat{\gamma} = \exp \left[ \tilde{k}_1 - \Psi^0(L) + \Psi^0(-\hat{\alpha}) \right] L, \quad (8)$$

where  $\tilde{k}_1 = \tilde{m}_1$  and  $\Psi^0(\cdot)$  is the digamma function [17].

### 2.3. Stochastic Distance

Contrast analysis often addresses the problem of quantifying how distinguishable two image regions are from each other [13], and a distance metric plays a crucial role to perform it. Similarly, CBIR systems rely on image content similarity and require distance metrics. Due to the statistical properties of SAR data, CBIR systems require suitable distances. In fact, stochastic distances are relevant tools for SAR image analysis and understanding, since they are capable of assessing differences between regions in a scene.

In this paper, the triangular distance was selected due to its favorable properties, such as not requiring an extreme computational effort and being effective for both extremely heterogeneous and homogeneous regions in SAR images [25]. Similarly to [13], we deal with distances between the same distributions, and thus, only their parameters are relevant. The triangular distance is described as:

$$d_T(Z_1, Z_2) = \int \left( \frac{(f_{Z_1}(z, \theta_1) - f_{Z_2}(z, \theta_2))^2}{f_{Z_1}(z, \theta_1) + f_{Z_2}(z, \theta_2)} \right) dz, \quad (9)$$

where  $Z_1$  and  $Z_2$  are random variables defined in the same probability space, with probability density functions  $f_{Z_1}(z, \theta_1)$  and  $f_{Z_2}(z, \theta_2)$ , respectively, where  $\theta_1$  and  $\theta_2$  are arrays of parameters.

## 3. Proposed Methodology

The proposed CBIR method is based on the knowledge that comes from the statistical model of real SAR images. It uses intensity images acquired from synthetic aperture

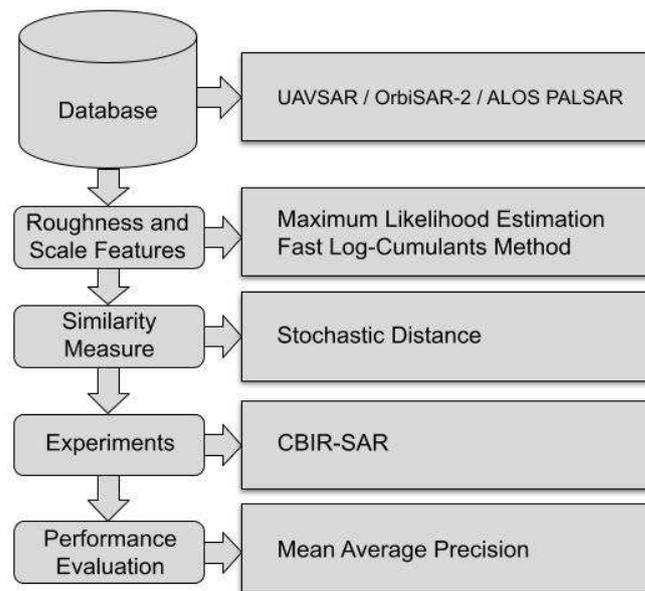
radar. The database consists of 25 clipping of images of each region (e.g., water, oil spill, forest) from UAVSAR and 25 images of each region (e.g., water, urban area, and forest) from OrbiSAR-2 and ALOS PALSAR. The Maximum Likelihood Estimation and the fast approach of the Log-Cumulative Method are the methods that estimate the roughness and scale parameters for each image region. The number of looks provided by the SAR sensors is equal to 1. Table 1 presents this radar information. The reason for dealing with single-look images is that they are markedly affected by speckle and pose potential challenges for the algorithm. Thus, all tests are performed with single-look images.

