

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
DE SANTA CATARINA
CAMPUS SÃO JOSÉ

GABRIEL LUIZ ESPINDOLA PEDRO

**DETECÇÃO DE ALVOS ESCONDIDOS EM FLORESTAS
UTILIZANDO IMAGENS SAR DE BAIXA FREQUÊNCIA**

SÃO JOSÉ

2025

Gabriel Luiz Espindola Pedro

Detecção de alvos escondidos em florestas utilizando imagens SAR de
baixa frequência

Monografia apresentada ao Curso de Engenharia de Telecomunicações do Instituto Federal de Santa Catarina, para a obtenção do título de bacharel em Engenharia de Telecomunicações.

Área de concentração: Telecomunicações

Orientador: Prof. Diego da Silva de Medeiros, Dr.

Coorientador: Prof. Dimas Irion Alves, Dr.

São José

2025

Gabriel Luiz Espindola Pedro

Detecção de alvos escondidos em florestas utilizando imagens SAR de
baixa frequência

Monografia apresentada ao Curso de Engenharia de Telecomunicações do Instituto Federal de Santa Catarina, para a obtenção do título de bacharel em Engenharia de Telecomunicações.

São José, 23 de Julho de 2025.

Prof. Diego da Silva de Medeiros, Dr.
Instituto Federal de Santa Catarina

Prof. Roberto Wanderley da Nóbrega, Dr.
Instituto Federal de Santa Catarina

Prof. Ramon Mayor Martins, Dr.
Instituto Federal de Santa Catarina

À minha família, que sempre esteve ao meu lado nessa jornada.

AGRADECIMENTOS

Primeiramente gostaria de agradecer à minha família. Agradeço ao meu pai, Martinho Luiz Pedro Neto, à minha mãe, Christiane Espindola Pedro, e à minha irmã, Gabriele Luiza Espindola Pedro, que sempre me ensinaram e trabalhar e lutar pelos meus objetivos, me dando amparo em momentos difíceis e sempre me lembrando que apesar dos obstáculos eu sempre terei eles ao meu lado para o que precisar.

Agradeço também à minha namorada, Jaqueline Büchner Albizu, pelo carinho, companheirismo e apoio nesse nosso primeiro ano de namoro. Sua presença foi fundamental para que eu me lembrasse de que existem coisas tão importantes quanto o trabalho e os estudos.

Sou grato aos professores Diego da Silva de Medeiros e Dimas Irion Alves pelo incentivo, apoio e pelas oportunidades oferecidas ao longo do desenvolvimento deste trabalho e que possamos seguir trabalhando juntos com a mesma harmonia em próximos projetos.

Aos meus amigos do ensino médio técnico Arthur Cadore Matuella Barcella, Paulo Bruno Bertorri Corá e Bruna Silveira por trazer risadas, brincadeiras e amizade desde sempre.

Gostaria também de agradecer aos professores que fizeram e fazem parte do Inova, por me proporcionarem a oportunidade de compartilhar espaço, conhecimento e momentos de confraternização com tantas pessoas especiais. Essa vivência foi fundamental para meu crescimento pessoal e profissional.

Por fim, agradeço a todos os professores, amigos e colegas que, de alguma forma, contribuíram para esta trajetória, desde o ensino médio técnico até os desafios e conquistas da graduação.

“Alone, it’s just a journey. Now adventures,
they must be shared.” (Gandalf)

RESUMO

A detecção de alvos ocultos sob a vegetação continua sendo um dos principais desafios enfrentados por sistemas de radar de abertura sintética (SAR) operando em bandas de frequência com resolução compatível ao comprimento de onda. A presença de vegetação densa dificulta a distinção entre o retorno do alvo e o ruído de fundo, exigindo modelagens estatísticas mais precisas para o clutter. Neste contexto, este artigo propõe a utilização da distribuição Gamma bivariada como modelo estatístico do clutter, demonstrando que ela se apresenta como um modelo mais adequado para imagens de intensidade diferença obtidas por sistemas SAR VHF UWB. A abordagem foi implementada em algoritmos de detecção de mudança (CD), tanto na forma iterativa quanto na não iterativa, ambos fundamentados no Teorema de Bayes. A eficácia do modelo foi avaliada por meio de curvas ROC, obtendo-se probabilidades de detecção de 98.94% para o método não iterativo e 98.99% para o método iterativo, ambos com uma taxa de falso alarme fixada em um falso alarme por quilômetro quadrado. Os resultados mostram que o modelo proposto oferece desempenho superior às distribuições tradicionalmente adotadas na literatura, com destaque para a aplicação no algoritmo não iterativo.

Palavras-chave: CARABAS-II; método de detecção de mudanças; SAR; resolução de comprimento de onda; teorema de Bayes'

ABSTRACT

The detection of concealed targets under foliage remains one of the main challenges faced by synthetic aperture radar (SAR) systems operating at frequency bands with wavelength-resolution. Dense vegetation makes it difficult to distinguish target returns from background clutter, demanding more accurate statistical modeling. In this context, this paper proposes the use of the bivariate Gamma distribution as a statistical clutter model, demonstrating that it provides a better fit for intensity difference images obtained from VHF UWB SAR systems. The approach was implemented in both iterative and non-iterative change detection (CD) algorithms based on Bayes' Theorem. The effectiveness of the model was evaluated using ROC curves, yielding detection probabilities of 98.94% for the non-iterative method and 98.99% for the iterative method, both at a fixed false alarm rate of one false alarm per square kilometer. The results show that the proposed model outperforms traditional statistical distributions used in the literature, with notable advantages in the non-iterative implementation.

Keywords: CARABAS-II; change detection method; SAR; wavelength-resolution; Bayes' theorem

LISTA DE ILUSTRAÇÕES

Figura 1 – Principais elementos para o processo de transmissão e recepção	15
Figura 2 – Forma de onda de um radar <i>pulsed</i>	15
Figura 3 – Ambiguidade da distância de um radar <i>pulsed</i>	16
Figura 4 – Tipos de ondas eletromagnéticas	17
Figura 5 – Coleta de dados de um sistema <i>Synthetic Aperture Radar</i> (SAR)	18
Figura 6 – Avião Sabreliner com o sistema CARABAS-II	20
Figura 7 – Imagens do banco de imagens CARABAS-II e mapa da floresta onde os dados foram obtidos	20
Figura 8 – Diagrama de blocos dos algoritmos iterativo e não iterativo	23
Figura 9 – Exemplo de curva <i>Receiver Operating Characteristic</i> (ROC) $P_d \times SNR$	25
Figura 10 – Exemplo de curva ROC comparando métodos de detecção na literatura	25
Figura 11 – Exemplos de imagens do dataset	27
Figura 12 – Exemplos de imagens geradas a partir das posições reais	27
Figura 13 – Representação visual do raio de validação das detecções	30
Figura 14 – Imagem de detecção com a distribuição Rayleigh bivariada $\tau = 0.4$ para a missão 2 passagem 1	30
Figura 15 – Curvas ROC de validação para distribuição Rayleigh com diferentes τ	32
Figura 16 – Curva ROC de validação para distribuição Gaussiana	32
Figura 17 – Resultados do algoritmo iterativo para distribuição Rayleigh bivariada $\tau = 0.4$ para a missão 2 passagem 1	34
Figura 18 – Curvas ROC de validação para distribuição Rayleigh com diferentes τ	34
Figura 19 – Curva ROC de validação para distribuição Gaussiana	35
Figura 20 – Imagem de intensidade diferença criada usando experimento 2 evidenciando pontos de maior intensidade	36
Figura 21 – Imagem de intensidade diferença, com máscara de valores de diferença positivos, criada usando experimento 2 evidenciando pontos de maior intensidade	36
Figura 22 – Resultados do algoritmo não iterativo para diferentes λ para a distribuição Gamma bivariada $\tau = 0.4$ no experimento 1	38
Figura 23 – Resultados do algoritmo não iterativo para diferentes τ para a distribuição Gamma bivariada no experimento 10	39
Figura 24 – Curvas ROC para os valores de τ utilizados para a distribuição Gamma bivariada no algoritmo não iterativo	39
Figura 25 – Comparação das curvas ROC para os modelos de <i>clutter</i> aplicados ao algoritmo não iterativo	40

Figura 26 – Resultados do algoritmo iterativo para diferentes λ para a distribuição Gamma bivariada $\tau = 0.4$ no experimento 1	41
Figura 27 – Resultados do algoritmo iterativo para diferentes τ para a distribuição Gamma bivariada no experimento 1	42
Figura 28 – Curvas ROC para os valores de τ utilizados para a distribuição Gamma bivariada no algoritmo iterativo	42
Figura 29 – Comparação das curvas ROC para os modelos de <i>clutter</i> aplicados ao algoritmo iterativo	43

LISTA DE ABREVIATURAS E SIGLAS

P_d Probabilidade de detecção.

P_{FA} Probabilidade de Falso Alarme.

CARABAS-II *Coherent All Radio Band System II.*

CD *Change Detection.*

CW *Continuous Waveform.*

EM Eletromagnética.

FAR *False Alarm Rate.*

FOI Agência Sueca de Pesquisa de Defesa.

FOPEN *Foliage Penetration.*

LRT *Likelihood-ratio Test.*

MLE *Maximum Likelihood Estimator.*

PDF Função Densidade de Probabilidade.

PRI *Pulse Repetition Interval.*

ROC *Receiver Operating Characteristic.*

SAR *Synthetic Aperture Radar.*

SBrT *Simpósio Brasileiro de Telecomunicações.*

SDMS *Sensor Data Management System.*

SNR *Signal to Noise Ratio.*

UHF *Ultra High Frequency.*

UWB *Ultrawide Band.*

VHF *Very High Frequency.*

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVOS GERAIS	13
1.2	OBJETIVOS ESPECÍFICOS	13
1.3	DISPOSIÇÃO DO TRABALHO	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	RADARES	14
2.1.1	Radar de Abertura Sintética	17
2.1.2	Wavelength-resolution	18
2.1.2.1	<i>CARABAS-II</i>	19
2.2	DETECÇÃO DE MUDANÇAS	21
2.2.1	Bayes não iterativo	21
2.2.2	Bayes iterativo	22
2.3	ANÁLISE DE DESEMPENHO DE ALGORITMOS	24
2.3.1	Curva ROC	24
3	METODOLOGIA	26
3.1	DATASET	26
3.2	ALGORITMO NÃO ITERATIVO	27
3.2.1	Validação das detecções	29
3.2.2	Reprodução dos resultados para o algoritmo não iterativo	30
3.3	ALGORITMO ITERATIVO	32
3.3.1	Reprodução dos resultados para o algoritmo iterativo	33
3.4	DISTRIBUIÇÃO GAMMA BIVARIADA	34
4	RESULTADOS	38
4.1	ALGORITMO NÃO ITERATIVO	38
4.1.1	Publicação relacionada	40
4.2	ALGORITMO ITERATIVO	41
5	CONCLUSÃO	44
5.1	TRABALHOS FUTUROS	44
	Referências	45
	APÊNDICE A – ARTIGO SBRT	47

1 INTRODUÇÃO

Radares são dispositivos que detectam, identificam e rastreiam alvos em regiões de interesse mediante a recepção de ecos de ondas eletromagnéticas por eles emitidas (Richards *et al.*, 2010). Sua aplicação abrange diversas áreas civis e militares, incluindo monitoramento de tráfego, previsão climática, vigilância de áreas florestais e sistemas de defesa militar (Alves, 2020).

Os sistemas de *Synthetic Aperture Radar* (SAR) são dispositivos de imageamento que utilizam o movimento relativo entre a antena do radar e a região de interesse para gerar imagens de alta resolução espacial. Os sistemas SAR aproveitam a trajetória da plataforma (aérea ou satelital) para sintetizar uma antena virtual de grande extensão, permitindo alcançar resoluções azimutais significativamente superiores (Alves, 2020). Devido a estas características os sistemas SAR são amplamente utilizados em fotogrametria, imageamento de áreas rurais e florestais e detecção de alvos.

Uma das aplicações dos radares SAR é a detecção de alvos em áreas florestais por meio da penetração de folhagem (*Foliage Penetration* (FOPEN)). Essa capacidade é viabilizada pelo uso de frequências como *Very High Frequency* (VHF) ou *Ultra High Frequency* (UHF), cujos comprimentos de onda são suficientemente grandes para atravessar a vegetação e atingir o solo (Alves, 2020).

Diante da necessidade de estudos nessas áreas, a Agência Sueca de Pesquisa de Defesa (FOI) desenvolveu o sistema *Coherent All Radio Band System II* (CARABAS-II) (Hellsten *et al.*, 1996). Essa iniciativa resultou na criação de um banco de dados de imagens SAR, no qual é possível implementar algoritmos de detecção para identificar alvos camuflados em ambientes florestais (Ulander *et al.*, 2005).

Diferentes metodologias de detecção de alvos foram propostas, estando em evidência os algoritmos baseados no teorema de Bayes desenvolvidos por Alves, Palm, Hellsten, Machado *et al.* (2023). Estes algoritmos utilizam os valores empíricos registrados pelo sistema comparados a uma descrição estatística do eco de fundo proveniente do terreno—conhecido como *clutter*—, comparando-os e computando a probabilidade de uma posição da imagem ser um alvo.

Trabalhos recentes realizaram estudos com o objetivo de encontrar um modelo que melhor descrevesse a natureza estatística do *clutter*. Os estudos desenvolvidos por Mittmann Voigt *et al.* (2023) identificaram que para imagens do tipo intensidade diferença de sistemas SAR VHF *Ultrawide Band* (UWB) um candidato mais adequado para descrever as características estatísticas é a distribuição Gamma bivariada.

Este trabalho tem como objetivo unificar as propostas de Alves, Palm, Hellsten,

Machado *et al.* (2023) e Mittmann Voigt *et al.* (2023), utilizando a distribuição Gamma bivariada como base estatística para o algoritmo desenvolvido por Alves. Para isso, será conduzido um estudo aprofundado sobre os algoritmos propostos por Alves, Palm, Hellsten, Machado *et al.* (2023) e os modelos de *clutter* utilizados no trabalho, possibilitando a reprodução dos algoritmos, validando os resultados por meio de comparação com os demonstrados no estudo, seguidos da implementação do modelo baseado na distribuição Gamma bivariada.

