



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA
BACHARELADO EM ESTATÍSTICA

Vinicius Dias Moura Feijo

**DETECÇÃO DE BORDAS EM IMAGENS DE SENSORIAMENTO REMOTO
COM BASE EM SÉRIES TEMPORAIS: UMA ABORDAGEM UTILIZANDO
*MARKOV-SWITCHING GARCH***

Recife

2024

Vinicius Dias Moura Feijo

**DETECÇÃO DE BORDAS EM IMAGENS DE SENSORIAMENTO REMOTO
COM BASE EM SÉRIES TEMPORAIS: UMA ABORDAGEM UTILIZANDO
*MARKOV-SWITCHING GARCH***

Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Estatística da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Bacharel em Estatística.

Orientador (a): Abraão D.C. Nascimento

Recife

2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Feijo, Vinicius Dias Moura.

Detecção de bordas em imagens de sensoriamento remoto com base em séries temporais: uma abordagem utilizando markov-switching GARCH / Vinicius Dias Moura Feijo. - Recife, 2024.

40 p. : il., tab.

Orientador(a): Abrãao David Costa do Nascimento

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Ciências Exatas e da Natureza, Estatística - Bacharelado, 2024.

Inclui referências.

1. Processamento de Imagem. 2. Séries Temporais. 3. Sensoriamento Remoto. I. Nascimento, Abrãao David Costa do. (Orientação). II. Título.

000 CDD (22.ed.)

VINICIUS DIAS MOURA FEIJO

**DETECÇÃO DE BORDAS EM IMAGENS DE SENSORIAMENTO REMOTO
COM BASE EM SÉRIES TEMPORAIS: UMA ABORDAGEM UTILIZANDO
*MARKOV-SWITCHING GARCH***

Trabalho de conclusão de curso apresentado ao Curso de Bacharelado em Estatística da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Bacharel em Estatística.

Aprovado em: 11/03/2024

BANCA EXAMINADORA

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

Prof. Dr. Jodavid de Araújo Ferreira (Examinador)
Universidade Federal de Pernambuco

Dr. Pedro Monteiro de Almeida Junior (Examinador)
Universidade Federal de Pernambuco

AGRADECIMENTOS

Primeiramente, expresso minha profunda gratidão a Deus, que me abençoou com saúde e sabedoria, elementos cruciais que me permitiram chegar até este ponto. A presença divina foi um pilar de inspiração e um refúgio de paz ao longo de todo esse percurso desafiador.

Quero estender minha sincera gratidão à minha família, meus pais, Ricardo e Valdênia, e minha irmã, Gabriela, que foram fundamentais em cada momento da minha trajetória. Um agradecimento especial ao meu pai, cujo investimento na minha educação e formação, junto com sua inquestionável fé em minhas capacidades, foram essenciais. A eles, devo não somente amor e apoio incondicionais, mas também a sólida fundação que me guiou até este marco significativo.

Um agradecimento especial ao meu orientador, Abraão D.C. Nascimento, cuja orientação foi indispensável ao longo da minha jornada acadêmica. Sua paciência, disponibilidade e conhecimento não apenas enriqueceram minha formação, mas também foram cruciais para a realização deste trabalho.

Agradeço imensamente a Matheus, Marcelo, Hygor e Lucas, meus colegas de classe e amigos verdadeiros, por todos os momentos compartilhados, sejam eles de estudo ou de descontração. Cada um contribuiu significativamente para minha jornada acadêmica, com destaque especial para Matheus, cuja influência foi particularmente marcante. Minha gratidão pela amizade e suporte de vocês é enorme e será sempre lembrada com carinho.

Expresso minha profunda gratidão a todos os meus outros estimados amigos, pela riqueza de cada conversa, por cada gesto de apoio e pelos momentos de alegria compartilhados. A presença de vocês foi crucial, não apenas para manter o meu equilíbrio e bem-estar durante os desafiadores anos universitários, mas também em todas as facetas da minha vida.

Em conclusão, quero expressar minha gratidão a todos que, direta ou indiretamente, desempenharam um papel na realização deste trabalho e na minha jornada educacional. Cada palavra de encorajamento, cada gesto de apoio e cada instante compartilhado desempenharam um papel crucial em me levar até este ponto. A contribuição de cada um de vocês foi fundamental e profundamente valorizada.

RESUMO

A resolução de problemas de sensoriamento remoto (SR) é crucial para o progresso de qualquer sociedade. O radar de abertura sintética (*synthetic aperture radar* - SAR) é considerado uma ferramenta promissora para a resolução de problemas de geoprocessamento, uma vez que pode ser utilizado em diferentes condições meteorológicas e fornece imagens com elevada resolução espacial. Por outro lado, as imagens SAR estão sujeitas a fortes interferências, o chamado efeito *speckle*, o que requer a utilização de métodos de processamento adaptados, tais como técnicas refinadas de detecção de borda. Neste trabalho, apresentamos um método inovador para a detecção de fronteiras em imagens SAR utilizando a análise de séries temporais numa abordagem baseada em modelos GARCH de mudança de estado Markoviana. O nosso objetivo é um duplo avanço: Explorar como a mudança na volatilidade por detrás dos dados de intensidade SAR pode melhorar a precisão na detecção de fronteiras e propor um método com um custo computacional inferior ao da literatura SAR. Efetuamos experimentos simulados para verificar a precisão do nosso método utilizando realizações de séries temporais do processo GARCH(1,1) com uma transição de Markov entre dois estados diferentes. Além disso, é feita uma aplicação a imagens SAR reais da região próxima à costa de Japaratinga, AL. Os resultados dos experimentos simulados e reais mostram que nossas propostas podem ser muito úteis para a detecção de limites em imagens SAR.

Palavras-chaves: SAR. MSGARCH. Detecção de borda. Sensoriamento Remoto. Série temporal.