**Table 1.** Radar Information.

<b>UAVSAR</b>		
	Covered Place	New Orleans, LA, USA
Physical Information	Height (km)	265.26
	Width (km)	16.49
	Area (km <sup>2</sup> )	4374.14
Radar Parameters	Sensor	SAR
	Polarization	HH, HV, VH, VV
	Band	L Band
Data Information	Product Format	SLC
	Number of Rows	442,106
	Number of Columns	9900
	Number of Looks	1
<b>ORBISAR-2</b>		
	Covered Place	Santos, Brazil
Physical Information	Height (km)	265.26
	Width (km)	16.49
	Area (km <sup>2</sup> )	4374.14
Radar Parameters	Sensor	SAR
	Polarization	HH, HV, VH, VV
	Band	P Band
Data Information	Product Format	SLC
	Number of Rows	26,616
	Number of Columns	8192
	Number of Looks	1
<b>ALOS PALSAR</b>		
	Covered Place	San Francisco, CA, USA
Physical Information	Height (km)	65.92
	Width (km)	28.57
	Area (km <sup>2</sup> )	1883.33
Radar Parameters	Sensor	SAR
	Polarization	HH, HV, VV
	Band	L Band
Image Data Information	Product Format	CEOS
	Number of Rows	18,432
	Number of Columns	1248
	Number of Looks	1

Figure 2 depicts the overall pipeline of the proposed CBIR. It shows that for the SAR image database, the parameters of the  $G_I^0$  distribution for each image region are estimated using *MLE* and *FLCM*. The main reason for using these parameter estimation methods is to assess the performance of the proposed algorithm on each one.

The estimates and the similarity measure are inputs to CBIR-SAR to compute the triangular stochastic distance between each query image and the other samples. Finally, the system outputs distances which provide a ranking list of the retrieved samples of water, oil spill, forest and urban area. Then, the MAP measure assesses the results. The higher the MAP value is, the better the performance of CBIR-SAR.

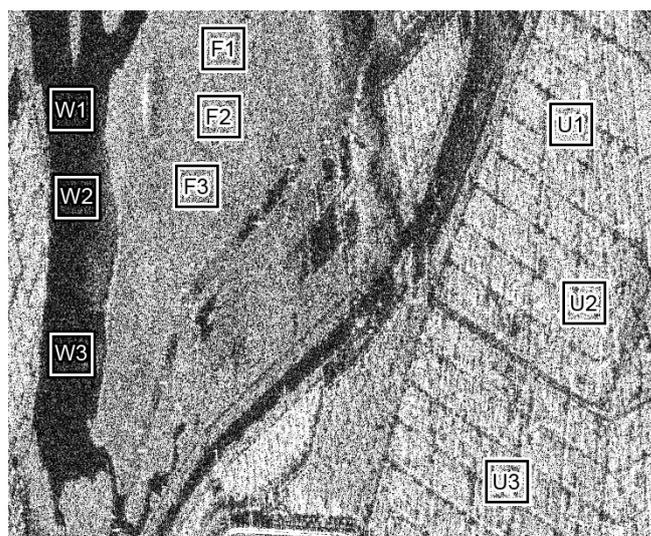


**Figure 2.** Flowchart of the proposed methodology.

### 3.1. SAR Database

The real SAR images were acquired from three different radars: single-look images from the airborne Uninhabited Aerial Vehicle Synthetic Aperture Radar (UAVSAR) from the National Aeronautics and Space Administration (NASA); OrbiSAR-2 from BRADAR; and ALOS Phased Array type L-band Synthetic Aperture Radar (ALOS PALSAR) from the National Aeronautics and Space Administration (NASA). To create the database, each image was manually cut and categorized into three regions according to the coverage area. The set of samples comprises 25 patches of  $100 \times 100$  pixels for each region of each radar polarization channel, i.e., HH, HV, VH and VV. The VH channel of ALOS PALSAR was unavailable.

Figure 3 exhibits samples of patches, where  $W1, W2, W3$  correspond to water,  $F1, F2, F3$  are forest regions and  $U1, U2, U3$  are urban areas. Table 1 presents important physical information about the three radars that acquired the real SAR images.



**Figure 3.** OrbiSAR-2 SAR image: Sample patches selected from water (W), forest (F) and urban areas (U).

### 3.2. Parameter Estimation

In this paper, the MLE and FLCM methods estimate the roughness and scale parameters of the  $G_I^0$  model for each image sample. In terms of CBIR-SAR, the parameter estimation extracts statistical information of images, and it corresponds to the feature extraction step of a CBIR system. Finally, the parameter estimates are inputs to the triangular stochastic distance. Given an image as an input query, CBIR-SAR calculates the distance between it and all images from the database.