1.1 OBJETIVOS GERAIS

Aplicar o modelo de *clutter* Gamma bivariada para imagens de intensidade diferença de sistemas SAR VHF UWB a algoritmos de detecção de mudanças baseados no teorema de Bayes.

1.2 OBJETIVOS ESPECÍFICOS

- Conversão de algoritmos MATLAB para Python;
- Reprodução dos algoritmos propostos por Alves, Palm, Hellsten, Machado *et al.* (2023)
- Aplicação dos algoritmos às imagens do dataset CARABAS-II;
- Aplicação da Gamma bivariada aos algoritmos de detecção de mudança;
- Comparação dos resultados presentes na literatura e obtidos;

1.3 DISPOSIÇÃO DO TRABALHO

O restante deste trabalho se organiza da seguinte maneira. Capítulo 2 realiza um estudo de base para construção do conhecimento necessário para o desenvolvimento deste projeto. Capítulo 3 explica as etapas de desenvolvimento e o ferramental criado e utilizado. Capítulo 4 demonstra os resultados obtidos pela utilização do modelo proposto aos algoritmos de interesse. Capítulo 5 traz uma visão geral sobre os resultados obtidos analisando-os e identificando pontos de atenção e lacunas do estudo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 RADARES

Os radares são dispositivos eletrônicos capazes de iluminar uma área de interesse por meio de ondas Eletromagnéticas (EMs), recebendo a reflexão dessas ondas provocada por um alvo. Geralmente, eles são empregados para medir grandezas físicas, como a distância entre o radar e o alvo e a velocidade relativa entre ambos.

O desenvolvimento do radar remonta às primeiras décadas do século XX, impulsionado pela necessidade de detecção remota de objetos. Durante a Segunda Guerra Mundial, os sistemas radar tornaram-se estratégicos para aplicações militares, como identificação de aeronaves e navios (Richards *et al.*, 2010). Inicialmente baseados em tecnologias analógicas, os radares evoluíram com avanços em eletrônica e processamento digital, permitindo maior precisão na medição de distâncias e velocidades. Ao longo dos anos, a miniaturização de componentes e a integração com técnicas computacionais, como o SAR, ampliaram suas capacidades, transformando-o em uma ferramenta versátil para além de aplicações militares.

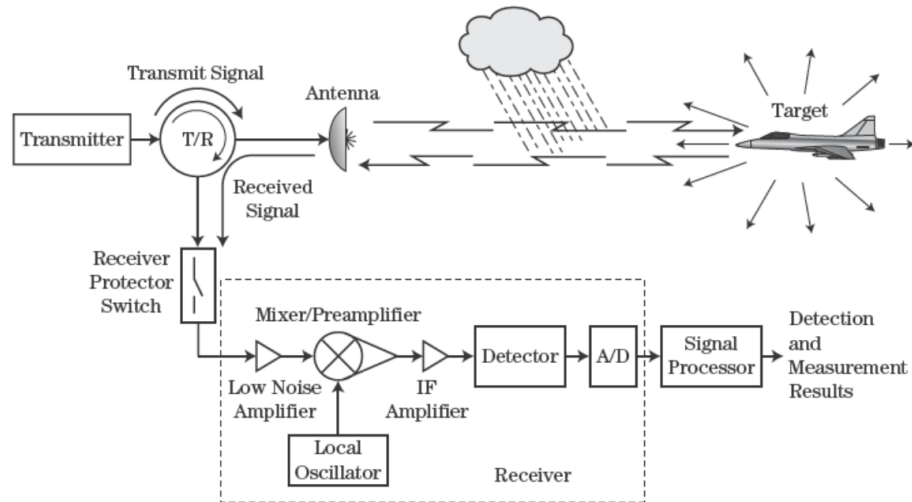
Atualmente, os radares são empregados em diversas áreas, desde o controle de tráfego aéreo e marítimo até o monitoramento meteorológico (Alves; Palm; Hellsten; Vu *et al.*, 2020), onde detectam precipitações e formam imagens de tempestades. Na defesa, são essenciais para vigilância e reconhecimento, enquanto na astronomia permitem mapear corpos celestes. Isso é possível pois sistemas SAR geram imagens de alta resolução ideal para estudos ambientais e observação planetária, independentemente de condições climáticas (Moreira *et al.*, 2013).

Para emitir e detectar as ondas refletidas pelo ambiente, o radar é composto por diversos componentes eletrônicos. A Figura 1 ilustra os principais elementos envolvidos no processo de transmissão e recepção. Os circuitos de transmissão e recepção são desacoplados para que a alta potência emitida pelo primeiro não sobrecarregue o segundo, contando com circuitos protetores que garantem que as ondas recebidas sejam apenas de baixa potência, correspondentes às reflexões.

O circuito de recepção filtra ruídos, modula o sinal recebido para uma frequência intermediária e o discretiza, permitindo seu processamento digital. No passado, devido à limitada capacidade computacional e à necessidade de grandes espaços físicos para o processamento dos sinais, os radares realizavam essa função por meio de circuitos analógicos.

Para a transmissão do sinal, os radares podem adotar duas políticas principais: transmissão contínua ou pulsada, classificando-se, respectivamente, como radares *Conti-*

Figura 1 – Principais elementos para o processo de transmissão e recepção

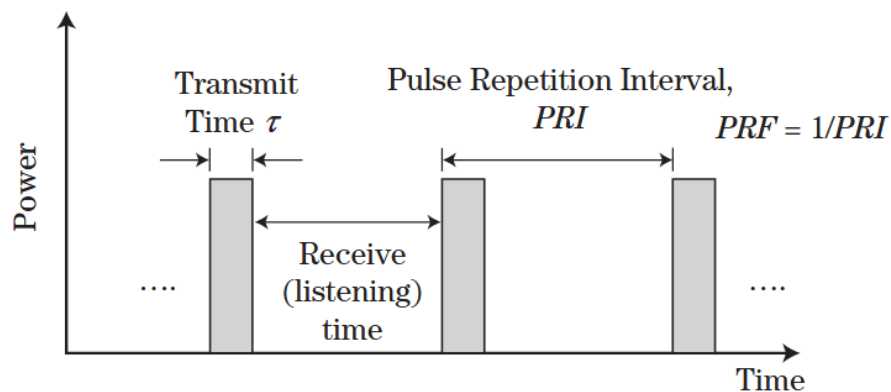


Fonte: Richards *et al.* (2010)


continuous Waveform (CW) ou *pulsed*. Os radares CW transmitem uma onda EM contínua com alguma modulação aplicada; devido a essas características, esse tipo de sistema apresenta baixa potência e é, conseqüentemente, utilizado em aplicações de curto alcance. Já os radares *pulsed* emitem pulsos de sinal em intervalos, permitindo que cada pulso seja refletido individualmente, de modo que o tempo de percurso e o desvio na frequência possam ser empregados para determinar a distância e a velocidade do alvo.

Os radares *pulsed* oferecem graus de liberdade que permitem definir tanto o período de transmissão (τ) quanto o intervalo de repetição de pulso (*Pulse Repetition Interval* (PRI)). Conforme ilustrado na Figura 2, esse tipo de radar emite um sinal durante um tempo τ , aguarda um período denominado tempo de recebimento ou escuta, durante o qual se espera captar um eco do ambiente e, em seguida, repete o processo.

Figura 2 – Forma de onda de um radar *pulsed*



Fonte: Richards *et al.* (2010)

Figura 3 – Ambiguidade da distância de um radar *pulsed*

Fonte: Richards *et al.* (2010)

Devido à natureza periódica do processo e à incerteza na posição dos alvos de interesse, pode ocorrer ambiguidade na determinação da posição do alvo. Se o PRI não for definido de forma a considerar a distância máxima de detecção, o eco poderá ser recebido após a transmissão de um pulso subsequente, sendo erroneamente atribuído a esse pulso. Para evitar essa ambiguidade na distância, o PRI deve ser maior ou igual ao tempo máximo de retorno de um eco.

Para determinar a distância de um alvo em relação ao radar, emprega-se uma equação que relaciona o tempo de percurso (ΔT) com a distância ao alvo (ou *range*, R), considerando a velocidade de propagação da onda EM no meio, que é aproximadamente a velocidade da luz (c)¹.

Já para determinar a velocidade relativa ao dispositivo, utiliza-se outra propriedade da onda: o efeito Doppler. Quando uma onda é refletida por um alvo que se aproxima do transmissor, ocorre um desvio que aumenta a frequência original do sinal; da mesma forma, se o alvo se afasta, a frequência é reduzida. Utilizando a equação a seguir, podemos aproximar a frequência Doppler (f_d) e identificar a velocidade relativa do alvo (v_r) com base no comprimento de onda emitido (λ):

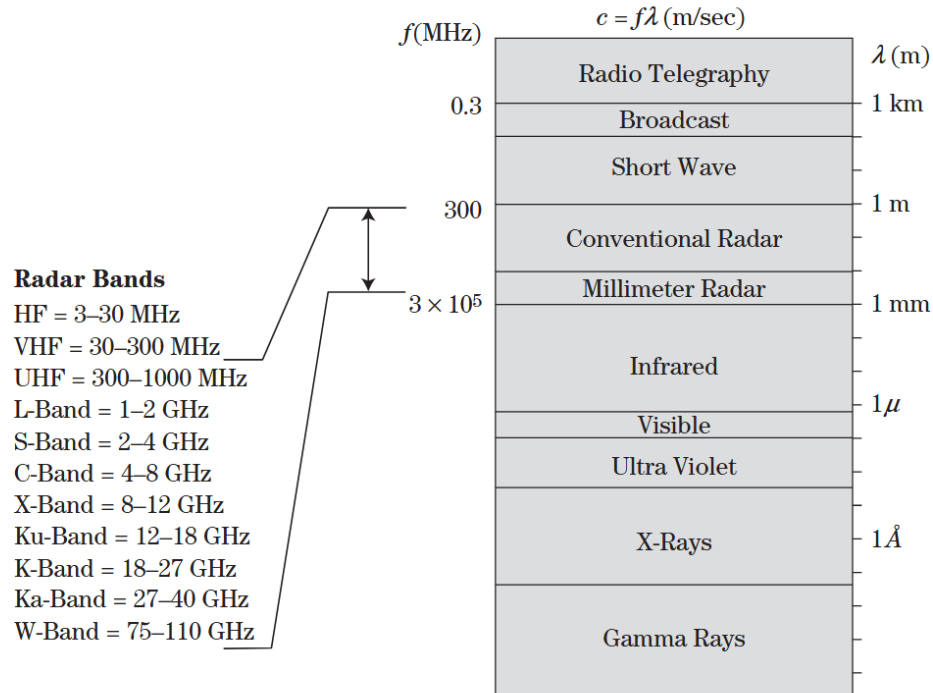
$$f_d \approx \frac{2v_r}{\lambda}. \quad (2.1)$$

Um dos parâmetros dos radares é a frequência de operação. O espectro eletromagnético é dividido em faixas, para as quais são atribuídas nomenclaturas que facilitam a identificação dos intervalos de operação dos dispositivos. A Figura 4 ilustra as faixas de frequência utilizadas pelos radares.

A escolha da frequência de operação do radar é determinada com base em sua aplicação. Por exemplo, radares meteorológicos devem operar em frequências sensíveis

¹ A velocidade da luz é de 299.792.458 m/s, normalmente aproximada para $3 \cdot 10^8$ m/s

Figura 4 – Tipos de ondas eletromagnéticas



Fonte: Richards *et al.* (2010)

a variações climáticas. Como característica das ondas EMs, sua interação com o meio material depende da relação entre o comprimento de onda e o tamanho do objeto. Dessa forma, objetos pequenos podem se tornar indetectáveis para ondas de baixa frequência.


Além desse fenômeno interferente, a natureza térmica dos componentes eletrônicos gera o chamado ruído térmico. A combinação desses efeitos introduz variações nas leituras, podendo resultar em erros de detecção, conhecidos como falsos alarmes.

2.1.1 Radar de Abertura Sintética

O imageamento por SAR se baseia no movimento contínuo da plataforma (aérea ou orbital) em relação à área de interesse. Diferentemente de radares imageadores convencionais, que direcionam o feixe diretamente abaixo da plataforma, o SAR opera em modo *side-looking*, ou seja, o radar emite pulsos lateralmente em relação à trajetória de voo (Alves, 2020). A Figura 5 ilustra a trajetória de um sistema SAR na sua coleta de dados.

A geração da imagem ocorre por meio da emissão sequencial de pulsos eletromagnéticos, cujos ecos retornam ao radar após interagir com a superfície. Cada pulso capturado corresponde à dimensão range (distância entre o radar e o alvo), determinada pelo tempo de retorno do sinal. A segunda dimensão, azimuth (direção paralela ao movimento da plataforma), é construída pela síntese de múltiplos pulsos emitidos em posições distintas ao

Figura 5 – Coleta de dados de um sistema SAR



Fonte: Moreira *et al.* (2013)

longo da trajetória. Esse processo de integração temporal permite simular uma antena de grande comprimento físico (antena sintética), melhorando significativamente a resolução azimutal (Richards *et al.*, 2010).

A resolução azimutal (ou *along-track*) pode ser definida como a distância mínima entre dois pontos na superfície que podem ser distinguidos pelo sistema (Alves, 2020). Em radares de abertura real, essa resolução é limitada pelo comprimento físico da antena. No entanto, no SAR, o movimento da plataforma gera variações nas frequências dos ecos recebidos devido ao efeito Doppler. Essas variações fornecem informações adicionais sobre a posição relativa dos alvos, permitindo que a resolução azimutal atinja valores teóricos equivalentes à metade do tamanho da antena real.

Durante a coleta, os dados brutos do SAR são armazenados em uma matriz complexa, na qual cada elemento contém informações de amplitude e fase dos ecos recebidos. Esses dados representam apenas sinais brutos que devem ser processados para resultar em uma imagem interpretável.

Essa capacidade de aquisição de alta resolução, aliada à independência de condições climáticas e de iluminação solar, torna o SAR uma ferramenta essencial para aplicações que demandam monitoramento detalhado, como vigilância militar, estudos ambientais e observação planetária.