ABSTRACT

Solving remote sensing problems is crucial for the progress of any society. Synthetic aperture radar (SAR) is considered a promising tool for solving remote sensing problems because it can be used in different weather conditions and provides images with high spatial resolution. In contrast, SAR images are subject to strong interferences, the so-called speckle effect, which requires the use of adapted processing methods, such as refined boundary detection techniques. In this work, we present an innovative method for detecting boundaries in SAR images using time series analysis in an approach based on Markov Switching GARCH models. We aim for a twofold advance: We exploit the change in volatility behind the SAR intensity data to improve the accuracy in detecting boundaries, and we propose a method with lower computational cost than in the SAR literature. We perform simulated experiments to verify the accuracy of our method using time series results from the GARCH(1,1) process with a Markov transition between two different states. In addition, an application to real SAR images from the region near the coast of Japaratinga, AL, is performed. The results of both simulated and real experiments show that our proposals can be very useful for SAR boundary detection.

Keywords: SAR. MSGARCH. Edge detection. Remote Sensing. Time Series.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL com apenas um raio tracejado e a série temporal formada pelo raio. | 24 |
| Figura 2 – Imagem simulada do Experimento 1 com região de borda destacada em azul. | 26 |
| Figura 3 – Imagem da aplicação do método considerando o modelo GARCH no Experimento 1 com região de borda predita destacada em vermelho. | 26 |
| Figura 4 – Imagem da aplicação do método considerando o modelo ARCH no Experimento 1 com região de borda predita destacada em verde. | 26 |
| Figura 5 – Imagem simulada do Experimento 2 com região de borda destacada em azul. | 27 |
| Figura 6 – Imagem da aplicação do método considerando o modelo GARCH no Experimento 2 com região de borda predita destacada em vermelho. | 28 |
| Figura 7 – Imagem da aplicação do método considerando o modelo ARCH no Experimento 2 com região de borda predita destacada em verde. | 28 |
| Figura 8 – Gráfico de barra com os valores médios da distância média para tamanho da simulação e segregado por modelo. | 29 |
| Figura 9 – Gráfico de barra com os valores médios da distância mediana para cada tamanho da simulação e segregado por modelo. | 29 |
| Figura 10 – Gráfico de barra com os valores médios da taxa de falso negativo para tamanho da simulação e segregado por modelo. | 30 |
| Figura 11 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL. . . | 31 |
| Figura 12 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL com raios tracejados considerando a primeira abordagem. | 32 |
| Figura 13 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em azul predita pelo modelo ARCH e considerando a primeira abordagem. | 32 |
| Figura 14 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em vermelho predita pelo modelo GARCH e considerando a primeira abordagem. | 33 |
| Figura 15 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em laranja predita pelo modelo EGARCH e considerando a primeira abordagem. | 33 |

| | |
|---|----|
| Figura 16 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em amarelo predita pelo modelo GJR e considerando a primeira abordagem. | 34 |
| Figura 17 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com raios tracejados considerando a segunda abordagem. | 34 |
| Figura 18 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em azul predita pelo modelo ARCH e considerando a segunda abordagem. | 35 |
| Figura 19 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em vermelho predita pelo modelo GARCH e considerando a segunda abordagem. | 35 |
| Figura 20 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em laranja predita pelo modelo EGARCH e considerando a segunda abordagem. | 36 |
| Figura 21 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em amarelo predita pelo modelo GJR e considerando a segunda abordagem. | 36 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 – Métricas de avaliação de detecção de pontos de mudança do Experimento | |
| Simulado 1 | 27 |
| Tabela 2 – Métricas de avaliação de detecção de pontos de mudança do Experimento | |
| Simulado 2 | 28 |

SUMÁRIO

| | | |
|--------------|--|-----------|
| 1 | INTRODUÇÃO | 11 |
| 1.1 | SENSORIAMENTO REMOTO | 11 |
| 1.2 | REVISÃO DA LITERATURA | 12 |
| 1.3 | PROPOSTA DO TCC | 13 |
| 1.4 | DIVISÃO DO TCC | 14 |
| 2 | MATERIAIS E MÉTODOS | 15 |
| 2.1 | VISÃO GERAL DE UMA IMAGEM DE RADAR | 15 |
| 2.2 | <i>MSGARCH</i> | 16 |
| 2.3 | APRENDIZAGEM DE MÁQUINA | 19 |
| 2.3.1 | Métodos não supervisionados | 19 |
| 2.3.2 | X-splines | 20 |
| 2.4 | INTERPOLAÇÃO POR VIZINHO MAIS PRÓXIMO | 21 |
| 3 | CONTRIBUIÇÃO E RESULTADOS NUMÉRICOS | 23 |
| 3.1 | IDENTIFICANDO A CONTRIBUIÇÃO | 23 |
| 3.2 | SIMULAÇÃO | 24 |
| 3.3 | APLICAÇÃO | 30 |
| 4 | CONCLUSÕES E TRABALHOS FUTUROS | 37 |
| | REFERÊNCIAS | 38 |

1 INTRODUÇÃO

1.1 SENSORIAMENTO REMOTO

O sensoriamento remoto representa a ciência e a arte de coletar informações sobre a superfície terrestre por meio de sistemas de sensores, abrangendo as regiões ultravioleta, visível, infravermelha e de micro-ondas do espectro eletromagnético, tudo isso sem a necessidade de contato físico direto (Mantovani; Soeters; Van Westen, 1996). Sensores instalados em satélites, aeronaves ou veículos aéreos não tripulados - VANTs são responsáveis por registrar a radiação eletromagnética refletida ou emitida - REM por características presentes na superfície terrestre. Essa radiação, proveniente de características na superfície, é registrada como um pixel e posteriormente convertida em um valor digital, resultando na obtenção remota de imagens (Kamusoko, 2019).

A importância do sensoriamento remoto reside em sua habilidade de fornecer dados abrangentes em larga escala, permitindo uma compreensão mais aprofundada dos processos naturais e das atividades humanas. Ao possibilitar o monitoramento de áreas extensas e de difícil acesso, essa técnica viabiliza estudos em escalas global, regional e local, abrangendo diversos campos como agricultura (Weiss; Jacob; Duveiller, 2020), cartografia (Meissner, 1994), gestão de recursos naturais (Pei et al., 2021), previsão meteorológica (Leese, 1987), planejamento urbano (Wellmann et al., 2020) e monitoramento ambiental (Li et al., 2020). Sendo assim, o sensoriamento remoto surge como uma ferramenta crucial para a obtenção de informações críticas que impulsionam pesquisas, facilitam a gestão sustentável dos recursos e orientam políticas públicas direcionadas a um futuro mais resiliente e consciente.