### 3.3. CBIR-SAR

CBIR systems search for similar images in a database by assessing the similarity between the reference image and the other images in the database [26]. It uses visual image features to compute distances and arrange them in ascending order and generate a ranking list of images. Here, the visual features are the roughness ( $\hat{\alpha}$ ) and scale ( $\hat{\gamma}$ ) parameters of the  $G_I^0$  model.

The proposed CBIR based on a stochastic approach recognizes and retrieves SAR image regions such as water, forest, urban areas, and oil spills, taking into account the  $G_I^0$  model and the stochastic distance between same distributions, which is possibly indexed by different parameters. Then, CBIR-SAR performs image retrieval matching samples by statistical similarity.

### 3.4. Mean Average Precision (MAP)

For performance evaluation, the Mean Average Precision (MAP) [16] is used, as:

$$AP(Q) = \frac{\sum_{i=1}^{N_R} (P(i) * F(i))}{S}, \quad (10)$$

where  $P(i)$  is the precision until the position  $i$  of the ranking, and  $F(i)$  is equal to 1 if the image  $i$  of the ranking  $i$  belongs to the same class as the query image  $Q$  and 0 otherwise.  $N_R$  is the number of images in the ranking, and  $S$  is the number of images of the same class obtained by the query image. The MAP is obtained by the average AP for all images of the ranking within the range  $(0, 1)$ , and higher values indicate better performance.

## 4. Results and Discussion

This section presents the results and discussions based on the experiments carried out with CBIR-SAR applied to synthetic and real SAR images acquired from three different SAR sensors. The statistical computational environment used to carry out the experiments was the R language [27], version 4.1.2, on a machine with a CPU of up to 4.20 GHz and 16 GB of RAM.

### 4.1. Experiments with Synthetic SAR Images

Inspired by [22], the intensity SAR images were simulated using:

$$S = -\frac{\gamma}{\alpha} Y_{2L, -2\alpha}^{-1}(U), \quad (11)$$

where  $S$  represents the simulated image,  $Y_{2L, -2\alpha}^{-1}$  is the inverse function of the  $F$ -Snedecor distribution, with  $2L$  and  $-2\alpha$  being the degrees of freedom and  $U$  is a random variable with uniform distribution over the interval  $(0, 1)$ . To generate SAR images from Equation (11), the following steps are required:

- (i) Define the parameters  $(\alpha, \gamma, L)$ .
- (ii) Generate  $U$ , with desirable size, from the uniform distribution over the interval  $(0, 1)$ .
- (iii) Put  $U$  in Equation (11). The result will be a synthetic intensity SAR image, with parameters defined in step (i).

Three different sets of intensity SAR images ( $S_1, S_2, S_3$ ) were simulated using Equation (11), where each set comprises 25 image samples of  $100 \times 100$  pixels. Our simulations considered the  $\alpha$  parameter values referring to extremely heterogeneous regions (urban areas) in the interval  $\alpha \in (-0.35, -1.52)$  for  $S_1$  as well as to heterogeneous regions (forest areas). The values are in the interval  $\alpha \in (-10.14, -23.75)$  for  $S_2$  and homogeneous regions (water, oil) are in the interval  $\alpha \in (-55.79, -71.08)$  for  $S_3$ . With regard to the other parameters, the  $\gamma$  values were adopted in the interval  $\gamma \in (1, 7)$  and  $L = 1$ . After generating the synthetic SAR image database, it we applied the CBIR methodology described in Section 3. Table 2 presents the results of the experiments. It shows the MAP values using both estimators and three regions with different roughness levels.

**Table 2.** MAP results for synthetic images and both estimators.

Region	MLE	FLCM
Extremely Heterogeneous	0.817	0.997
Heterogeneous	0.845	0.847
Homogeneous	0.820	0.859

The results show the relevance of the texture degree and the parameter estimation to obtain MAP values close to 1.0. The higher the degree of texture, the better the performance of CBIR-SAR. *FLCM* obtained better results than *MLE* because the latter encountered a numerical convergence problem in the process. However, MAP reached values above 0.81 for all scenarios.