2.1.2 Wavelength-resolution

Os sistemas SAR que operam com resolução na ordem do comprimento de onda da radiação emitida apresentam características distintas em comparação aos radares de

micro-ondas tradicionais. Nesses sistemas, a reflexão ocorre predominantemente por ressonância, fenômeno no qual a energia da onda interage com objetos cujas dimensões físicas são comparáveis ao comprimento de onda. Isso os torna pouco sensíveis a alvos significativamente menores, como folhagens ou partículas atmosféricas, que não geram reflexões relevantes.

Essa propriedade é explorada em aplicações como FOPEN, em que o objetivo é detectar alvos sob densa cobertura vegetal. Como as folhas e galhos são menores que o comprimento de onda do radar, sua reflexão é mínima, permitindo que os sinais penetrem a vegetação e sejam refletidos por estruturas maiores no solo, como veículos ou construções. Além disso, objetos de grande porte, como pontes ou relevos topográficos, tendem a ser estáveis temporalmente, facilitando a comparação de imagens de múltiplas passagens do radar para detecção de mudanças sutis.

Apesar da baixa reflexão por objetos pequenos, esses sistemas enfrentam desafios como a atenuação do sinal ao atravessar a folhagem. Em frequências abaixo de 100 MHz, por exemplo, a vegetação pode causar perdas de aproximadamente 3 dB, reduzindo a intensidade do eco recebido. Para compensar esse efeito, é necessário ajustar parâmetros como a potência de transmissão ou o tempo de integração dos pulsos.

Exemplos práticos de sistemas que utilizam essa abordagem incluem o CARABAS (Coherent All Radio Band Sensing), o LORA (Low-frequency Radar) e o TRACER (Tactical Reconnaissance and Counter-Concealment Enabled Radar). Esses radares operam em faixas de frequência muito baixas (VHF/UHF) e empregam técnicas de UWB para alcançar resoluções compatíveis com o comprimento de onda, consolidando-se como ferramentas estratégicas em cenários que demandam imageamento em ambientes complexos ou sob condições climáticas adversas (Alves, 2020).

2.1.2.1 CARABAS-II

O sistema CARABAS-II é a segunda geração de um sistema SAR UWB, desenvolvido pela Agência de Pesquisa de Defesa Sueca (FOI). Ele opera na faixa de frequência de 20 a 90 MHz, correspondendo a comprimentos de onda entre 3.3 e 15 metros. Com o uso de toda a largura de banda do sinal e um ângulo de integração azimutal de aproximadamente 70°, o sistema atinge uma resolução espacial, ou seja tamanho mínimo do alvo a ser detectado, na ordem de 2.5×2.5 metros no plano de imagem (Hellsten *et al.*, 1996).

O radar é instalado em um avião do tipo Sabreliner (Figura 6), onde os dados brutos são obtidos e armazenados em discos rígidos durante o voo. O processamento dos sinais, incluindo a formação de imagens, calibração radiométrica, geocodificação e detecção de mudanças, é realizado posteriormente em laboratório (Ulander *et al.*, 2005).


Figura 6 – Avião Sabreliner com o sistema CARABAS-II



Fonte: Ulander *et al.* (2005)

O CARABAS-II gerou um conjunto de dados público², composto por 24 imagens (Figura 7), divididas em quatro distribuições de alvos. Cada distribuição contém duas repetições de três direções de voo, cobrindo uma área de 2×3 km. As imagens são georreferenciadas no sistema de referência sueco RR92 e cada pixel representa 1×1 metro, resultando em uma matriz de 3000 linhas por 2000 colunas.

Figura 7 – Imagens do banco de imagens CARABAS-II e mapa da floresta onde os dados foram obtidos



Fonte: Ulander *et al.* (2005)

² https://www.sdms.afrl.af.mil/index.php?collection=vhf_change_detection

Esse conjunto de dados foi coletado durante uma campanha de voo realizada na Suécia em 2002, com o objetivo de avaliar a detecção de alvos sob folhagem utilizando técnicas de detecção de mudanças em imagens SAR de banda VHF (Ulander *et al.*, 2005).

2.2 DETECÇÃO DE MUDANÇAS

A geração de múltiplas imagens com alvos estáveis no tempo permite a aplicação de algoritmos de detecção de mudanças, também chamados de *Change Detection* (CD). Esses algoritmos comparam duas ou mais imagens de uma mesma região, capturadas em momentos distintos, para identificar alterações significativas no cenário observado.

Os primeiros algoritmos de CD basearam-se em ferramentas estatísticas, como o teste de razão de verossimilhança (*Likelihood-ratio Test* (LRT)), para distinguir mudanças relevantes de variações naturais no ambiente (Ulander *et al.*, 2005). No entanto, um dos principais desafios nesse processo é encontrar um equilíbrio entre a Probabilidade de detecção (P_d) e a Probabilidade de Falso Alarme (P_{FA}). Enquanto P_d mede a capacidade do algoritmo de identificar corretamente mudanças reais, P_{FA} quantifica a ocorrência de detecções incorretas, causadas por ruído ou variações insignificantes. Com isso em mente, técnicas buscam otimizar esse equilíbrio, maximizando a detecção de mudanças genuínas enquanto minimizam os falsos alarmes.

Um aspecto crítico para o desempenho dos algoritmos de CD é a modelagem estatística do *clutter* (interferência causada por reflexões de objetos não alvo) e do ruído presentes nas imagens SAR wavelength-resolution (Mittmann Voigt *et al.*, 2023). Diferentes modelos estatísticos foram propostos para descrever o comportamento do *clutter* combinado com o ruído para sistemas SAR VHF wavelength-resolution, incluindo as distribuições Gaussiana, Rayleigh, Exponencial e Gamma bivariadas. Estudos comparativos, como os realizados por Mittmann Voigt *et al.* (2023), indicam que a distribuição Gamma bivariada é a mais adequada para modelar o cenário de aplicações FOPEN.

A escolha do modelo estatístico correto é essencial para o sucesso dos algoritmos de CD, pois influencia diretamente a precisão das detecções. Objetos que não são de interesse, mas refletem parte do sinal emitido, podem mascarar mudanças reais ou gerar falsos alarmes. Portanto, a combinação de modelos estatísticos com técnicas de processamento de sinais é fundamental para melhorar a eficácia dos algoritmos de detecção de mudanças.

2.2.1 Bayes não iterativo

O método proposto por Alves, Palm, Hellsten, Vu *et al.* (2020) utiliza o Teorema de Bayes para estimar a probabilidade de mudança entre pares de imagens SAR de resolução de comprimento de onda (*wavelength-resolution*), combinando modelos estatísticos do *clutter*. A equação fundamental é adaptada ao contexto de CD como

$$P(s_T | z_U, z_R) = \frac{P(z_U | s_T, z_R) P(s_T | z_R)}{P(z_U | z_R)}, \quad (2.2)$$

onde s_T são valores reais e indica a presença de mudança, enquanto z_U e z_R também são valores reais e representam as intensidades dos pixels nas imagens de vigilância e referência, respectivamente. A partir desta formulação, assume-se a hipótese nula de ausência de mudança (s_C), associada a pixels de *clutter*. A Equação 2.2 pode ser manipulada, seguindo os passos apresentados por Alves, Palm, Hellsten, Vu *et al.* (2020), para chegar em

$$P(s_T | z_U, z_R) \approx 1 - \frac{P(z_U, z_R | s_C)}{P(z_U, z_R)}, \quad (2.3)$$

onde $P(z_U, z_R | s_C)$ é derivada do modelo estatístico escolhido. Quando não há mudança, $P(z_U, z_R) \approx P(z_U, z_R | s_C)$, o resultado tende a zero, sendo assim possível escolher um limiar máximo para definir a detecção.

O fluxo do algoritmo não iterativo (Figura 8) inicia com a formação do histograma conjunto das imagens de referência e vigilância, onde os valores de intensidade dos pixels são agrupados em *bins* para estimar a distribuição conjunta $P(z_U, z_R)$. Em seguida, calculam-se as probabilidades condicionais $P(z_U, z_R | s_C)$ por meio do modelo estatístico adotado, como a distribuição Rayleigh bivariada, que caracteriza o cenário de *clutter*. Por fim, aplica-se uma limiarização com $\lambda \in (0, 1)$ para discriminar mudanças significativas: pixels com $P(s_T | z_U, z_R) \geq \lambda$ são classificados como alterados, enquanto os demais são descartados como ruído.

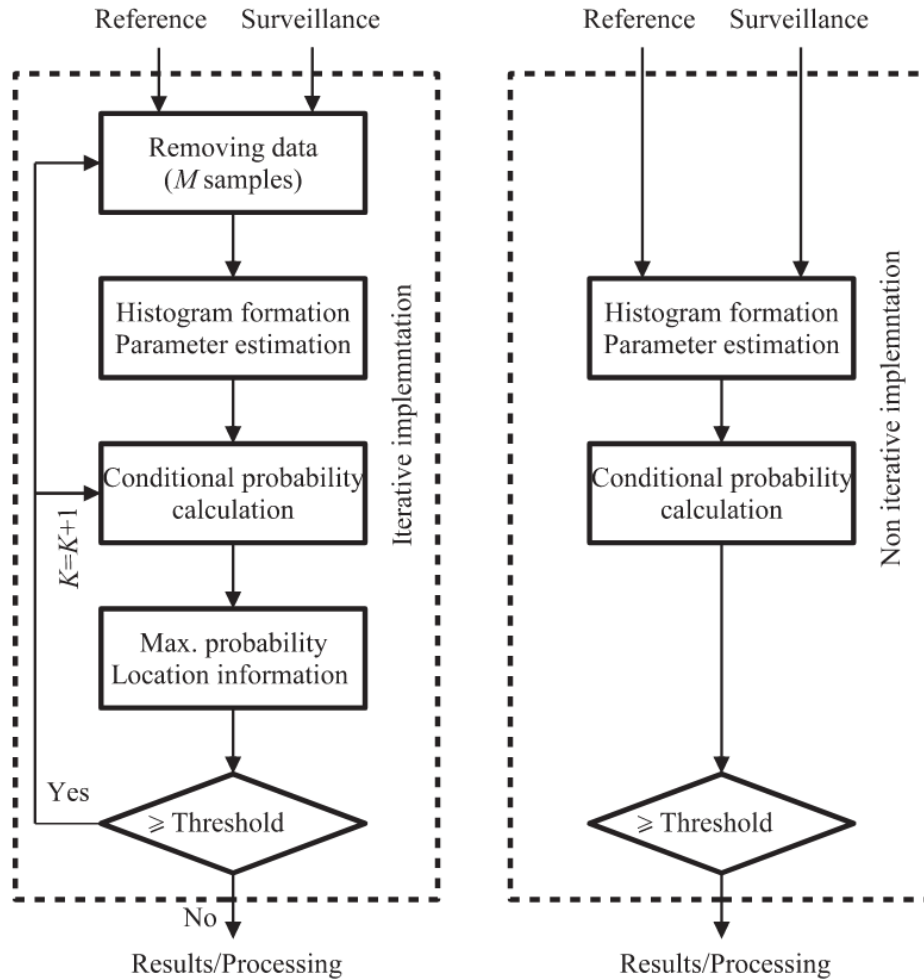
2.2.2 Bayes iterativo

Também desenvolvido por Alves, Palm, Hellsten, Vu *et al.* (2020), o método iterativo utiliza a independência da mudança na probabilidade condicional $P(s_T | z_R)$ para definir a probabilidade de ocorrência de uma mudança em função do número de alvos já detectados (K), do número de pixels ocupados por uma mudança (M) e do total de pixels na imagem (N):

$$P(s_T | z_R) = P(s_T) = \frac{MK}{N}. \quad (2.4)$$

Nesta abordagem (Figura 8), a cada iteração, o algoritmo atualiza K (quantidade de mudanças detectadas) e remove M pixels ao redor do alvo identificado, reestimando $P(s_T)$ e o histograma das imagens. O processo inicia com $K = 1$ e calcula a probabilidade $P(s_T | z_U, z_R)$ para todos os pixels usando:

Figura 8 – Diagrama de blocos dos algoritmos iterativo e não iterativo



Fonte: Alves, Palm, Hellsten, Vu *et al.* (2020)

$$P(s_T | z_U, z_R) \approx \frac{1}{1 + \frac{P(z_U | s_C, z_R)}{P(z_U | s_T)P(s_T)}}, \quad (2.5)$$

Se a probabilidade máxima exceder um limiar λ , o pixel é marcado como mudança, e os M pixels adjacentes são excluídos para evitar redundâncias. Nas iterações subsequentes, K é incrementado, e os parâmetros do modelo estatístico são recalculados com os dados restantes, refinando a precisão.

A principal vantagem da implementação iterativa é a capacidade de adaptar-se dinamicamente ao cenário, mitigando interferências de alvos previamente detectados. Contudo, essa flexibilidade implica maior complexidade computacional em comparação à versão não iterativa. Experimentos com dados CARABAS-II mostraram que o método iterativo é ideal para cenários com alvos de tamanho conhecido (M fixo), enquanto a abordagem não iterativa é preferível para detecção em tempo real.

Resultados experimentais com dados do sistema CARABAS-II demonstram P_d de 98,7% para $FAR = 1/km^2$ (Alves; Palm; Hellsten; Vu *et al.*, 2020), havendo um ganho

considerável quando comparado com outros algoritmos baseados em LRT da literatura, como por exemplo os resultados obtidos por Ulander *et al.* (2005) que atingiu cerca de 90% com a mesma taxa de falsos alarmes por km^2 .

2.3 ANÁLISE DE DESEMPENHO DE ALGORITMOS

A análise de desempenho de algoritmos de detecção de mudanças (CD) requer metodologias que quantifiquem a qualidade da classificação entre detecções válidas e falsos alarmes. Em cenários ideais, utiliza-se uma base de dados com *ground truth*, em que as mudanças reais são previamente conhecidas e georreferenciadas. Isso permite calcular métricas como a P_d , definida pela razão entre o número de alvos corretamente identificados e o total de alvos presentes, e a *False Alarm Rate* (FAR), expressa pelo número de detecções incorretas por unidade de área ($FAR = 1 \text{ km}^{-2}$).