Há diversos sistemas de sensoriamento remoto, sendo os mais reconhecidos para aquisição de imagens da Terra os sistemas multi espectrais e ativo por micro-ondas. No contexto dos sistemas multi espectrais, eles registram a energia refletida ou emitida por um alvo em múltiplas bandas discretas do espectro eletromagnético. Esses sistemas dependem de fontes externas de radiação eletromagnética, como a luz solar, para iluminar a superfície terrestre. Ao medir a quantidade de energia refletida ou emitida em faixas específicas de comprimento de onda, eles fornecem informações detalhadas sobre a composição, saúde da vegetação e outras propriedades do alvo (Jensen, 2013). Entretanto, a cobertura de nuvens, as condições atmosféricas e a ausência de luz solar podem limitar severamente a aquisição de dados úteis. Um exemplo notável de aplicação do sensoriamento remoto multi espectral é o programa

LANDSAT, gerenciado pela NASA e *U.S. Geological Survey*.

O sistema de sensoriamento remoto ativo por micro-ondas também chamado de *RA*dio *DE*tectio*N* *AN*d *R*ang*ing* - RADAR, baseia-se na transmissão de micro-ondas de comprimento de onda longo através da atmosfera e, em seguida, registra a quantidade de energia retroespalhada pela superfície do terreno. Uma modalidade de RADAR amplamente conhecida e empregada nos dias de hoje é o Radar de Abertura Sintética - SAR.

O SAR utiliza o movimento relativo entre o sensor e o alvo para sintetizar uma abertura maior, resultando em uma resolução espacial significativamente mais detalhada na imagem final. Contudo, as imagens SAR são afetadas por um ruído conhecido como *speckle*, que surge devido à natureza coerente da onda de radar, provocando interferências construtivas e destrutivas aleatórias. Isso resulta em áreas brilhantes e escuras de forma imprevisível em uma imagem proveniente do uso do SAR (Jensen, 2013). Além do ruído *speckle*, outra desvantagem do SAR é sua complexidade analítica. Isso decorre da natureza intrincada dos sinais de radar, exigindo métodos de processamento avançados para interpretar os dados de forma precisa.

1.2 REVISÃO DA LITERATURA

A detecção de bordas é uma das tarefas mais importantes no campo de visão computacional e processamento de imagens. O termo "borda" pode ser conceituado como uma fronteira, seja um ponto específico, seja uma faixa, que separa duas regiões caracterizadas por propriedades estatísticas distintas. As bordas fornecem informações cruciais para muitas tarefas visuais, tais como reconhecimento, segmentação e recuperação de imagens, reconhecimento facial, detecção de cantos e estradas, problemas em imagens médicas e rastreamento de alvos. Cada uma dessas tarefas visuais requer a extração de limites de objetos ou a percepção de bordas evidentes a partir da imagem original (Jing et al., 2022).

Ao desempenhar um papel crucial em diversas aplicações que envolvem processamento de imagem, a detecção de bordas tem sido objeto de inúmeros estudos ao longo dos anos. Cada pesquisa dedicada a aprimorar as técnicas nesse domínio contribui de maneira única para o avanço significativo desse campo.

Dentre as diversas contribuições, pode-se destacar (Abdel-Gawad; Said; Radwan, 2020), cuja abordagem centraliza-se no emprego de algoritmos genéticos como método eficaz de detecção de borda. Essa metodologia apresentou resultados promissores, especialmente quando aplicada a imagens de ressonância magnética para a identificação de tumores cerebrais. Tais avanços

forneem uma perspectiva valiosa para a área de processamento de imagens médicas.

Fu, You e Fu (2012) apresentaram uma abordagem inovadora ao empregar a técnica *square successive difference of averages* (SSDOA) no desenvolvimento de um método de detecção de borda. Este estudo se sobressai pela sua notável aplicabilidade em imagens SAR, oferecendo *insights* valiosos para o processamento de imagens provenientes de sistemas de RADAR.

Além disso, outro trabalho relevante no âmbito da detecção de borda em imagens de RADAR (Jing; Jin; Xiang, 2021), concentra-se na utilização do *effective recurrent guidance filter* como método de detecção de borda, um filtro proposto pelos autores com o objetivo específico de suprimir informações não relacionadas às bordas, como ruído de granulação e texturas detalhadas, ao mesmo tempo em que preserva de forma eficaz as informações essenciais das bordas.

Os artigos citados são representativos da riqueza e diversidade de abordagens existentes na detecção de borda. A análise crítica desses estudos serve como alicerce para uma compreensão mais aprofundada do estado atual da pesquisa.

1.3 PROPOSTA DO TCC

Embora métodos propostos na literatura, como o de (Nascimento; Silva; Frery, 2021), que utilizam raios sobre a imagem, tenham demonstrado eficácia, eles frequentemente não consideram adequadamente a dependência entre pixels vizinhos, ou seja, a autocorrelação presente no raio. Nesse contexto, um método de detecção de borda que leve em consideração essa característica surge como um objeto de estudo promissor e relevante.

O objetivo do estudo é apresentar um método inovador de detecção de borda aplicado a imagens de sensoriamento remoto, utilizando séries temporais, mais especificamente o *Markov Switching GARCH* - MSGARCH. A escolha do MSGARCH é fundamentada em sua capacidade singular de modelar a variância condicional, uma característica crucial ao analisar informações provenientes de radares. Modelos do tipo GARCH tem sido aplicado com sucesso em imagens de radar, conforme demonstrado em estudos anteriores (Amirmazlaghani; Amindavar; Moghaddamjoo, 2009; Pascual et al., 2014). Adicionalmente, a utilização de um processo de Markov discreto latente amplifica a eficácia da abordagem para detecção de pontos de borda.