#### 4.2. Experiments with Real SAR Images

In this study, the proposed approach was evaluated using three real images from the SAR database, and 25 clippings of the respective regions of size  $100 \times 100$  were created from each original image, resulting in a total of 75 images for each database. The roughness and scale parameters were estimated using *FLCM* and *MLE*. Then, we calculated the ranking list based on the obtained stochastic distances and the MAP measure value for each image region.

Table 3 presents the results for the different sensors, polarization channels, and bands. The L-band UAVSAR radar database showed promising results using both estimators and all polarization channels. The method efficiently identified homogeneous regions with consistent results, especially for the VV polarization. This polarization provides better contrast between the oil slick and the ocean, which indicates that it is a suitable channel to detect roughness and brightness variations from the sea surface, such as those caused by oil spills.

The experiments with OrbiSAR-2 achieved the highest MAP values for urban areas for all channels. On the other hand, MAP values around 0.5 indicate that CBIR-SAR incorrectly considered water and forest samples with similar texture. Both *MLE* and *FCLM* provided good estimates and hence MAP values above 0.88 for water samples in VV. The HH channel achieved the best result for forest.

**Table 3.** Mean Average Precision for all images using *MLE* and *FLCM*.

		HH	HV	VH	VV
		UAVSAR			
Water	MLE	0.751	0.620	0.713	0.880
	FLCM	0.949	0.959	0.947	0.904
Oil Spill	MLE	0.854	0.302	0.956	0.934
	FLCM	0.943	0.978	0.938	0.990
Forest	MLE	0.995	0.988	1.000	0.833
	FLCM	1.000	0.994	1.000	0.856

Table 3. Cont.

		HH	HV	VH	VV
ORBISAR					
Water	<i>MLE</i>	0.791	0.694	0.593	0.860
	<i>FLCM</i>	0.926	0.686	0.930	0.864
Urban Area	<i>MLE</i>	1.000	0.984	0.919	0.959
	<i>FLCM</i>	1.000	0.985	0.919	0.957
Forest	<i>MLE</i>	0.845	0.429	0.583	0.573
	<i>FLCM</i>	0.863	0.545	0.627	0.615
ALOS PALSAR					
Water	<i>MLE</i>	0.940	0.987	-	0.833
	<i>FLCM</i>	0.781	0.897	-	0.820
Urban Area	<i>MLE</i>	0.889	0.931	-	0.618
	<i>FLCM</i>	0.877	0.953	-	0.617
Forest	<i>MLE</i>	0.904	0.980	-	0.555
	<i>FLCM</i>	0.821	0.972	-	0.560

- data is not available for this channel.

The results with ALOS PALSAR for HH and HV were superior to VV, mostly in extremely heterogeneous regions. On the other hand, VV presented the best results for water. Overall, CBIR-SAR performed better in homogeneous regions for both L-band sensors. The worst results for VV refer to heterogeneous regions, i.e., forest.

## 5. Conclusions

The proposed method is based on the statistical data modeling and stochastic distance to perform CBIR on single-look SAR images. Single-look SAR images are more challenging due to the marked presence of the speckle noise. The  $G_l^0$  distribution models the SAR intensity data, and its parameters are estimated by two estimation methods, i.e., the Maximum Likelihood Estimation and the Fast Log-Cumulant Method. The input features of the CBIR system comprise the estimated parameters of the image region, and the triangular distance compares the similarity between image regions. These estimated parameters represent the roughness and mean brightness features which discriminate image regions. In fact, the stochastic distance is highly dependent on the estimation quality of the parameters. Both estimation methods were tested: *MLE* due to its good properties and *FLCM* due to its estimation speed.