2.3.1 Curva ROC


A curva ROC é uma ferramenta gráfica para análise comparativa de classificadores, permitindo visualizar e selecionar modelos com base no equilíbrio entre sensibilidade e especificidade (Fawcett, 2006). No contexto de detecção de mudanças (CD), a curva ROC relaciona a taxa de verdadeiros positivos, que representa a P_d , e a taxa de falsos positivos, correspondente à taxa de falsos alarmes (FAR), para uma dada *Signal to Noise Ratio* (SNR) (Richards *et al.*, 2010), como demonstrado na Figura 9. Os quatro resultados possíveis da classificação são:

- Verdadeiro Positivo (VP): Mudança detectada e presente no *ground truth*,
- Falso Positivo (FP): Mudança detectada mas ausente no *ground truth*,
- Verdadeiro Negativo (VN): Ausência de mudança corretamente identificada,
- Falso Negativo (FN): Mudança existente não detectada.

Para a análise de desempenho de algoritmos de CD, é utilizado da curva ROC com o eixo Y representando P_d , e o eixo X representando FAR, como exemplificado na Figura 10. Cada ponto da curva corresponde a um limiar (λ) de decisão, variando de 0 a 1. Por exemplo, um limiar baixo ($\lambda \rightarrow 0$) maximiza P_d às custas de um alto FAR, enquanto um limiar alto ($\lambda \rightarrow 1$) reduz falsos alarmes, porém penaliza P_d .


Quanto melhor o classificador mais próximo do canto superior esquerdo ele está. Dessa forma um classificador perfeito—capaz de detectar todos os alvos ($P_d = 1$) sem gerar falsos alarmes ($FAR = 0$)—corresponderia ao ponto (0,1) nessa curva. Por exemplo, na Figura 10, a curva correspondente ao algoritmo iterativo com modelo Gaussiano pode ser indicada como a de melhor desempenho.

Figura 9 – Exemplo de curva ROC $P_d \times SNR$



Fonte: Richards *et al.* (2010)

Figura 10 – Exemplo de curva ROC comparando métodos de detecção na literatura



Fonte: Alves, Palm, Hellsten, Machado *et al.* (2023)

3 METODOLOGIA

Este capítulo tem como objetivo descrever as etapas de desenvolvimento deste projeto, demonstrando a reprodução e validação dos algoritmos utilizados, assim como o desenvolvimento do ferramental necessário para essa realização.

3.1 DATASET

Com o objetivo de testar a distribuição Gamma bivariada como modelagem estatística de *clutter* para imagens de intensidade diferença em sistemas SAR VHF UWB foi necessário a aquisição das imagens. Disponibilizado pelo site da *Sensor Data Management System* (SDMS)¹ foi possível adquirir essas imagens juntamente das posições dos alvos para as missões, scripts MATLAB de leitura e manipulação das imagens e documentação dos scripts.

A linguagem definida para o desenvolvimento deste projeto foi Python, portanto para trabalhar com o dataset foi necessário a adaptação destes scripts para a linguagem utilizada. Para fins de praticidade de desenvolvimento foi criada uma biblioteca contendo todas as funções originais disponibilizadas juntamente com o dataset.


A Figura 11 ilustra três imagens do dataset lidas utilizando o script adaptado em Python. As imagens do dataset são armazenadas como pontos flutuantes com ordenamento de bytes *big-endian* e para sua leitura é necessário usar um script que lê e armazena em memória cada byte para poder ser manipulado dentro do algoritmo.

Para além da leitura da imagem é necessário também identificar as posições reais dos alvos dispostos em cada uma das missões, para isso também é utilizado um script. Com ele a partir das posições reais georreferenciadas utilizando o sistema RR92 dispostas num arquivo texto são convertidas em posições relativas ao índice da matriz da imagem, que contem 3000×2000 pixels. Com essa informação é possível posteriormente comparar as posições reais com as posições detectadas pelos algoritmos. A Figura 12 ilustra exemplos de imagens-geradas usando o script das posições reais.

Ao comparar as imagens 11 e 12 identificamos que as imagens geradas possuem pontos nas regiões onde existem pontos de intensidade nas imagens do dataset, indicando que aqueles pontos de intensidade representam alvos. Ao utilizar as imagens num algoritmo de detecção de alvos, é utilizado desse posicionamento para comparar os resultados e extrair uma métrica de assertividade para o algoritmo.

¹ <https://www.sdms.afrl.af.mil/>

Figura 11 – Exemplos de imagens do dataset




(a) Missão 2 Passagem 1

(b) Missão 3 Passagem 6

(c) Missão 4 Passagem 5

Figura 12 – Exemplos de imagens geradas a partir das posições reais



(a) Missão 2 Passagem 1

(b) Missão 3 Passagem 6

(c) Missão 4 Passagem 5

3.2 ALGORITMO NÃO ITERATIVO

Com base nos estudos de Alves, Palm, Hellsten, Vu *et al.* (2020), foi implementado o algoritmo não iterativo. Inicialmente foi realizada uma leitura exploratória a fim de identificar as etapas principais do algoritmo, dessa forma—baseado também no diagrama de blocos apresentado na Figura 8—foi desenvolvido o pseudocódigo para ser implementado na linguagem de programação Python.

O Pseudocódigo 1 descreve as etapas de execução do algoritmo não iterativo. Primeiramente, para aplicar o algoritmo de detecção de mudanças é necessário duas imagens,

Pseudocódigo 1: Algoritmo não iterativo

- Entrada:** Imagem de interesse z_s ; Imagem de referência z_r
- 1 Criar do histograma 2D com os valores de z_s e z_r ;
 - 2 Estimar os parâmetros da distribuição;
 - 3 Criar máscara para os pixels onde $z_s \geq z_r + \tau$;
 - 4 Criar $P(z_s, z_r | s \neq s_T)$ com o cálculo da PDF para os pixels na máscara;
 - 5 Criar $P(z_s, z_r)$ com a contagem de ocorrências dos valores de z_s e z_r ;
 - 6 Criar matriz de probabilidade P ;
 - 7 $P \leftarrow \max(0, 1 - P(z_s, z_r | s \neq s_T) / P(z_s, z_r))$;
 - 8 Aplicar filtro passa-baixas 3×3 ;
 - 9 Criar matriz de detecção D ;
 - 10 $C \leftarrow P > \lambda$;
 - 11 Aplicar erosão C com kernel 3×3 ;
 - 12 Aplicar dilatação C com kernel 3×3 ;
 - 13 Aplicar dilatação C com kernel 7×7 ;
- Saída:** Matriz de mudanças C
-

uma imagem de interesse, z_s , onde se deseja detectar os alvos, e uma imagem de referência, z_r , que serve de base de comparação para detecção de alvos.

A partir das duas imagens cria-se o histograma das coocorrências dos valores de intensidade, ou seja uma contagem de ocorrências simultâneas dos valores empíricos para cada posição de z_s e z_r com isso sendo possível criar uma matriz com a probabilidade observada em cada posição da imagem $P(z_s, z_r)$.

Sabendo que grandes estruturas, que também podem refletir o sinal transmitido, são estáveis no tempo—isto é, estarão presentes em ambas as imagens na mesma posição—é dado enfoque nos alvos que estão aparecendo em z_s , isto ocorre quando $z_s \geq z_r$, e, para que pequenas variações de leitura não sejam consideradas posições válidas para teste, é adicionado um termo de guarda, τ , garantido que a posição testada possui uma mudança significativa. Com isso criamos uma máscara que limita os testes de mudança nas imagens.

Com esta matriz de probabilidade observada $P(z_s, z_r)$, utilizamos o modelo de *clutter* para estimar a probabilidade esperada, $P(z_s, z_r | s \neq s_T)$, nas posições onde é possível ter havido uma mudança, isso é feito por meio do cálculo da Função Densidade de Probabilidade (PDF) do modelo estatístico escolhido.

Uma vez possuindo estes componentes podemos então criar uma matriz de probabilidade $P(s = s_T | z_s, z_r)$ com base na Equação 2.2, obtendo assim a probabilidade de ter ocorrido uma mudança em cada uma das posições da imagem de interesse. Para remover mudanças abruptas na imagem, que não representam uma mudança, utilizamos um filtro passa-baixas minimizando pequenas mudanças repentinas.

Para definir uma detecção utilizamos uma limiarização comparando $P(s = s_T | z_s, z_r)$ com um valor λ , com valores de 0 a 1, obtendo por fim uma matriz booleana com

as posições onde foram detectadas mudanças pelo algoritmo.

Por fim, para minimização de falsos alarmes, são aplicadas operações morfológicas. Utilizando a operação de erosão podemos eliminar pequenas detecções que não representam alvos reais, uma vez que as dimensões do alvo detectado tem que ser maior que a resolução do sistema. O processo de erosão é seguido por duas etapas de dilatação: a primeira usando um kernel de 3×3 —o mesmo kernel utilizado para o processo de erosão—para recuperar as detecções maiores que 3 metros, seguido de uma segunda dilatação com um kernel de 7×7 , resultando em cada detecção representando 10×10 metros.

3.2.1 Validação das detecções

Para validação de detecções corretas e falsos alarmes a partir dos resultados obtidos com o processamento do algoritmo não iterativo, é aplicada uma metodologia de comparação de posições baseadas em centroide. É comparado o centroide de cada objeto detectado pelo algoritmo com as posições reais estabelecidas pelo dataset. O Pseudocódigo 2 descreve o procedimento de validação das detecções e a Figura 13 demonstra visualmente do raio de validação das detecções definidas pelo algoritmo.

Pseudocódigo 2: Processo de validação das detecções

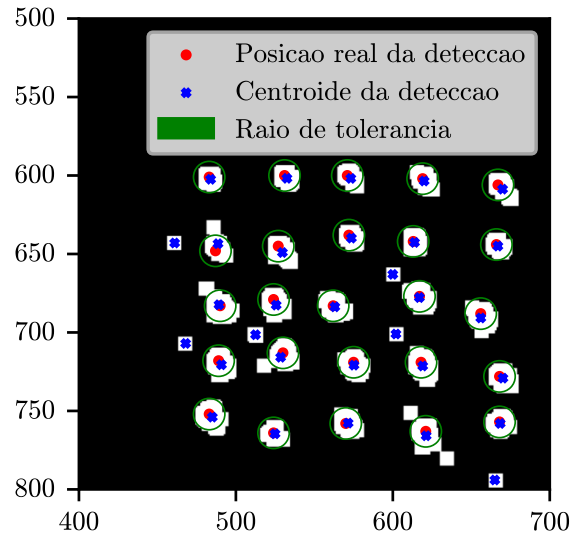
Entrada: Mapa binário de mudança C
Entrada: Lista de posições reais l

- 1 Identificar objetos a partir dos pixels conectados em C ;
- 2 Encontrar os centroides de cada objeto;
- 3 Inicializar os contadores de falsos alarmes e detecções com 0;
- 4 **para** cada *centroide detectado* **faça**
- 5 **se** a posição do centroide está em um raio de 10 pixels de qualquer posição verdadeira **então**
- 6 Incrementar o contador de detecções;
- 7 Remover a posição verdadeira correspondente;
- 8 **fim**
- 9 **senão**
- 10 Incrementar o contador de falsos alarmes;
- 11 **fim**
- 12 **fim**
- 13 $P_d \leftarrow$ contador de detecções dividido por 25;
- 14 $FAR \leftarrow$ contador de falsos alarmes dividido por 6;

Saída: Probabilidade de detecção P_d
Saída: Taxa de falsos alarmes FAR

Com este procedimento podemos criar então uma tabela de resultados e comparar com os valores demonstrados na literatura. A fim de validar os algoritmos desenvolvidos foi executado o algoritmo não iterativo e o procedimento de validação de detecções para as distribuições demonstradas na literatura e comparado os resultados.

Figura 13 – Representação visual do raio de validação das detecções




3.2.2 Reprodução dos resultados para o algoritmo não iterativo


Primeiramente foram reproduzidos os resultados para a distribuição Rayleigh bivariada, os pares de imagens utilizados foram os estabelecidos na literatura, apresentados na Tabela 1.

Podemos identificar nas imagens de detecção obtidas pelo algoritmo que ocorre o comportamento esperado, conforme o valor de λ aumenta, ocorre uma diminuição de falsos alarmes conjuntamente com a diminuição da probabilidade de detecção. A Figura 14 mostra esse comportamento para a missão 2 passagem 1 com $\tau = 0.4$.


Figura 14 – Imagem de detecção com a distribuição Rayleigh bivariada $\tau = 0.4$ para a missão 2 passagem 1



(a) $\lambda = 0.1$



(b) $\lambda = 0.5$



(c) $\lambda = 0.9$

Tabela 1 – Experimentos utilizados para execução de algoritmos, cada célula referenciando uma imagem do dataset representados pela notação $MxPy$ em que x indica o número da missão e y o número da passagem.

	Pares		Trios		
	A	B	A	B	C
1	M2P1	M3P1	M2P1	M4P1	M3P1
2	M3P1	M4P1	M3P1	M5P1	M4P1
3	M4P1	M5P1	M4P1	M2P1	M5P1
4	M5P1	M2P1	M5P1	M3P1	M2P1
5	M2P2	M4P2	M2P2	M4P2	M3P2
6	M3P2	M5P2	M3P2	M5P2	M4P2
7	M4P2	M2P2	M4P2	M2P2	M5P2
8	M5P2	M3P2	M5P2	M3P2	M2P2
9	M2P3	M5P3	M2P3	M4P3	M3P3
10	M3P3	M2P3	M3P3	M5P3	M4P3
11	M4P3	M3P3	M4P3	M2P3	M5P3
12	M3P3	M4P3	M5P3	M3P3	M2P3
13	M2P4	M3P4	M2P4	M4P4	M3P4
14	M3P4	M4P4	M3P4	M5P4	M4P4
15	M4P4	M5P4	M4P4	M2P4	M5P4
16	M5P4	M2P4	M5P4	M3P4	M2P4
17	M2P5	M4P5	M2P5	M4P5	M3P5
18	M3P5	M5P5	M3P5	M5P5	M4P5
19	M4P5	M2P5	M4P5	M2P5	M5P5
20	M5P5	M3P5	M5P5	M3P5	M2P5
21	M2P6	M5P6	M2P6	M4P6	M3P6
22	M3P6	M2P6	M3P6	M5P6	M4P6
23	M4P6	M3P6	M4P6	M2P6	M5P6
24	M5P6	M4P6	M5P6	M3P6	M2P6

Para analisar a performance como um todo do algoritmo entre todas os experimentos realizados utilizamos a curva ROC. A Figura 15 compara as curvas ROC originais e desenvolvidas para cada valor de τ utilizado. Pode-se observar que os resultados obtidos foram próximos dos esperados, embora tenham apresentado maior dificuldade em atingir $P_d = 1$, o que possivelmente se deve à metodologia de validação de detecções utilizada.