1.4 DIVISÃO DO TCC

No Capítulo 2, intitulado "Materiais e Métodos", serão discutidos os fundamentos teóricos e as técnicas utilizadas no desenvolvimento do método proposto, assim como sua aplicação em imagens de radar. Este capítulo detalha os procedimentos metodológicos adotados, fornecendo uma base para a compreensão do estudo.

No Capítulo 3 é explorada a contribuição do método proposto para o campo de detecção de bordas em imagens de sensoriamento remoto. Inclui-se uma simulação destinada a avaliar a eficácia do modelo MSGARCH na identificação de pontos de mudança, bem como uma aplicação em uma imagem SAR. Este capítulo tem como objetivo demonstrar a aplicabilidade e o impacto do método no contexto de análise de imagens de radar.

Por fim, no Capítulo 4 são apresentadas as conclusões do estudo, ressaltando os principais resultados e a importância do método desenvolvido. Discutem-se, também, possíveis direções para pesquisas futuras baseadas nos resultados alcançados, indicando caminhos para avanços na área de sensoriamento remoto e análise de imagens de radar.

2 MATERIAIS E MÉTODOS

2.1 VISÃO GERAL DE UMA IMAGEM DE RADAR

Imagens podem ser categorizadas de duas maneiras principais: pancromáticas e multiespectrais. Uma imagem pancromática é descrita por uma função bidimensional de intensidade de luz, simbolizada por $f(x, y)$, onde x e y são as coordenadas espaciais. O valor de f em qualquer ponto (x, y) reflete a luminosidade observada naquela localização. Por outro lado, numa imagem multiespectral, $f(x, y)$ se torna um vetor, com cada elemento correspondendo à intensidade luminosa em uma banda espectral distinta no ponto (x, y) (Petrou; Petrou, 2010).

Este trabalho visa contribuir para o processamento de um tipo específico de imagem de radar, o SAR (*synthetic aperture radar*). O SAR destaca-se entre as várias ferramentas de sensoriamento remoto pela sua eficiência na solução de problemas desta natureza. Isso posto, deve-se a mínimo dois fatos: sua capacidade de trabalhar em vários estados atmosféricos (ambiente de muita umidade, ausência de luminosidade, cenários nublados e com cobertura vegetal) e sua habilidade de produzir imagens em alta resolução espacial, o que gera uma grande nível de detalhes. O SAR é capaz de capturar imagens em uma vasta seleção de bandas de frequência, incluindo as bandas X, C, L, Ku, Ka e entre outras, o que lhe permite estudar a física de diferentes tipos de relevo. Embora as imagens SAR sejam tipicamente monoespectrais, (ou seja, capturadas em uma única banda de radar) é possível obter imagens multiespectrais ao combinar várias capturas de radar em diferentes bandas de frequência e/ou polarizações. Esse processo enriquece a representação do objeto ou área observada, oferecendo detalhes mais complexos e variados.

As imagens obtidas via sensoriamento remoto estão sujeitas a distorções devido a fatores como características do sensor, incidência solar, influências atmosféricas e topografia. Assim, é essencial realizar etapas de pré-processamento para corrigir tais distorções (Campbell; Wynne, 2011). A correção radiométrica é uma técnica fundamental para ajustar os dados coletados, visando eliminar interferências atmosféricas e erros inerentes ao sensor. Isso melhora a precisão das medições de reflectância da superfície, emissividade e retroespalhamento, resultando em uma coleta de dados mais exata (Kamusoko, 2019).

Apesar das grandes vantagens em utilizar o sistema SAR, ele demanda um desafio aos seus usuários: lidar com um tipo particular de interferência conhecida como *ruído speckle*. O *speckle* afeta a natureza tanto dos retornos de imagens (que são números complexos)

como de seus atributos (como sua norma quadrada associada, conhecida como intensidade, foco da modelagem proposta nesse estudo) (Fabregas; Pottier, 2005). Os dados "speckled" são afetados tal que a natureza de suas intensidades é multiplicativa e não Gaussiana (Freitas; Frery; Correia, 2005). Essa quebra de suposições comumente usadas requer a elaboração cuidadosa tanto de técnicas de pré-processamento (o entendimento estatístico dos dados) como de pós-processamento (como detecção de bordas).

Um modo inicial descritivo de lidar com o *speckle* é através do que se entende como *processamento multilook*. Esta técnica envolve a coleta de várias imagens da mesma área sob iluminação semelhante e a combinação dessas imagens, visando reduzir o ruído *speckle* enquanto mantém a qualidade da amplitude da imagem. Este método é comparável à técnica de HDR (*High Dynamic Range*) na fotografia, que combina múltiplas exposições para melhorar a qualidade da imagem final (Frery; Wu; Deniz, 2022).

Quando os pulsos eletromagnéticos do SAR interagem com a região de interesse, cada espalhamento resulta em uma onda retroespalhada na qual as informações de fase (ângulo associado ao retorno complexo) e amplitude (raiz quadrada da intensidade, ou na norma) mudam. Assim, o retroespalhamento da onda incidente na entrada (i, j) é

$$R(i, j) = A(i, j) \exp\{\sqrt{-1}\psi(i, j)\} \in \mathbb{C},$$

em que $A(i, j) > 0$ é a amplitude de onda e $\psi(i, j) \in (0, 2\pi]$ é a fase de onda. A intensidade - foco do nosso estudo - é então dada por $I(i, j) = A(i, j)^2 = \Im[R(i, j)]^2 + \Re[R(i, j)]^2$, em que $\Im[\cdot]$ e $\Re[\cdot]$ representam as partes imaginária e real, respectivamente. A intensidade multilook é dada por: Dado que se obteve $L \in \mathbb{N}$ imagens de uma mesma cena, então a intensidade multilook na entrada (i, j) é dada por:

$$I_L(i, j) = \frac{1}{L} \sum_{k=1}^L I^{(k)}(i, j).$$

No que segue, será procurado modelar $I_L(i, j)$.