Our experiments demonstrated the effectiveness of the proposed method with synthetic and real SAR images. For both estimators, CBIR-SAR achieved the highest MAP values for extremely heterogeneous regions. These results confirmed that the proposed method is able to retrieve regions of similar texture based on the roughness parameter and hence, it is highly dependent on the region texture. However, it accomplished satisfactory results for homogeneous regions, and it was capable of revealing subtle texture differences between water and oil spills. Both synthetic and real SAR data results support that the proposed CBIR-SAR provides an effective solution to overcome the challenges posed by speckle for SAR image retrieval. We also demonstrated the role of the statistical data model, estimation methods and stochastic distance in the development of an expert system that can organize and query SAR image regions more efficiently. Tests with other stochastic distances and data may extend the method for other scenarios and applications, such as change detection and classification.

Among the advantages of the proposed methodology, we can list the following. CBIR-SAR is able to retrieve different image regions based on the parameters of the  $G_l^0$  model, which are image features embodied in the stochastic triangular distance. In addition, our approach deals with raw data and hence it does not require a preprocessing step due to the speckle noise. Lastly, the methodology presented promising results on both parameter

estimation methods. Moreover, CBIR-SAR results may also drive other image processing techniques, such as SAR image segmentation and classification. A disadvantage of this methodology is that the *MLE* estimation method requires the use of numerical techniques.

**Author Contributions:** Conceptualization: A.D.S. and F.N.S.M.; Methodology: A.D.S., P.H.d.S.S., R.R.V.S., F.A.À.R. and F.N.S.M.; Formal analysis and investigation: A.D.S. and F.N.S.M.; Writing: A.D.S., P.H.d.S.S., R.R.V.S., F.A.À.R. and F.N.S.M.; Supervision: F.N.S.M. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by Fundação de Amparo à Pesquisa do Estado do Piauí (FAPEPI) grant number Edital 001/2022.