Foi também reproduzido os resultados para a distribuição Gaussiana. Diferentemente da distribuição Rayleigh, a distribuição Gaussiana precisa passar por um processo de formação da imagem, uma vez que o modelo é adequado para imagens de diferença (Machado *et al.*, 2016), ou seja é necessário subtrair duas imagens para que a característica estatística dela seja Gaussiana. Por esse motivo os experimentos realizados utilizam os trios apresentados na Tabela 1. A Figura 16 apresenta os resultados por meio de uma curva ROC. Como pode ser visto, existe em um dos pontos divergência de resultado de P_d para o mesmo FAR , isso pode ser explicado pela aplicação da metodologia de validação



Figura 15 – Curvas ROC de validação para distribuição Rayleigh com diferentes τ 

Figura 16 – Curva ROC de validação para distribuição Gaussiana



de detecções.

3.3 ALGORITMO ITERATIVO

Os estudos desenvolvidos por Alves, Palm, Hellsten, Machado *et al.* (2023) exploram a versão iterativa do algoritmo de detecção de mudanças baseado no teorema de Bayes. A partir deste arcabouço foi desenvolvido o Pseudocódigo 3.

Diferentemente do algoritmo não iterativo, o algoritmo iterativo realiza o processamento de criação de histograma e cálculo da PDF para cada detecção. Isso ocorre porque ao invés de realizar todas as detecções de uma única vez, o algoritmo escolhe o ponto de maior probabilidade como detecção da iteração e repete o processo até que o valor de probabilidade visto seja menor que o limiar λ definido.

Para que sejam reduzidas as chances de um grupo de posições pertencentes a mesma detecção sejam classificados como múltiplas detecções, cada iteração define o ponto de maior probabilidade como detecção e exclui as posições adjacentes numa janela de 31×31 com a detecção no centro. As posições de maior probabilidade são armazenadas em uma lista, esta sendo o resultado do algoritmo.

Pseudocódigo 3: Algoritmo iterativo

Entrada: Imagem de interesse z_s , Imagem de referência z_r

- 1 Inicializar matriz booleana de posições excluídas E ;
- 2 Inicializar contador de iteração: $K \leftarrow 1$;
- 3 Inicializa lista de posições detectadas d ;
- 4 **while** $\max(P) \geq \lambda$ **do**
- 5 $x_s \leftarrow$ posições não excluídas z_s ;
- 6 $x_r \leftarrow$ posições não excluídas z_r ;
- 7 Criar histograma 2D com os valores de x_s e x_r ;
- 8 Estimar parâmetros da distribuição com os valores de x_s e x_r ;
- 9 Criar máscara para as posições onde $z_s \geq z_s + \tau$ e não seja uma posição excluída;
- 10 Criar $P(z_s, z_r | s \neq s_T)$ com o cálculo da PDF para os pixels na máscara;
- 11 Criar $P(z_s, z_r)$ com a contagem de ocorrências dos valores de x_s e x_r ;
- 12 Criar matriz de probabilidade P ;
- 13 $P \leftarrow \max(0, 1 - P(z_s, z_r | s \neq s_T) / P(z_s, z_r) \times MK / N)$;
- 14 Aplicar filtro passa-baixas 3×3 ;
- 15 **se** $\max(P) \geq \lambda$ **então**
- 16 Adicionar posição a lista d ;
- 17 Marcar posições ao redor do alvo detectado na matriz E ;
- 18 $K++$;
- 19 **fim**
- 20 **end**

Saída: Lista de posições detectadas d

Para melhor aproveitamento do tempo de computação, foi optado por executar os algoritmos apenas uma vez para o menor valor de λ uma vez que este parâmetro apenas define o momento de parada do algoritmo. Dessa forma, para avaliação do comportamento do algoritmo para diferentes valores de λ é necessário um tratamento das posições detectadas, para que isso fosse possível foi armazenado a informação do valor da probabilidade máxima da iteração junto com a posição de linha e coluna da detecção.

Uma vez que a detecção é pontual, e não um conjunto de posições como no algoritmo não iterativo, não é necessário a extração da posição do centroide, dessa forma excluindo esta etapa, o mesmo procedimento apresentado no Pseudocódigo 2 pode ser aplicado para validação das detecções do algoritmo não iterativo.

3.3.1 Reprodução dos resultados para o algoritmo iterativo

Assim como realizado para o algoritmo não iterativo, foi aplicado o algoritmo iterativo para as distribuições Rayleigh e Gaussiana bivariadas a fim de comparar os resultados obtidos com os disponibilizados na literatura.

Inicialmente foi reproduzido os resultados para a distribuição Rayleigh bivariada, a Figura 17 mostra as detecções para diferentes valores de λ . Como podemos inspecionar

visualmente, um aumento de λ implica numa diminuição de falsos alarmes, assim como uma diminuição de probabilidade de detecção.




Figura 17 – Resultados do algoritmo iterativo para distribuição Rayleigh bivariada $\tau = 0.4$ para a missão 2 passagem 1

Com os resultados de todos os experimentos foi possível construir as curvas ROC. Como demonstrado nas Figuras 18 para Rayleigh, e 19 para Gaussiana. O resultado obtido foi satisfatoriamente próximo do resultado desejado.





Figura 18 – Curvas ROC de validação para distribuição Rayleigh com diferentes τ

3.4 DISTRIBUIÇÃO GAMMA BIVARIADA

Com os algoritmos reproduzidos e validados, foi dado início a implementação da distribuição Gamma bivariada como modelo de *clutter* para os algoritmos iterativos e não iterativos.

Para a aplicação do modelo, foi necessário inicialmente processar as imagens de forma que as características estatísticas do *clutter* se aproximassem de uma distribuição

Figura 19 – Curva ROC de validação para distribuição Gaussiana



Gamma bivariada. Esse processamento consistiu na criação de uma imagem de intensidade diferença, obtida a partir da subtração entre duas imagens seguida da elevação ao quadrado dos valores pixel a pixel. Considerando que os algoritmos requerem duas imagens —uma de vigilância (z_s) e uma de referência (z_r)—utilizamos os experimentos organizados em trios, conforme apresentados na Tabela 1. Nesse contexto, a imagem de referência z_r foi construída como $(a - c)^2$, enquanto a imagem de vigilância z_s foi formada como $(b - c)^2$.

A Figura 20 ilustra uma imagem de intensidade diferença criada utilizando o experimento 2 dos conjuntos de trios apresentados na Tabela 1. Foi limiarizada a imagem para facilitar visualização. Pode ser verificado a disposição de dois grupos de alvos na imagem, uma representando os alvos da imagem interesse a ou b , marcado em vermelho, e outra representando os alvos da imagem usada para subtração c .

Ao aplicar um algoritmo de detecção de mudanças todos estes alvos seriam mudanças válidas e detectadas pelo algoritmo. Como o objetivo é a detecção apenas dos alvos na imagem de interesse, foi necessária a computação em duas etapas do valor de z_r , primeiramente extraíndo o valor da diferença das imagens e posteriormente a criação da intensidade diferença. Dessa forma é possível manter a informação de qual mudança possui valor positivo—ou seja, representa um alvo presente na imagem de interesse e não presente na imagem de subtração—dessa forma pode-se remover os alvos da imagem de subtração. A Figura 21 ilustra a imagem de intensidade diferença com a máscara de valores de diferença positivos.

Este passo de exclusão de pontos é essencial para a exclusão de alvos que seriam detectados corretamente pelo algoritmo, mas representariam falsos alarmes no contexto da análise.

Para comparação com os valores empíricos analisados nas posições das imagens, criado utilizando o histograma, é necessária a computação dos valores teóricos a serem

Figura 20 – Imagem de intensidade diferença criada usando experimento 2 evidenciando pontos de maior intensidade





Figura 21 – Imagem de intensidade diferença, com máscara de valores de diferença positivos, criada usando experimento 2 evidenciando pontos de maior intensidade



comparados do modelo de *clutter*, isto é feito utilizando a PDF. Os parâmetros da distribuição são k e θ e são estimados utilizando *Maximum Likelihood Estimator* (MLE).

Com o estabelecimento destas etapas foi possível obter os resultados para os experimentos propostos e realizar a comparação com os demais modelos de *clutter*. Os resultados serão apresentados e discutidos no Capítulo 4.

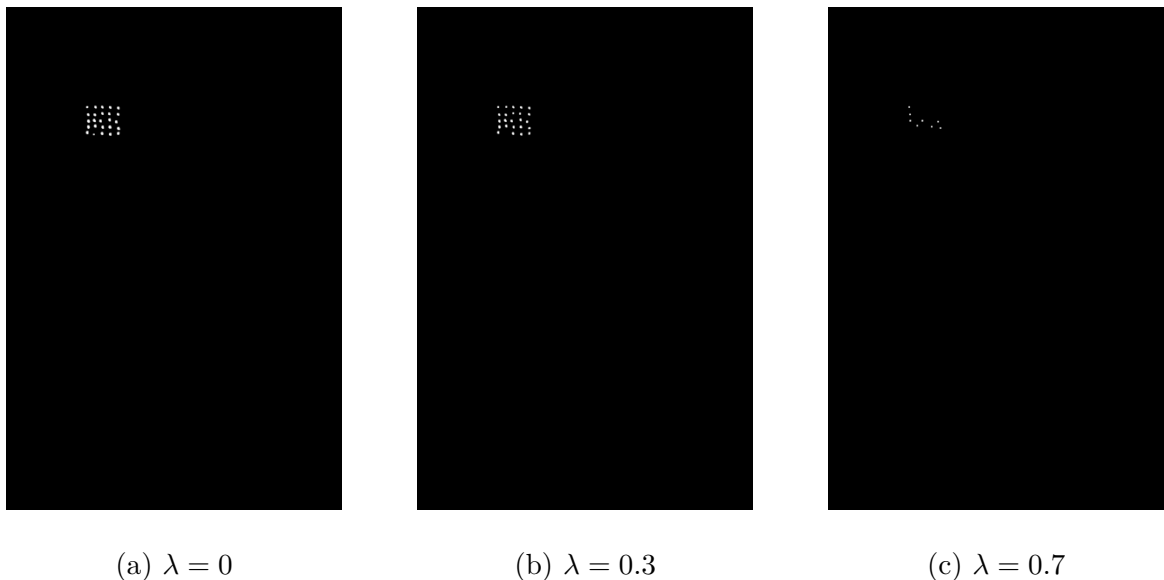
4 RESULTADOS

A partir dos algoritmos implementados e do modelo de *clutter* adaptado, foram realizados todos os experimentos e obtidos resultados para os algoritmos não iterativo e iterativo. As seguintes seções apresentam os resultados e os discute.

4.1 ALGORITMO NÃO ITERATIVO

A Figura 22 ilustra imagens de detecção para o algoritmo não iterativo com a distribuição Gamma bivariada como modelo de *clutter*, utilizando $\lambda \in \{0, 0.3, 0.7\}$. Verificamos um melhor desempenho no experimento realizado pela ausência de falsos alarmes evidenciados pelo limiar mais permissivo, i.e, $\lambda = 0$.

Figura 22 – Resultados do algoritmo não iterativo para diferentes λ para a distribuição Gamma bivariada $\tau = 0.4$ no experimento 1



A Figura 24 demonstra as curvas ROC obtidas para a distribuição. Como é possível observar na figura, a utilização do valor de guarda τ implica numa diminuição de taxa de falsos alarmes máxima, representada pelo ponto mais a esquerda no eixo de *FAR*.

A ocorrência desse comportamento pode ser explicada pela remoção de posições a serem testadas como possível posição de detecção. Como apresentado no Algoritmo 1, a utilização da máscara $z_s \geq z_r + \tau$ inibe que pequenas flutuações de valores de leitura tornem a posição uma célula válida de teste, e, ao aumentar o valor de τ mais posições são excluídas—como ilustrado na Figura 23— implicando na remoção de células que continham alvos nas imagens de intensidade diferença montadas.

Figura 23 – Resultados do algoritmo não iterativo para diferentes τ para a distribuição Gamma bivariada no experimento 10





Figura 24 – Curvas ROC para os valores de τ utilizados para a distribuição Gamma bivariada no algoritmo não iterativo



A Figura 25 apresenta as curvas ROC separadas por valor de τ . Analisando individualmente as figuras, é possível verificar que a Gamma bivariada obteve melhores resultados, com maiores valores de P_d para os mesmos FAR quando comparada com os demais modelos.

Uma análise essencial para a avaliação de algoritmos de detecção de mudanças é o valor de P_d para um dado FAR . Na literatura é comumente utilizado o valor de $FAR = 1/\text{km}^2$, porém, devido FAR máximo obtido—decorrente de τ nas curvas ROC da Gamam bivariada $\tau \in \{0.3, 0.4\}$ —não é possível utilizar este valor para comparação, visto que ele ultrapassa a FAR máxima obtida. Com essa limitação em mente foram escolhidos outros dois valores de FAR para comparação numérica entre os modelos, $FAR \in \{0.1, 0.25\}$.