2.2 MSGARCH

O estudo adotará a abordagem MSGARCH proposta por Haas, Mittnik e Paoletta (2004) e implementada em R (R Core Team, 2024) por Ardia et al. (2019). Modelos GARCH convencionais podem ter limitações na previsão da volatilidade, especialmente em situações de mudanças de regime na dinâmica volátil. Nesse contexto, a abordagem alternativa MSGARCH

permite a variação dos parâmetros de um modelo do tipo GARCH ao longo do tempo, guiada por um processo Markov discreto latente. Essa estratégia, conhecida como Markov-switching GARCH - MSGARCH, oferece previsões de volatilidade ágeis, adaptando-se rapidamente às flutuações no nível de volatilidade não condicional.

Considera-se, nessa abordagem, a variável de interesse como a intensidade SAR multilook no instante t (como uma função das entradas (i, j) , como abordado por McCormick e Jayaramamurthy (1974), Chin, Jau e Weinman (1987), Dutra e Mascarenhas (1984), Rangayyan (2004), Almeida'Junior e Nascimento (2021) e Silva, Almeida-Junior e Nascimento (2023)) como I_t e sua realização i_t , supomos que I_t possui uma média zero e não apresenta correlação serial, ou seja, as seguintes condições de momentos são estabelecidas: $E[I_t] = 0$ e $E[I_t I_{t-l}] = 0$ para $l \neq 0$, válidas para todos os $t > 0$.

Nesse sentido, introduz-se a possibilidade de alternância de regime no processo de variância condicional. Denotando por \mathcal{F}_{t-1} o conjunto de informações observado até o tempo $t - 1$, ou seja, $\mathcal{F}_{t-1} \equiv \{i_{t-j}, j > 0\}$. A formulação geral do GARCH com alternância de regime pode ser expressa da seguinte forma:

$$[I_t | (S_t = k), \mathcal{F}_{t-1}] \sim D(0, h_{k,t}, \boldsymbol{\xi}_k),$$

em que " $D(0, h_{k,t}, \boldsymbol{\xi}_k)$ " representa uma distribuição contínua com média zero, variância que varia ao longo do tempo $h_{k,t}$, e parâmetros adicionais reunidos no vetor $\boldsymbol{\xi}_k$. Uma vez que essa é a primeira abordagem na qual usaremos uma estrutura GARCH com alternância de regime para detectar bordas, assumiremos a distribuição normal com um primeiro suposto de referência a trabalhos futuros. Como é conhecido, embora o suporte da normal não seja o mais adequado ao problema, a sua tratabilidade analítica e a sua importância como lei à qual converge grande parte dos resultados limites (vide Teorema Central do Limite) justifica sua escolha nesse primeiro estudo. A variável estocástica S_t , de valor inteiro, é definida no espaço discreto $\{1, \dots, K\}$ caracterizando o modelo GARCH com alternância de regime. As inovações padronizadas são definidas como $\eta_{k,t} \equiv I_t/h_{k,t}^{1/2}$ iid $\sim D(0, 1, \boldsymbol{\xi}_k)$.

Adicionalmente, assume-se que S_t evolui de acordo com uma cadeia de Markov homogênea ergódica de primeira ordem não observada, com uma matriz de transição $K \times K$ denotada por P :

$$\mathbf{P} \equiv \begin{bmatrix} p_{1,1} & \cdots & p_{1,K} \\ \vdots & \ddots & \vdots \\ p_{K,1} & \cdots & p_{K,K} \end{bmatrix},$$

em que $p_{i,j} \equiv \Pr[S_t = j | S_{t-1} = i]$ representa a probabilidade de transição do estado i para o estado j . Naturalmente, as seguintes restrições são impostas: $0 < p_{i,j} < 1$ para todo $i, j \in \{1, \dots, K\}$, e $\sum_{j=1}^K p_{i,j} = 1$ para todo $i \in \{1, \dots, K\}$. Considerando a parametrização de $D(\cdot)$, temos $E[I_t^2 | S_t = k, \mathcal{F}_{t-1}] = h_{k,t}$, ou seja, $h_{k,t}$ é a variância condicional de I_t dado $S_t = k$. Será assumido que as variâncias condicionais $h_{k,t}$ para $k = 1, \dots, K$ seguem K processos GARCH distintos que evoluem simultaneamente.

É assumido que a variância condicional de I_t segue um modelo do tipo GARCH. Assim, condicional ao regime $S_t = k$, $h_{k,t}$ está disponível como uma função da observação passada i_{t-1} , da variância passada $h_{k,t-1}$, e do vetor adicional de parâmetros dependente do regime $\boldsymbol{\theta}_k$:

$$h_{k,t} \equiv h(I_{t-1}, h_{k,t-1}, \boldsymbol{\theta}_k),$$

em que $h(\cdot)$ é uma função mensurável por \mathcal{F}_{t-1} que define o filtro para a variância condicional e também assegura sua positividade. Os modelos tipo GARCH abordados neste estudo incluem o ARCH, GARCH, E-GARCH e GJR.

O modelo ARCH (Engle, 1982) com mudança de regime é definido da seguinte maneira:

$$h_{k,t} \equiv \alpha_{0,k} + \alpha_{1,k} i_{t-1}^2,$$

para $k = 1, \dots, K$, em que $\boldsymbol{\theta}_k = (\alpha_{0,k}, \alpha_{1,k})^\top$. Para assegurar a positividade, exigimos que $\alpha_{0,k} > 0$ e $\alpha_{1,k} \geq 0$. A estacionariedade na covariância em cada regime é garantida pela condição $\alpha_{1,k} < 1$.

O modelo GARCH (Bollerslev, 1986) com mudança de regime é expresso como:

$$h_{k,t} \equiv \alpha_{0,k} + \alpha_{1,k} i_{t-1}^2 + \beta_k h_{k,t-1},$$

para $k = 1, \dots, K$, em que $\boldsymbol{\theta}_k = (\alpha_{0,k}, \alpha_{1,k}, \beta_k)^\top$. Para assegurar a positividade, impomos $\alpha_{0,k} > 0$, $\alpha_{1,k} > 0$ e $\beta_k \geq 0$. A estacionariedade na covariância em cada regime é alcançada através da condição $\alpha_{1,k} + \beta_k < 1$.