**Institutional Review Board Statement:** Not applicable.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** No new data were created or analyzed in this study. Data sharing is not applicable to this article.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. Krishna, G.S.; Prakash, N. Deep learning for efficient and multi-labelled classification of synthetic aperture radar images. *Evol. Syst.* **2021**, *12*, 741–754. [[CrossRef](#)]
2. Alshehri, M. A content-based image retrieval method using neural network-based prediction technique. *Arab. J. Sci. Eng.* **2020**, *45*, 2957–2973. [[CrossRef](#)]
3. Zhang, K.; Li, B.; Tao, R. SAR image retrieval based-on fly algorithm. In Proceedings of the Tenth International Conference on Advanced Computational Intelligence (ICACI), Xiamen, China, 29–31 March 2018; pp. 502–507. [[CrossRef](#)]
4. Tang, X.; Jiao, L.; Emery, W.J. SAR Image Content Retrieval Based on Fuzzy Similarity and Relevance Feedback. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2017**, *10*, 1824–1842. [[CrossRef](#)]
5. Jiao, L.; Tang, X.; Hou, B.; Wang, S. SAR Images Retrieval Based on Semantic Classification and Region-Based Similarity Measure for Earth Observation. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2015**, *8*, 3876–3891. [[CrossRef](#)]
6. Tang, X.; Jiao, L. Fusion Similarity-Based Reranking for SAR Image Retrieval. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 242–246. [[CrossRef](#)]
7. Schroder, M.; Rehrauer, H.; Seidel, K.; Datcu, M. Interactive learning and probabilistic retrieval in remote sensing image archives. *IEEE Trans. Geosci. Remote Sens.* **2000**, *38*, 2288–2298. [[CrossRef](#)]
8. Argenti, F.; Lapini, A.; Bianchi, T.; Alparone, L. A tutorial on speckle reduction in synthetic aperture radar images. *IEEE Geosci. Remote Sens. Mag.* **2013**, *1*, 6–35. [[CrossRef](#)]
9. Nobre, R.H.; Rodrigues, F.A.A.; Marques, R.C.P.; Nobre, J.S.; Neto, J.F.S.R.; Medeiros, F.N.S. SAR Image Segmentation with Renyi's Entropy. *IEEE Signal Process. Lett.* **2016**, *23*, 1551–1555. [[CrossRef](#)]
10. Frery, A.C.; Muller, H.J.; Yanasse, C.C.F.; Sant'Anna, S.J.S. A model for extremely heterogeneous clutter. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 648–659. [[CrossRef](#)]
11. Gambini, J.; Casseti, J.; Lucini, M.M.; Frery, A.C. Parameter Estimation in SAR Imagery Using Stochastic Distances and Asymmetric Kernels. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2015**, *8*, 365–375. [[CrossRef](#)]
12. Rodrigues, F.A.A.; Nobre, J.S.; Vigélio, R.; Liesenberg, V.; Marques, R.C.P.; Medeiros, F.N.S. A Fast Approach for the Log-Cumulants Method Applied to Intensity SAR Image Processing. In Proceedings of the 2020 IEEE Latin American GRSS and ISPRS Remote Sensing Conference (LAGIRS), Santiago, Chile, 22–26 March 2020; pp. 494–498. [[CrossRef](#)]
13. Nascimento, A.D.C.; Cintra, R.J.; Frery, A.C. Hypothesis testing in speckled data with stochastic distances. *IEEE Trans. Geosci. Remote Sens.* **2010**, *48*, 373–385. [[CrossRef](#)]
14. Casella, G.; Berger, R.L. *Statistical Inference*; Cengage Learning: Boston, MA, USA, 2021.
15. Braga, I.H.T.; Sacramento, V.P.; Oliveira, L.C.C.; Medeiros, F.N.S.; Rodrigues, F.A.Á. Ocean surface change detection from remote sensing image based on stochastic similarity measure. *Braz. J. Water Resour.* **2022**, *27*. [[CrossRef](#)]
16. Wang, B.; Brown, D.; Gao, Y.; La Salle, J. MARCH: Multiscale-arch-height description for mobile retrieval of leaf images. *Inf. Sci.* **2015**, *302*, 132–148. [[CrossRef](#)]
17. Arfken, G.B.; Weber, H.J. *Mathematical Methods for Physicists*; AAPT: College Park, MD, USA, 1999.
18. Bustos, O.H.; Lucini, M.M.; Frery, A.C. M-Estimators of Roughness and Scale for  $G_A^0$ -Modelled SAR Imagery. *EURASIP J. Appl. Signal Process.* **2002**, *1*, 105–114.
19. Frery, A.C.; Wu, J.; Gomez, L. *Sar Image Analysis—A Computational Statistics Approach*; Wiley: Hoboken, NJ, USA, 2022.
20. Ferreira, J.A.; Nascimento, A.D.C. Shannon Entropy for the  $G_1^0$  Model: A New Segmentation Approach. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *13*, 2547–2553. [[CrossRef](#)]
21. Junior, P.M.A.; Nascimento, A.D.C.  $G_1^0$  ARMA process for speckled data. *J. Stat. Comput. Simul.* **2021**, *91*, 3125–3153. [[CrossRef](#)]

22. 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. Pattern Anal. Mach. Intell.* **2012**, *34*, 2046–2057. [[CrossRef](#)]
23. Abramowitz, M.; Stegun, I.A. *Handbook of Mathematical Functions with Formulas, Graphs, and Mathematical Tables*, 9th ed.; Dover: New York, NY, USA, 1964.
24. Nicolas, J.M. Introduction aux statistiques de deuxième espèce: Applications des logs-moments et des logs-cumulants à l'analyse des lois d'images radar. *TS. Trait. Signal* **2002**, *19*, 139–167.
25. Rey, A.; Revollo Sarmiento, N.; Frery, A.C.; Delrieux, C. Automatic Delineation of Water Bodies in SAR Images with a Novel Stochastic Distance Approach. *Remote Sens.* **2022**, *14*, 5716. [[CrossRef](#)]
26. Liu, Y.; Zhang, D.; Lu, G.; Ma, W.Y. A survey of content-based image retrieval with high-level semantics. *Pattern Recognit.* **2007**, *40*, 262–282. [[CrossRef](#)]
27. R Core Team. R: A language and environment for statistical computing. *MSOR Connect.* **2014**, *1*.

**Disclaimer/Publisher's Note:** The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.