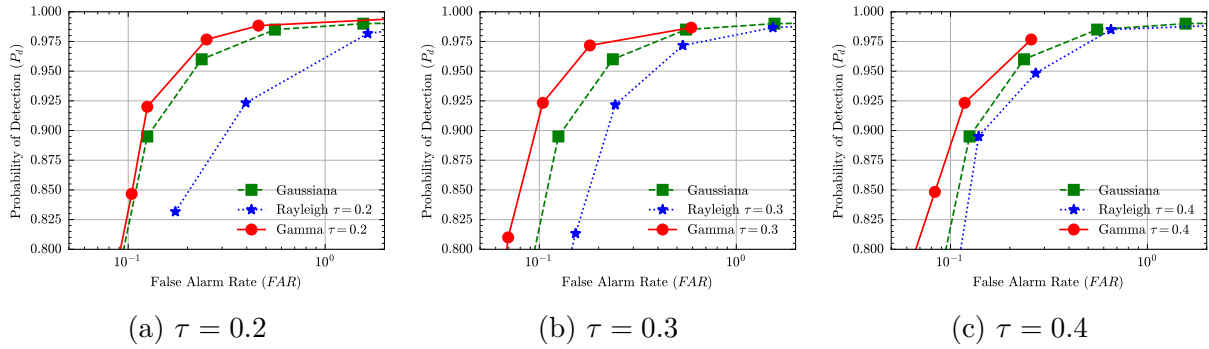


Figura 25 – Comparação das curvas ROC para os modelos de *clutter* aplicados ao algoritmo não iterativo

A Tabela 2 detalha os valores de P_d obtidos para cada distribuição e τ utilizados para cada FAR testado. Utilizando como base de comparação $FAR = 1/\text{km}^2$ observamos que a Gamma bivariada com $\tau = 0.2$ teve um resultados superior quando comparada com as demais distribuições, tendo um de 0.22 pontos percentuais quando comparada com a Gaussiana e 0.36 quando comparada com o melhor resultado utilizando a distribuição Rayleigh.

Analisando os resultados obtidos para FAR menores, como 0.25, identifica-se um maior ganho em pontos percentuais quando comparada com as demais distribuições, sendo possível identificar um ganho de 1.56 quando comparada a Gaussiana e 3.68 quando comparada com o melhor resultado da Rayleigh. Comparando os valores obtidos para $FAR = 0.1/\text{km}^2$ o modelo toma ainda mais uma posição de destaque atingindo ganhos de até 15.28 pontos percentuais.

Tabela 2 – P_d obtido para valores FAR de interesse para os modelos de *clutter* utilizados no algoritmo não iterativo

Distribuição	τ	P_d [%]		
		$FAR = 0.1/\text{km}^2$	$FAR = 0.25/\text{km}^2$	$FAR = 1/\text{km}^2$
Gamma	0.2	83.02	97.67	98.94
	0.3	90.97	97.42	-
	0.4	88.43	97.40	-
Gaussiana	0	81.46	96.11	98.72
Rayleigh	0.2	-	86.32	95.15
	0.3	68.51	92.29	97.86
	0.4	75.69	93.99	98.58

4.1.1 Publicação relacionada

Os resultados obtidos nesta seção deram origem ao artigo *Change Detection based on Bayes' Theorem for Intensity Wavelength-Resolution SAR Difference Images*, aprovado e publicado no *Simpósio Brasileiro de Telecomunicações (SBrT) 2025*. O trabalho será

apresentado em sessão oral durante o evento, que ocorrerá em Natal, Rio Grande do Norte.

O desenvolvimento do artigo contou com a participação dos professores Dimas Irion Alves e Diego da Silva de Medeiros, e pesquisadores Paulo Ricardo Branco da Silva, João Vitor Rosa Negri and Arthur Cadore Matuella Barcella.

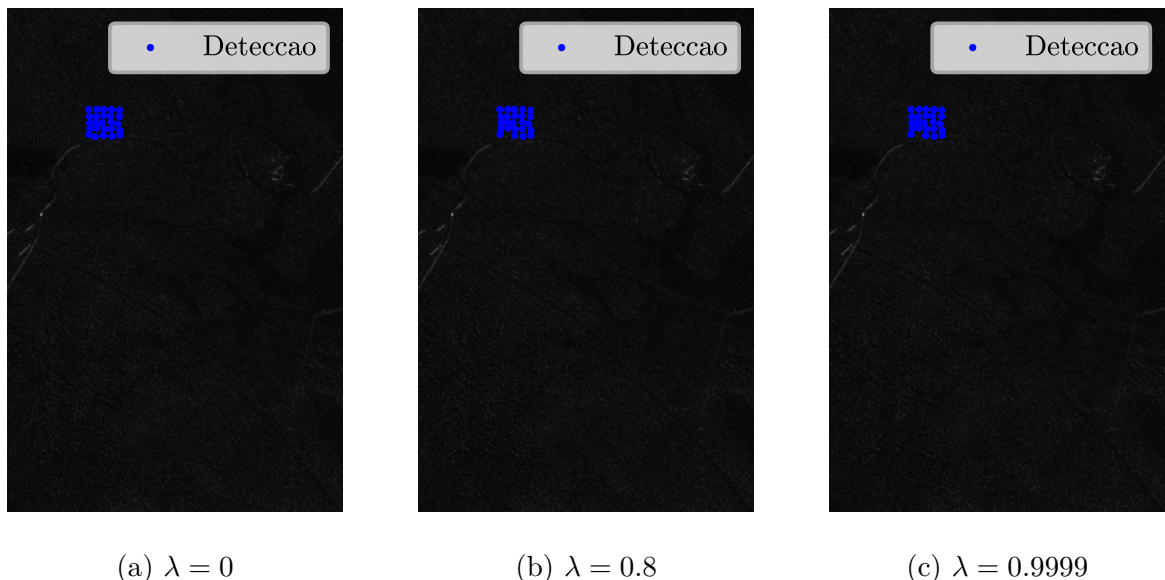
A versão final do artigo publicado está incluída nos apêndices, conforme apresentado no Apêndice A.

4.2 ALGORITMO ITERATIVO

Realizando as mesmas análises para os resultados do algoritmo iterativo, é possível verificar um melhor desempenho com a diminuição de falsos alarmes e uma alta probabilidade de detecção.

Ao analisar a Figura 26 podemos verificar o comportamento para os valores de λ utilizados. É possível verificar que mesmo utilizando 0 como limiar, a detecção é livre de falsos alarmes (para o experimento 1). A Figura 27 ilustra as detecções para os τ utilizados, utilizando $\lambda = 0$. É possível verificar a diminuição falsos alarmes com o aumento de τ .

Figura 26 – Resultados do algoritmo iterativo para diferentes λ para a distribuição Gamma bivariada $\tau = 0.4$ no experimento 1



Analisando globalmente o desempenho do modelo aplicado ao algoritmo no dataset, por meio de curvas ROC, a Figura 28 evidencia um desempenho maior e muito similar para τ 0.3 e 0.4, enquanto $\tau = 0.2$ possui um pior desempenho comparativo.

Figura 27 – Resultados do algoritmo iterativo para diferentes τ para a distribuição Gamma bivariada no experimento 1

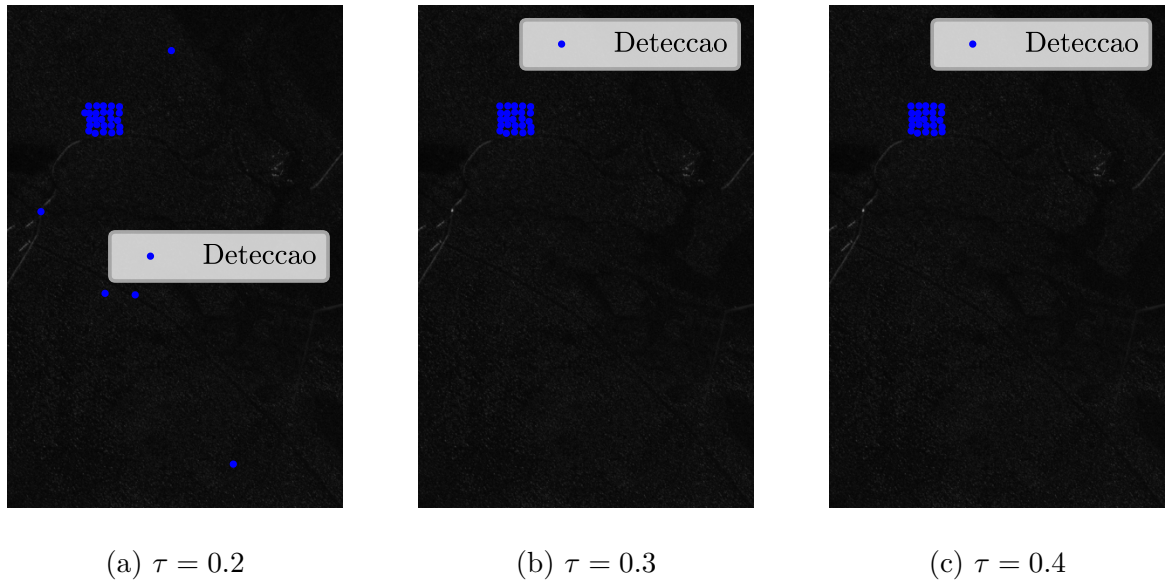
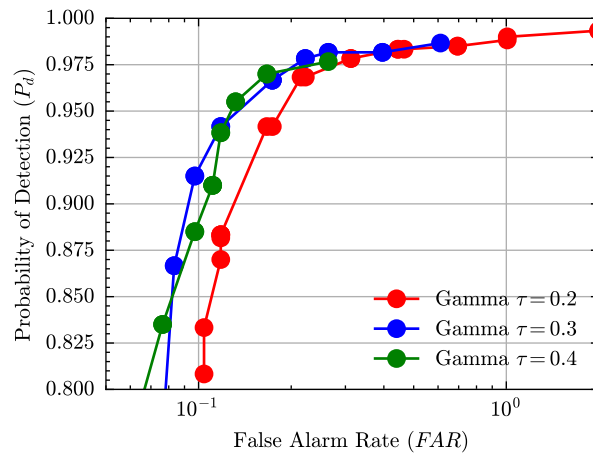


Figura 28 – Curvas ROC para os valores de τ utilizados para a distribuição Gamma bivariada no algoritmo iterativo



Com a Figura 29, ao comparar os resultados entre as distribuições para cada valor de τ utilizado percebemos que o desempenho do modelo proposto é equivalente ao da Gaussiana no algoritmo iterativo. A Tabela 3 evidencia os resultados para os FAR estabelecidos.

Como podemos analisar na Tabela 3, em a Gamma bivariada se sobressaiu para $FAR = 0.25/\text{km}^2$, obtendo ganhos de 0.58%, porém, analisando para outros valores de FAR , a distribuição apresentou desempenho similar ao da Gaussiana.

Figura 29 – Comparação das curvas ROC para os modelos de *clutter* aplicados ao algoritmo iterativo




Tabela 3 – P_d obtido para valores FAR de interesse para os modelos de *clutter* utilizados no algoritmo iterativo

Distribuição	τ	P_d [%]		
		$FAR = 0.1/\text{km}^2$	$FAR = 0.25/\text{km}^2$	$FAR = 1/\text{km}^2$
Gamma	0.2	-	97.14	98.99
	0.3	91.86	98.06	-
	0.4	89.00	97.57	-
Gaussiana	0	88.77	97.48	99.12
Rayleigh	0.2	-	-	93.37
	0.3	-	92.67	97.61
	0.4	-	94.57	98.58

5 CONCLUSÃO

Este trabalho teve como objetivo a análise da Gamma bivariada como modelo de *clutter* para imagens de intensidade diferença para sistemas SAR VHF UWB em algoritmos de detecção de mudanças baseados no teorema de Bayes. Para isso foram implementadas técnicas de processamento de sinais, análise estatística e programação.

A primeira etapa do trabalho foi a criação de ferramentas para manuseio do dataset CARABAS-II, onde foram desenvolvidas funções para orquestração das imagens e validação das posições reais dos alvos. Em seguida, foi realizada reprodução dos algoritmos da literatura seguidos da validação dos resultados obtidos para garantia de correteza na implementação.

Foi analisado o comportamento das detecções com o modelo aplicado aos algoritmos com foco no limiar de decisão de detecção λ e no valor de guarda τ , onde verificou-se a troca entre quantidade de falsos alarmes detectados e probabilidade de detecção, onde a criteriosidade com a minimização de falsos alarmes prejudica a probabilidade de detecção, assim como o contrário.

Percebeu-se também que a utilização de um valor τ é imprescindível para o melhor aproveitamento do desempenho do algoritmo, onde a diminuição possibilita o aumento de células a serem testadas—aumentando a probabilidade de falsos alarmes—e o aumento limitando a probabilidade de detecção.

A partir dos algoritmos implementados, foi aplicado o modelo de *clutter* alvo de estudo. Conclui-se que para o algoritmo não iterativo o modelo desempenha melhor quando comparado os já estudados pela literatura, obtendo ganhos de 1.56 pontos percentuais quando comparado com os melhores resultados. Já para o algoritmo iterativo avaliou-se uma equiparação de desempenho com a distribuição Gaussiana bivariada, obtendo P_d similares para mesmos valores de FAR avaliados.

5.1 TRABALHOS FUTUROS

Com o desenvolvimento deste trabalho, alguns pontos a serem explorados com mais profundidade foram encontrados, como:

- Análise de valor ótimo de τ para imagens diferença de intensidade;
- Comparação de metodologias de validação de detecções;
- Validação do desempenho do algoritmo iterativo com realocação de estimação de parâmetros da distribuição e criação do histograma fora do laço de repetição.