O modelo Exponential GARCH (EGARCH) (Nelson, 1991) com mudança de regime é formulado como:

$$\ln(h_{k,t}) \equiv \alpha_{0,k} + \alpha_{1,k} (|\eta_{k,t-1}| - E[|\eta_{k,t-1}|]) + \alpha_{2,k} \eta_{k,t-1} + \beta_k \ln(h_{k,t-1}),$$

para $k = 1, \dots, K$, em que $E[|\eta_{k,t-1}|]$ é calculado em relação à distribuição condicional no regime k . Aqui, $\boldsymbol{\theta}_k = (\alpha_{0,k}, \alpha_{1,k}, \alpha_{2,k}, \beta_k)^\top$.

O modelo GJR (Glosten; Jagannathan; Runkle, 1993), que captura assimetria na volatilidade condicional, com mudança de regime é definido como:

$$h_{k,t} \equiv \alpha_{0,k} + (\alpha_{1,k} + \alpha_{2,k} \mathbb{I}\{i_{t-1} < 0\}) i_{t-1}^2 + \beta_k h_{k,t-1},$$

para $k = 1, \dots, K$, em que $\mathbb{I}\{\cdot\}$ é a função indicadora que assume o valor 1 se a condição é verdadeira e 0 caso contrário. Neste caso, $\boldsymbol{\theta}_k = (\alpha_{0,k}, \alpha_{1,k}, \alpha_{2,k}, \beta_k)^\top$. O parâmetro $\alpha_{2,k}$ regula a assimetria na resposta da volatilidade condicional ao choque passado no regime.

A estimação dos modelos MSGARCH no estudo será realizada pela técnica *Bayesian Markov chain Monte Carlo* (Ardia, 2009) que leva em consideração a função de máxima verossimilhança.

Seja $\boldsymbol{\Psi} \equiv (\boldsymbol{\theta}_1, \boldsymbol{\xi}_1, \dots, \boldsymbol{\theta}_K, \boldsymbol{\xi}_K, \boldsymbol{P})^\top$ o vetor de parâmetros do modelo. A função de verossimilhança é dada por:

$$L(\boldsymbol{\Psi} | I_T) \equiv \prod_{t=1}^T f(i_t | \boldsymbol{\Psi}, \mathcal{F}_{t-1}), \quad (2.1)$$

onde $f(i_t | \boldsymbol{\Psi}, \mathcal{F}_{t-1})$ denota a densidade de i_t dado as observações passadas, \mathcal{F}_{t-1} , e os parâmetros do modelo $\boldsymbol{\Psi}$.

A densidade condicional de i_t é dada por:

$$f(i_t | \boldsymbol{\Psi}, \mathcal{F}_{t-1}) \equiv \sum_{n=1}^K \sum_{j=1}^K p_{i,j} z_{n,t-1} f_D(i_t | S_t = j, \boldsymbol{\Psi}, \mathcal{F}_{t-1}), \quad (2.2)$$

em que $z_{n,t-1} \equiv \Pr[S_{t-1} = n | \boldsymbol{\Psi}, \mathcal{F}_{t-1}]$ representa a probabilidade filtrada do estado n no tempo $t - 1$, obtida através do filtro de Hamilton (Hamilton, 1989).

2.3 APRENDIZAGEM DE MÁQUINA

2.3.1 Métodos não supervisionados

Para estabelecer um ponto de referência para a implementação do método, optaremos por empregar o algoritmo de clusterização *K-means* (MacQueen, 1967). O *K-means* é amplamente reconhecido como o método de agrupamento mais empregado devido à sua simplicidade e natureza intuitiva, tornando-o acessível para compreensão e implementação. Este algoritmo opera ao designar pontos de dados ao grupo mais próximo com base na distância, que, neste estudo, será a distância euclidiana.

Conforme (Kassambara, 2017), sendo k o número de grupos, a variação total dentro de um grupo como a soma das distâncias quadradas das distâncias entre os itens e o correspondente centroide pode ser definida da forma:

$$W(C_k) = \sum_{x_i \in C_k} (x_i - \mu_k)^2, \quad (2.3)$$

em que:

- x_i : É uma observação pertencente ao grupo C_k .
- μ_k : É o valor médio dos pontos atribuídos ao grupo C_k .

Cada observação x_i é atribuída a um grupo específico de forma que a soma dos quadrados das distâncias entre a observação e os centros do grupos atribuído μ_k seja minimizada.

2.3.2 X-splines

Na sua definição mais geral, *splines* podem ser consideradas como um modelo matemático que associa uma representação contínua com um conjunto discreto de pontos de um espaço afim (usualmente \mathbb{R}^2 ou \mathbb{R}^3). No caso de curvas, esta definição pode ser expressa da seguinte forma: seja $P_k \in \mathbb{R}^3$ com $k = 0, \dots, n$ um conjunto de pontos chamados pontos de controle, e seja $F_k : [0, 1] \rightarrow \mathbb{R}$ (com $k = 0, \dots, n$) um conjunto de funções chamadas funções de mistura, a curva *spline* gerada pelos pares (P_k, F_k) é a curva C definida pela equação paramétrica:

$$\forall t \in [0, 1], \quad C(t) = \sum_{k=0}^n P_k F_k(t). \quad (2.4)$$

Para a junção eficiente dos pontos de borda identificados pelo método proposto, será utilizado a ferramenta *X-Splines*. *X-Splines* representam uma inovação na modelagem de *splines*, aprimorando o modelo de *B-Spline* tradicional (Gordon; Riesenfeld, 1974), para torná-lo mais intuitivo e acessível, especialmente para usuários que possuem um conhecimento matemático mais limitado. Desenvolvidas conforme descrito por (Blanc; Schlick, 1995), as *X-Splines* foram cuidadosamente projetadas para proporcionar um controle mais refinado e maior flexibilidade na manipulação de *splines*, superando desafios frequentes em áreas como computação gráfica e *Computer-Aided Design* (CAD).

Na formulação das *X-Splines*, está um conjunto de funções de mistura, que são mais adaptáveis e intuitivas em comparação com as funções básicas padrão de *B-Spline*. Essas funções

ditam como os pontos de controle influenciam a forma da *spline*, permitindo manipulações mais precisas e amigáveis ao usuário.

Pontos de controle são fundamentais para as *X-Splines*, determinando a forma geral da curva. O aspecto único das *X-Splines* é a inclusão de parâmetros de forma, como tensão e viés. Esses parâmetros dão aos usuários controle direto sobre a curvatura e a nitidez da *spline* em cada ponto de controle, um aprimoramento que geralmente não é encontrado em *B-Splines* tradicionais.

O controle de continuidade é outra característica significativa das *X-Splines*. Os usuários podem ajustar explicitamente a continuidade nos pontos de controle, possibilitando a criação de *splines* com curvas suaves e cantos afiados. Esse nível de controle é alcançado modificando as propriedades das funções de mistura em cada ponto, oferecendo uma flexibilidade particularmente útil para designs complexos.

Como as *B-Splines*, as *X-Splines* utilizam um vetor de nós, que define o espaço de parâmetros e a aplicação das funções de mistura ao longo da *spline*. No entanto, as funções de mistura e os parâmetros de forma das *X-Splines* introduzem um nível de controle e personalização que vai além do modelo padrão de *B-Spline*. Para mais detalhes sobre *X-splines* e *B-splines*, ver (Blanc; Schlick, 1995) e (Gordon; Riesenfeld, 1974), respectivamente.

2.4 INTERPOLAÇÃO POR VIZINHO MAIS PRÓXIMO

Os interpoladores, conforme o próprio termo sugere, desempenham o papel de calcular valores para pontos adicionados a um conjunto preexistente de dados. O processo de interpolação resulta na criação de uma faixa contínua, que pode ser tanto regular quanto irregular, contendo valores estimados para as novas posições introduzidas nessa faixa.

A interpolação por vizinho mais próximo é o tipo mais simples de interpolação, exigindo pouquíssimos cálculos, o que permite que seja um algoritmo rápido. Além disso, é bastante intuitivo, o pixel que interpolamos terá um valor igual ao valor do pixel conhecido mais próximo (Franke, 1982). Este método será utilizado para extrair dados das áreas delimitadas pelos raios tracejados na imagem. Considerando que se trata de um problema de detecção de bordas, é imperativo adotar um método de interpolação que empregue um pixel existente na imagem. Nesse contexto, a interpolação por vizinho mais próximo é particularmente adequada, pois realiza exatamente essa tarefa.

Seja (x_0, y_0) o ponto de origem e (x_{n-1}, y_{n-1}) o ponto de destino de um raio. O compri-

mento do raio, denotado por n , é calculado como o maior inteiro menor ou igual à distância euclidiana entre o ponto de origem e o ponto de destino, ajustado pela função piso, conforme expresso por:

$$n = \left\lfloor \sqrt{(x_{n-1} - x_0)^2 + (y_{n-1} - y_0)^2} \right\rfloor.$$

Para gerar as coordenadas intermediárias do raio, calcula-se as posições x e y para cada ponto k ao longo do raio, onde k varia de 0 até $n - 1$. As fórmulas para essas coordenadas são ajustadas para garantir que o espaçamento entre cada ponto seja uniforme, e são definidas como:

$$x_k = \left\lfloor x_0 + k \cdot \left(\frac{x_{n-1} - x_0}{n - 1} \right) \right\rfloor, \quad k = 0, \dots, n - 1,$$

$$y_k = \left\lfloor y_0 + k \cdot \left(\frac{y_{n-1} - y_0}{n - 1} \right) \right\rfloor, \quad k = 0, \dots, n - 1.$$

Essas fórmulas garantem que as coordenadas de cada ponto ao longo do raio sejam calculadas de forma que o raio seja representado por pontos igualmente espaçados, iniciando no ponto de origem (x_0, y_0) e terminando no ponto de destino (x_{n-1}, y_{n-1}) .

Finalmente, os pontos do raio são organizados em um vetor de coordenadas \mathbf{Z} , representando a trajetória do raio da seguinte forma:

$$\mathbf{Z} = [(x_0, y_0), (x_1, y_1), (x_2, y_2), \dots, (x_{n-1}, y_{n-1})]^T.$$

Utilizando o vetor de coordenadas \mathbf{Z} , é viável prosseguir com o ajuste de modelos do tipo MSGARCH, uma vez que os pixels correspondentes aos raios foram meticulosamente mapeados.

3 CONTRIBUIÇÃO E RESULTADOS NUMÉRICOS

3.1 IDENTIFICANDO A CONTRIBUIÇÃO

A contribuição fundamental do método apresentado neste TCC para o campo da detecção de bordas reside na proposta de um detector de bordas que leve em consideração modelos de séries temporais, quando a abordagem de detecção de bordas com base na modelagem do raio é usada em Nascimento, Silva e Frery (2021) ela assume independência embora haja estrutura tanto na média condicional (Almeida-Junior; Nascimento, 2021; Silva; Almeida-Junior; Nascimento, 2023) quanto na variância condicional (Pascual et al., 2014; Zhang et al., 2016; Zhang et al., 2017; Zhang et al., 2018). Nossa proposta oferece uma nova perspectiva na análise de imagens, ampliando o escopo de ferramentas disponíveis para pesquisadores e profissionais da área, integrando conceitos de séries temporais com técnicas tradicionais de detecção de bordas. Este enfoque enriquece a metodologia existente, torna mais econômica a execução da detecção por ser um método de mais baixo custo e abre caminho para futuras investigações e aplicações práticas no domínio do processamento de imagens.