REFERÊNCIAS

- ALVES, Dimas Irion. **Change detection methods for wavelength-resolution SAR images**. 2020. f. 120. Tese (Doutorado) – Universidade Federal de Santa Catarina, Florianópolis, Brasil. Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, 2020. Disponível em: <https://repositorio.ufsc.br/handle/123456789/215951>.
- ALVES, Dimas Irion; PALM, Bruna Gregory; HELLSTEN, Hans; MACHADO, Renato *et al.* Change Detection Method for Wavelength- Resolution SAR Images Based on Bayes' Theorem: An Iterative Approach. **IEEE Access**, v. 11, p. 84734–84743, 2023. Conference Name: IEEE Access. ISSN 2169-3536. DOI: 10.1109/ACCESS.2023.3303107. Disponível em: <https://ieeexplore.ieee.org/document/10210380>. Acesso em: 19 out. 2024.
- ALVES, Dimas Irion; PALM, Bruna Gregory; HELLSTEN, Hans; VU, Viet Thuy *et al.* Wavelength-Resolution SAR Change Detection Using Bayes' Theorem. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 5560–5568, 2020. Conference Name: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. ISSN 2151-1535. DOI: 10.1109/JSTARS.2020.3025089. Disponível em: <https://ieeexplore.ieee.org/document/9200787>. Acesso em: 12 fev. 2025.
- FAWCETT, Tom. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, jun. 2006. ISSN 0167-8655. DOI: 10.1016/j.patrec.2005.10.010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016786550500303X>. Acesso em: 12 fev. 2025.
- HELLSTEN, Hans *et al.* Development of VHF CARABAS II SAR. *In: RADAR Sensor Technology*. SPIE, jun. 1996. v. 2747, p. 48–60. DOI: 10.1117/12.243087. Disponível em: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/2747/0000/Development-of-VHF-CARABAS-II-SAR/10.1117/12.243087.full>. Acesso em: 30 set. 2024.
- MACHADO, Renato *et al.* The Stability of UWB Low-Frequency SAR Images. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 8, p. 1114–1118, 2016. DOI: 10.1109/LGRS.2016.2569582.
- MITTMANN VOIGT, Gustavo Henrique *et al.* A Statistical Analysis for Intensity Wavelength-Resolution SAR Difference Images. *en. Remote Sensing*, v. 15, n. 9, p. 2401, jan. 2023. Number: 9 Publisher: Multidisciplinary Digital Publishing Institute. ISSN 2072-4292. DOI: 10.3390/rs15092401. Disponível em: <https://www.mdpi.com/2072-4292/15/9/2401>. Acesso em: 27 set. 2024.
- MOREIRA, Alberto *et al.* A tutorial on synthetic aperture radar. **IEEE Geoscience and Remote Sensing Magazine**, v. 1, n. 1, p. 6–43, mar. 2013. Conference Name: IEEE Geoscience and Remote Sensing Magazine. ISSN 2168-6831. DOI: 10.1109/MGRS.

2013.2248301. Disponível em: <https://ieeexplore.ieee.org/document/6504845>. Acesso em: 6 fev. 2025.

RICHARDS, M. A. *et al.* (ed.). **Principles of modern radar**. Raleigh, NC: SciTech Pub, 2010. ISBN 978-1-891121-52-4.

ULANDER, L.M.H. *et al.* Change detection for low-frequency SAR ground surveillance. en. **IEE Proceedings - Radar, Sonar and Navigation**, v. 152, n. 6, p. 413, 2005. ISSN 13502395. DOI: 10.1049/ip-rsn:20050002. Disponível em: https://digital-library.theiet.org/content/journals/10.1049/ip-rsn_20050002. Acesso em: 1 nov. 2024.

APÊNDICE A – ARTIGO SBRT

Change Detection based on Bayes' Theorem for Intensity Wavelength-Resolution SAR Difference Images

Gabriel Luiz Espindola Pedro, Dimas Irion Alves, Diego da Silva de Medeiros,
Paulo Ricardo Branco da Silva, João Vitor Rosa Negri and Arthur Cadore Matuella Barcella

Abstract—Detecting concealed targets under foliage remains a significant challenge for wavelength-resolution synthetic aperture radar (SAR) systems. This paper proposes the usage of the bivariate Gamma distribution as a clutter model, shown to be a well-fitted distribution for intensity SAR difference images, on an noniterative Change Detection (CD) algorithm based on Bayes' Theorem. The results were compared by using ROC curves and a probability of detection of 98.94% at false alarm ratio of 1 per kilometer squared was achieved, outperforming previously used distributions in the literature.

Keywords—CARABAS II, change detection, bivariate Gamma distribution, background statistics

I. INTRODUCTION

Detecting concealed targets beneath vegetation is a persistent challenge for conventional imaging systems. Optical sensors, in particular, are highly susceptible to weather conditions. Synthetic Aperture Radar (SAR) systems mitigate the impact of weather on image formation. However, in traditional microwave SAR systems, foliage still interacts with the radar signal, making concealed-target detection difficult [1].

To address this issue, wavelength-resolution SAR systems operate at low frequencies, ensuring that the dominant scatterers correspond to the transmitted signal's wavelength, i.e., small scatterers will not add predominant interference on the reflected signal, thus penetrating vegetation and being able to detect targets under foliage [2]. Additionally, these systems are not significantly affected by the speckle noise phenomenon [3].

Due to the electromagnetic nature associated with SAR image formation, interpreting information in SAR images tends to be challenging for human analysts [4]. Because of this, target detection is usually done using automatic detection

Gabriel Luiz Espindola Pedro, Diego da Silva de Medeiros Arthur Cadore Matuella Barcella are with the Department of Telecommunications, Instituto Federal de Santa Catarina, São Jose-SC, e-mails: gabrielluizep.glep@gmail.com, diegomedeiros@ifsc.edu.br, arthurbarcella.cadore@gmail.com. Dimas Irion Alves and Paulo Ricardo Branco da Silva are with the Department of Telecommunications, Instituto Tecnológico da Aeronáutica, São José dos Campos-SP, e-mails: dimasirion@ita.br and pbranco@ita.br; João Vitor Rosa Negri is with the Department of Communications and Signal Processing, Universidade Federal de Santa Catarina, Florianópolis-SC, e-mail: joao.vitornegri@gmail.com. This work was partially sponsored by FINEP (01.22.0581.00), National Institute of Science and Technology (INCT-Signals) sponsored by Brazil's National Council for Scientific and Technological Development (CNPq) under grant no. 406517/2022-3, Ministry of Science, Technology and Innovation (MCTI), and by the São Paulo Research Foundation (FAPESP) under grant 20/09838-0 (BIOS—Brazilian Institute of Data Science).

algorithms [4]. One category of algorithms often used for this task is change detection algorithms, which check for variations between two or more images [5], [6].

Considering the statistical behavior of SAR images, Change Detection (CD) methods are typically developed using statistical approaches. Some studies employ the Likelihood Ratio Test (LRT) [7], which evaluates the likelihood of the null hypothesis H_0 , stating that the region under test consists of clutter, against the alternative hypothesis H_1 , indicating the presence of a target. Other studies adopt an approach based on Bayes' Theorem, in an iterative and noniterative manner [6], [8], to perform detection by comparing the expected value of a pixel under the clutter model with the empirical value observed in the image.

Since clutter statistics can be modeled as following a known distribution, the performance of the CD method can be improved by identifying a distribution that more accurately represents the clutter behavior in these type of images. Additionally, by processing the images, their statistical properties change, making it possible to describe clutter behavior using different distributions [9].

In [6], it was shown that the Bivariate Rayleigh distribution can be used to model the clutter in incoherent wavelength-resolution SAR images, particularly in regions of interest for detection. Additionally, studies have demonstrated that the Bivariate Gamma distribution provides a good fit for intensity wavelength-resolution SAR difference images [9].

Considering that the Bayesian CD method developed by Alves et al. demonstrated superior performance compared to other approaches in the literature [8], and that it relies on an underlying clutter model, this paper focuses on applying the statistical model proposed in [9] within the CD framework of [8]. We adopt the non-iterative version of the CD method due to its lower computational complexity.

The remainder of this paper is organized as follows. Section II describes the characteristics of wavelength-resolution SAR images and the dataset used in the performance tests. Section III presents the change detection method used in this paper. Section IV demonstrates the results obtained for the change detection method with the currently studied models for the clutter-plus-noise in the literature and the tested model. Section V discusses the results obtained and the metric algorithm for validating detection and false alarms. Finally, section VI brings concluding remarks of the study.

II. WAVELENGTH-RESOLUTION SAR IMAGES

Traditionally SAR systems uses microwave wavelengths to image the scenario [1]. This choice of frequency impacts directly the penetrability of the signal. In this sense, traditional SAR systems are not well suited for Foliage Penetration (FOPEN) applications, since smaller wavelengths suffers from back-scattering from small objects, thus leaves impacting substantially the reflected signal [1].

In the wavelength-resolution regime the spatial resolution of the SAR system is comparable to the wavelength of the transmitted signal, i.e., the distance between two distinguishable objects is in the order of the wavelength of the transmitted signal [1]. To emphasize the detection of larger targets, signals with longer wavelengths are used, i.e., signals with frequencies in the order of MHz.

This characteristic leads also to a minimization of speckle noise, since one resolution cell has at most one scatterer [3]. Also, due to the temporal characteristics of large targets, the images exhibit temporal stability, being a good candidate for CD [3].

Illustrating the concept of a wavelength-resolution system, the CARABAS-II is a Very High Frequency (VHF) Ultra-wideband (UWB) SAR system developed by the Swedish Defense Research Agency (FOI). Mounted on a Sabreliner aircraft, the system uses radio waves emitted from two phased wide-band dipoles with frequencies ranging from 20 to 90 MHz to create scene imagery [10]. The system features a cell resolution of 1×1 (one pixel per square meter) and a system resolution of approximately 2.5×2.5 (minimum detectable object size).

One of the core applications of the VHF SAR systems is FOPEN, in 2002 it was developed a flight campaign in Visdel, Sweden, which provided a dataset containing 24 images, each of them covering an area of $3 \text{ km} \times 2 \text{ km}$, containing 25 vehicles deployed on the forest that was imaged [5]. The images are divided in four deployments, each deployment containing six passes with three groups of two repeated flight headings. Figure 1 shows an example of image from the dataset, which can be found in [11].

III. CHANGE DETECTION METHOD

The CD method presented in this work employs Bayes' Theorem to compute the probability of pixel-level changes [6]. For each pixel, we evaluate the posterior probability $P(s \equiv s_T | z_s, z_r)$ of containing a target change ($s \equiv s_T$) given surveillance (z_s) and reference (z_r) image values as

$$P(s \equiv s_T | z_s, z_r) = \frac{P(z_s | s \equiv s_T, z_r) P(s \equiv s_T | z_r)}{P(z_s | z_r)}. \quad (1)$$

Applying the Bayes Theorem and the considerations made in [6], we achieve the equation that relates the probability of a pixel containing a target with the empirical values and the theoretical expected clutter values, defined as

$$P(s \equiv s_T | z_s, z_r) = \max\left(0, 1 - \frac{P(z_s, z_r | s \neq s_T)}{P(z_s, z_r)}\right), \quad (2)$$

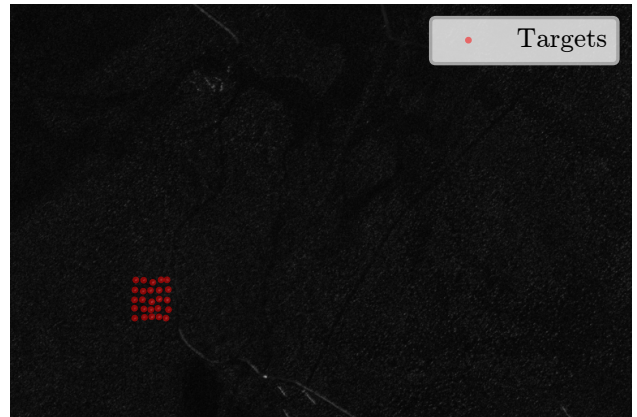


Fig. 1: An example image acquired during Mission 2, Pass 3 of the CARABAS-II campaign, with targets highlighted in red.

where $P(z_s, z_r | s \neq s_T)$ represents the clutter-conditional probability and $P(z_s, z_r)$ denotes the total empirical probability. The $P(z_s, z_r | s \neq s_T)$ derives from a bivariate distribution Probability Density Function (PDF), while the $P(z_s, z_r)$ term is estimated through histogram analysis of empirical pixel value co-occurrences.

It is expected that the histogram constructed from two images containing only clutter will closely match the shape of the theoretical distribution PDF. The addition of targets to the images results in higher observed values, which are not predicted by the PDF, leading to a mismatch between the histogram and the theoretical model. This discrepancy indicates a high probability of change obtained by (2).

Based on (2), we can describe the change detection method considered in this work, which consists, respectively, of obtaining the empirical histogram, calculating (2), detection based on a threshold, and a stage of morphological operations to exclude detections of objects with dimensions that do not fit the application. This method is represented in the simplified block diagram presented in Figure 2.




Fig. 2: Block diagram for noniterative algorithm, adapted from [6].

There are established models for the clutter-plus noise for wavelength-resolution SAR imagery, for example bivariate complex Normal distribution for complex images [7], bivariate Rayleigh distribution for magnitude images [12], bivariate Normal distribution for difference images [8] and bivariate

Gamma distribution for intensity difference images [9]. Based on the observed results, this work will evaluate the bivariate Normal, Rayleigh and Gamma distribution models.

A. Implementation Aspects

As the bivariate Gamma distribution is established as a model for clutter-plus-noise in intensity difference images, it is required to create this type of image from the combination of pairs, by subtracting two base images and squaring it [9]. For comparison, we used the same combinations provided in [9].

Knowing that large structures that also can reflect the transmitted signal are stable in time, we focus the analysis on appearing targets in the z_s , occurring only when $z_s \geq z_r$, and, to avoid small value fluctuations to be considered as valid cells to test, we add a guard value τ to test the cell only when $z_s \geq z_r + \tau$, the same constraints are made in [8], [6], [12], [13]. This reduces computational effort and focuses the analysis on the distribution tail, where the targets are most likely localized, and the histogram matches the theoretical PDF more. For a fair comparison, we used the same values provided by literature $\tau \in \{0.2, 0.3, 0.4\}$.

To calculate the probability $P(z_s, z_r | s \neq s_T)$, we first need to estimate the shape k and scale θ parameters for the z_s and z_r images from the CD pair. For the parameter estimation, the Maximum Likelihood Estimator (MLE) was employed.

Subsequently, the association parameter η between the image pair can be calculated by

$$\eta = \begin{cases} \rho \sqrt{\frac{k_s}{k_r}} & \text{if } k_1 \geq k_2 \\ \rho \sqrt{\frac{k_r}{k_s}} & \text{if } k_1 < k_2 \end{cases}, \quad (3)$$

where ρ is the Pearson's product-moment correlation coefficient.

Based on this setup, the bivariate Gamma PDF can be computed to retrieve the likelihood of a pixel being clutter, given by

$$\begin{aligned} f(z_s, z_r) &= \frac{1}{\Gamma(k_r) \Gamma(k_s - k_r) \theta_s \theta_r (1 - \eta) \eta^{(k_r - 1)/2}} \\ &\times \left(\frac{z_s}{\theta_s}\right)^{k_s - k_r} \left(\frac{z_s z_r}{\theta_s \theta_r}\right)^{(k_r - 1)/2} \\ &\times \exp\left[-\frac{1}{1 - \eta} \left(\frac{z_s}{\theta_s} + \frac{z_r}{\theta_r}\right)\right] \\ &\times \int_0^1 (1 - t)^{(k_r - 1)/2} t^{(k_s - k_r - 1)} \\ &\times \exp\left[\frac{\eta}{1 - \eta} \left(\frac{z_s}{\theta_s}\right) t\right] \\ &\times I_{k_r - 1} \left[\frac{2}{1 - \eta} \sqrt{\eta \left(\frac{z_s z_r}{\theta_s \theta_r}\right) (1 - t)} \right] dt, \end{aligned} \quad (4)$$

where $I_{(\cdot)}[\cdot]$ stands for the modified Bessel function of the first kind.

It is important to emphasize that the calculation of the bivariate Gamma PDF has an elevated processing cost due to the integral calculation with a Bessel function in the integrand. Therefore, τ plays an important role in reducing the amount of pixels that will be calculated, making the process quicker. As a result of the change detection method we are left with a bi-dimensional probability matrix, with each value in the matrix representing the likelihood of the corresponding pixel contains a target.

In order to define a detection, we must compare the value with a threshold λ . A detection is declared at a pixel if $P(s \equiv s_T | z_s, z_r) \geq \lambda$. To ensure consistency, we adopted values for $\lambda \in \{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8\}$, same as in [6].

For false alarm minimization, morphological operations are performed. By using erosion, we are able to eliminate small detections that did not represent actual targets, since the target dimensions are greater than the system resolution. The erosion process was followed by two dilation steps: first, a dilation using a 3×3 kernel—the same size as the one used for erosion—was applied to restore detections larger than 3 meters. Subsequently, a second dilation was performed with a 7×7 kernel, resulting in detected targets that represent areas of 10×10 meters.

To validate correct detections and false alarms, we compared the centroids of the detected objects with the ground truth positions from the deployment. A detection is considered correct if its centroid lies within 10 meters of any ground truth position, otherwise, it is classified as a false alarm. To ensure consistency, the literature models were also subjected to the same validation criteria. Algorithms 1 and 2 illustrates as a pseudo-code the step by step process for the change detection process and the detection and false alarm evaluation.

Algorithm 1: Detection process pseudo-code

- Data:** Interest image a ; Reference image b ;
Subtraction base image c
- 1 Create the z_s and z_r images;
 - 2 $z_s \leftarrow |a - c|^2$;
 - 3 $z_r \leftarrow |b - c|^2$;
 - 4 Create a 2D histogram with the values of z_s and z_r ;
 - 5 Estimate k_s k_r θ_s θ_r and η ;
 - 6 Create a mask for the pixels where $z_s \geq z_r + \tau$;
 - 7 Create $P(z_s, z_r | s \neq s_T)$ with the PDF for the pixels within the mask;
 - 8 Create $P(z_s, z_r)$ with the recurrence count for z_s and z_r values;
 - 9 Create the target likelihood matrix P ;
 - 10 $P \leftarrow \max(0, 1 - P(z_s, z_r | s \neq s_T) / P(z_s, z_r))$;
 - 11 Apply low-pass filter with kernel 3×3 ;
 - 12 $P \leftarrow 0$ in the pixels where $(a - c) < 0$;
 - 13 Create detections matrix D ;
 - 14 $C \leftarrow P > \lambda$;
 - 15 Erode C with kernel 3×3 ;
 - 16 Dilate C with kernel 3×3 ;
 - 17 Dilate C with kernel 7×7 ;
- Result:** Binary change map C
-

Algorithm 2: Detection validation process pseudo-code

Data: Binary change map C

Data: Ground truth positions pixel list l

- 1 Identify objects from the connected pixels in C ;
 - 2 Find the centroids of each object;
 - 3 Initialize false alarms and detection counters with 0;
 - 4 **for** each detected centroid **do**
 - 5 **if** the centroid position is in a 10 pixel radius of any ground truth **then**
 - 6 Increment the detection counter;
 - 7 Delete ground truth position;
 - 8 **else**
 - 9 Increment false alarm counter;
 - 10 **end**
 - 11 **end**
 - 12 $P_d \leftarrow$ detection counter divided by 25;
 - 13 $FAR \leftarrow$ false alarms counter divided by 6;
- Result:** Probability of detection P_d
- Result:** False alarm rate FAR
-

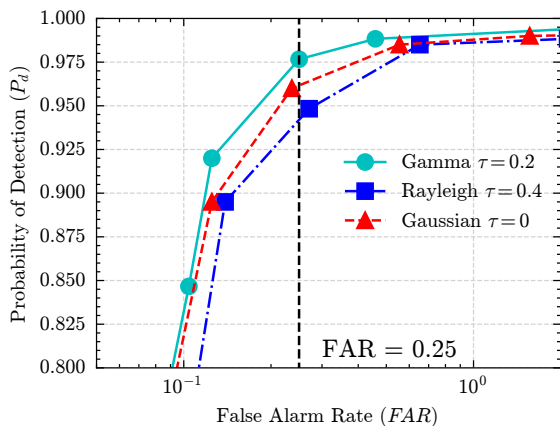


Fig. 3: ROC Curves comparing Gamma with literature models

IV. RESULTS

This paper evaluates the performance of the proposed CD algorithm by analyzing Receiver Operating Characteristic (ROC) curves under different clutter models. As a comprehensive benchmark against other algorithms lies beyond the scope of this work, the analysis is restricted to variations in clutter modeling.

Figure 3 presents an ROC curve comparing the best results obtained for each model. The value $\tau = 0.2$ was selected for the bivariate Gamma due to its superior performance in the false alarm rate range of interest. For the bivariate Rayleigh, $\tau = 0.4$ was used as it provided the best overall result for that distribution. In the case of the bivariate Normal, $\tau = 0$ was chosen due to the lower complexity of its PDF and the good match with the histogram in the center region. Among all tested τ values, the bivariate Gamma distribution consistently achieves a higher Probability of Detection (P_d) than the other distributions under the same False Alarm Rate (FAR) scenario.

As is shown in Figure 3 an increase in the threshold λ reduces false alarms, concurrently limiting the detection. The CD image visual inspection confirms that behavior, Figure 4 shows the detection image for experiments 1 and 18 [9], for $\tau = 0.2$, $\lambda = 0.1$ and $\lambda = 0.3$.

TABLE I: P_d performance comparison for different clutter-plus-noise models at $FAR = 0.25/\text{km}^2$ and $FAR = 1.00/\text{km}^2$.

Model	τ	P_d [%]	
		$FAR = 0.25/\text{km}^2$	$FAR = 1/\text{km}^2$
Gamma	0.2	97.67	98.94
	0.3	97.42	-
	0.4	97.40	-
Gaussian	0.0	96.11	98.72
Rayleigh	0.4	93.99	98.58


As τ increases, the maximum FAR decreases, which leads to a smaller maximum point in the FAR axis for the curves with greater τ values. Considering this, we selected two operation points, one for the minimum FAR value between the maximum of each τ curve, $FAR = 0.25/\text{km}^2$, and one for the standard operation point in the literature, $FAR = 1/\text{km}^2$. Enabling the comparison among all τ values tested in this study and the standard used in the literature. Table I shows a comparison of P_d at the two chosen operation points for FAR . Obtaining the best result for the bivariate Gamma model with $\tau = 0.2$, with 97.67% and 98.94%, for FAR values of 0.25 and 1 per kilometer squared respectively.

V. DISCUSSION


The bivariate Gamma model outperforms the other clutter models applied to the CD algorithm discussed in this paper. However, the model does not entirely capture all clutter behavior, as indicated by the use of τ , which limits the analysis to the tail of the distribution, where detection takes place.

The use of τ also reduced the number of tested pixels, directly impacting computational time. Given that the calculation of the PDF is computationally expensive, it is crucial to assess the operational applicability of this approach for time-sensitive applications. In the case of the Gamma distribution, τ tends to be highly selective, which helps reduce false alarms but can also lead to the removal of actual targets. Without applying τ , however, the system becomes computationally costly and prone to a large number of false positives due to distribution mismatch. Therefore, a compromise value of $\tau = 0.2$ was adopted. For the Rayleigh model, $\tau = 0.4$ was selected, as it yielded the best detection performance. Finally, for the Normal distribution, $\tau = 0$ was used both because of its simplicity and because it resulted in the best performance among the tested configurations.

As observed in Table I, as the values of τ decrease, P_d increases for a fixed value of FAR . This suggests that there is an optimal value of τ at which the maximum P_d can be achieved. In high FAR scenarios, potentially false alarms link one or more correctly detected targets. This event shifts the centroid of the detected object, which may result in a reduction in the number of detected targets. Also, if a false alarm links



(a) Experiment 1, $\lambda = 0.1$ (b) Experiment 18, $\lambda = 0.1$



(c) Experiment 1, $\lambda = 0.3$ (d) Experiment 18, $\lambda = 0.3$

Fig. 4: Comparison of detection results for experiments 1 and 18 at thresholds $\lambda = 0.1$ and $\lambda = 0.3$ on clutter model bivariate Gamma distribution with $\tau = 0.2$.

two objects, that would count as correct detection, and the centroid remains within a radius of 10 pixels from the ground truth, the detection would count as one. Figure 5 illustrates this scenario. With that, a better detection validation method should be considered.

VI. FINAL REMARKS

Overall, the bivariate Gamma distribution was shown to be more well-fitted to describe the tail behavior of the clutter, resulting in a reduction of false alarms when compared to the previously used in the literature. Reaching higher $P_d = 97.67\%$ for $FAR = 0.25/\text{km}^2$ and $P_d = 98.94\%$ for $FAR = 1/\text{km}^2$.

Although it achieved a superior P_d , it should be noticed that the bivariate Gamma distribution has an elevated computational cost due to the complexity of his PDF formula, and, differently from the bivariate Rayleigh distribution, it needs intensity difference images to serve as input for the method.

For future work, we will implement the iterative version of the change detection method to analyze the performance of




Fig. 5: Grouped detection example from experiment 18 using the Rayleigh model with $\tau = 0.4$.

P_d using the bivariate Gamma distribution as a clutter model. Additionally, a study on the effects of τ on the ROC curve is planned to evaluate the optimal point for maximizing the probability of detection.

REFERENCES

- [1] H. Hellsten, *Meter-wave synthetic aperture radar for concealed object detection*. Boston: Artech house, 2017.
- [2] G. Smith, A. Persson, J. Hohmgren, B. Hallberg, J. Fransson, and L. Ulander, "Forest stem volume estimation using high-resolution lidar and SAR data," in *IEEE International Geoscience and Remote Sensing Symposium*, vol. 4, Jun. 2002, pp. 2084–2086 vol.4. [Online]. Available: <https://ieeexplore.ieee.org/document/1026452>
- [3] R. Machado, V. T. Vu, M. I. Pettersson, P. Dammert, and H. Hellsten, "The Stability of UWB Low-Frequency SAR Images," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, no. 8, pp. 1114–1118, Aug. 2016.
- [4] C. Oliver and S. Quegan, *Understanding Synthetic Aperture Radar Images*. Raleigh, NC: SciTech Publishing, 2004.
- [5] M. Lundberg, L. M. H. Ulander, W. E. Pierson, and A. Gustavsson, "A challenge problem for detection of targets in foliage," E. G. Zelnio and F. D. Garber, Eds., Orlando (Kissimmee), FL, May 2006.
- [6] D. I. Alves, B. G. Palm, H. Hellsten, V. T. Vu, M. I. Pettersson, R. Machado, B. F. Uchôa-Filho, and P. Dammert, "Wavelength-Resolution SAR Change Detection Using Bayes' Theorem," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 5560–5568, 2020.
- [7] L. Ulander, M. Lundberg, W. Pierson, and A. Gustavsson, "Change detection for low-frequency SAR ground surveillance," *IEEE Proceedings - Radar, Sonar and Navigation*, vol. 152, no. 6, p. 413, 2005.
- [8] D. I. Alves, B. G. Palm, H. Hellsten, R. Machado, V. T. Vu, M. I. Pettersson, and P. Dammert, "Change Detection Method for Wavelength-Resolution SAR Images Based on Bayes' Theorem: An Iterative Approach," *IEEE Access*, vol. 11, pp. 84 734–84 743, 2023.
- [9] G. H. Mittmann Voigt, D. Irion Alves, C. Müller, R. Machado, L. P. Ramos, V. T. Vu, and M. I. Pettersson, "A Statistical Analysis for Intensity Wavelength-Resolution SAR Difference Images," *Remote Sensing*, vol. 15, no. 9, p. 2401, Jan. 2023.
- [10] H. Hellsten, L. M. H. Ulander, A. Gustavsson, and B. Larsson, "Development of VHF CARABAS II SAR," in *Radar Sensor Technology*, vol. 2747. SPIE, Jun. 1996, pp. 48–60.
- [11] Air Force Research Laboratory, Sensors Directorate, "Vhf change detection problem set," https://www.sdms.afrl.af.mil/index.php?collection=vhf_change_detection. [Online]. Available: https://www.sdms.afrl.af.mil/index.php?collection=vhf_change_detection
- [12] N. R. Gomes, M. I. Pettersson, V. T. Vu, P. Dammert, and H. Hellsten, "Likelihood ratio test for incoherent wavelength-resolution SAR change detection," in *2016 CIE International Conference on Radar (RADAR)*, Oct. 2016, pp. 1–4.
- [13] V. T. Vu, N. R. Gomes, M. I. Pettersson, P. Dammert, and H. Hellsten, "Bivariate Gamma Distribution for Wavelength-Resolution SAR Change Detection," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 1, pp. 473–481, Jan. 2019.