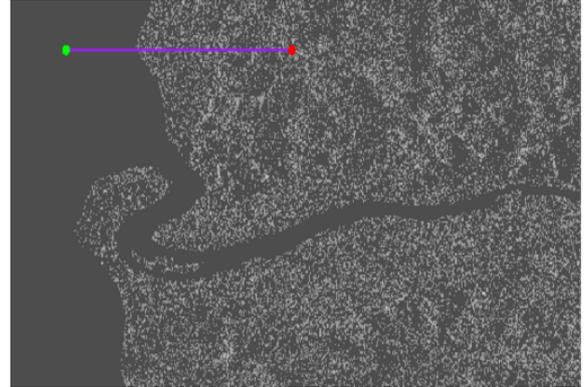
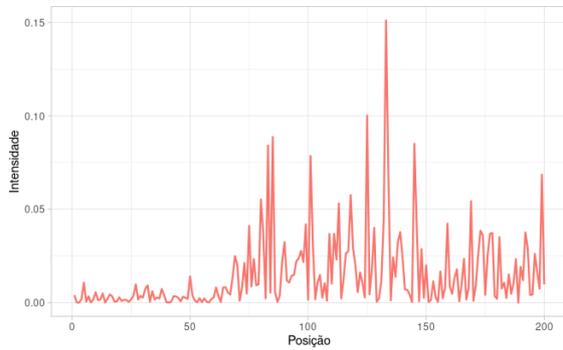
Começando com um ponto de referência C , traçam-se raios em direção a pontos de controle P_i , onde i varia de 1 a S . Esses S raios podem ser expressos como vetores $\mathbf{s}^{(i)} = \overline{CP_i}$, com o ângulo entre raios consecutivos representado por $\epsilon_i = \angle(\mathbf{s}^{(i)}, \mathbf{s}^{(i+1)})$. Esses raios são então mapeados em pixels adjacentes utilizando o método de interpolação do vizinho mais próximo.

Cada raio $\mathbf{s}^{(i)}$, para i de 1 a S , gera uma faixa de dados contendo $N^{(i)}$ pixels. Considera-se que a faixa de dados para cada raio $\mathbf{s}^{(i)}$ forma uma série temporal denotada por $Y^{(i)} = (y_1^{(i)}, y_2^{(i)}, \dots, y_t^{(i)})$, onde t indica a sequência dos pixels ao longo da faixa de dados.

Para identificar pontos de borda na série temporal $Y^{(i)}$, ajusta-se um modelo MSGARCH de dois estados. A estimação do modelo se dá através do uso do método *Bayesian Markov Chain Monte Carlo* (Ardia, 2009). Seguido ao ajuste, emprega-se o algoritmo de Viterbi (Viterbi, 1967) para decodificar os estados da série ajustada. Assim, a série original, que era composta por valores numéricos, é transformada em uma sequência de estados. O ponto de borda é determinado como o local da primeira transição de estado na série decodificada.

Na Figura 1, um raio específico é realçado na imagem SAR escolhida para a aplicação prática do método proposto. Esse raio é interpretável como uma série temporal, com início no ponto verde e término no ponto vermelho. Uma transição notável é observada nesta série, caracterizada pela mudança da região homogênea para a heterogênea, evidenciando uma

Figura 1 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL com apenas um raio tracejado e a série temporal formada pelo raio.



significativa alteração de regime.

3.2 SIMULAÇÃO

Para avaliar a eficiência do método na identificação de pontos de mudança, será conduzida uma simulação baseada em um processo *Markov-Switching* GARCH, seguida pela aplicação do método nas simulações geradas. A simulação envolverá um processo GARCH(1,1) com uma transição de Markov entre dois estados distintos, detalhados conforme segue:

No estado $s_t = 1$, a dinâmica é definida por:

$$h_{1,t} = 0,1 + 0,1i_{t-1}^2 + 0,8h_{k,t-1}. \quad (3.1)$$

No estado $s_t = 2$, a configuração muda para:

$$h_{2,t} = 1,5 + 0,1i_{t-1}^2 + 0,8h_{k,t-1}. \quad (3.2)$$

Esse não é um cenário tão trivial de identificar o ponto de mudança, o que sugere diante de uma boa performance que o método é razoável para ser aplicado na prática. A transição entre esses estados é regida por uma cadeia de Markov de dois estados, cuja matriz de transição \mathbf{P} é estruturada da seguinte maneira para a simulação:

$$\mathbf{P} = \begin{bmatrix} 0,95 & 0,05 \\ 0,03 & 0,97 \end{bmatrix}.$$

Esta formulação permite a análise detalhada do comportamento do método proposto sob condições variáveis, facilitando a compreensão de sua capacidade de detecção de mudanças significativas no comportamento do processo simulado.

A metodologia da simulação será implementada da seguinte forma:

1. Numa imagem de tamanho 252×252 , com um ponto de referência central, serão criados 72 raios que se estendem por toda a imagem.
2. Cada raio será composto por uma simulação do processo descrito anteriormente, com um intervalo angular de 5 graus entre raios consecutivos.
3. Posteriormente, cada raio simulado será analisado, identificando-se o ponto de mudança real como o local onde ocorre a primeira transição de estado entre os modelos.

Este procedimento visa simular de maneira detalhada o processo e facilitar a identificação precisa dos pontos de mudança, permitindo uma análise rigorosa do desempenho do método proposto.

Para investigar a capacidade preditiva dos modelos MSGARCH no método proposto em detectar pontos de mudança, adotou-se um método de comparação. Este enfoque consiste em ajustar o modelo MSGARCH e, posteriormente, comparar o ponto identificado pelo modelo como a primeira mudança de estado com o ponto real de ocorrência dessa mudança. Este processo tem como objetivo avaliar a acurácia do modelo na identificação de pontos de mudança em um cenário simulado. A análise foi realizada para ambos os modelos ARCH e GARCH utilizando a abordagem MSGARCH com o intuito de examinar a eficácia da metodologia de detecção de borda proposta pelo estudo. A fim de avaliar o detector usando como *input* ambos os processos ARCH e GARCH com mudança de estado, como medidas de avaliação (i) a média e mediana das distâncias euclidianas entre os pontos preditos e reais e (ii) a taxa de falso negativo, a qual indica a incapacidade do modelo de reconhecer mudança de estado no raio definido.

Na Figura 2, apresenta-se a representação simulada do Experimento 1, destacando-se a região de borda construída utilizando X-spline em tonalidade azul. As Figuras 3 e 4 expõem, respectivamente, os resultados visuais obtidos pela implementação dos modelos GARCH e ARCH dentro do método proposto. Através de uma investigação prévia por inspeção visual, é evidente que ambos os modelos produziram resultados comparáveis e satisfatórios, demonstrando eficácia.

Figura 2 – Imagem simulada do Experimento 1 com região de borda destacada em azul.

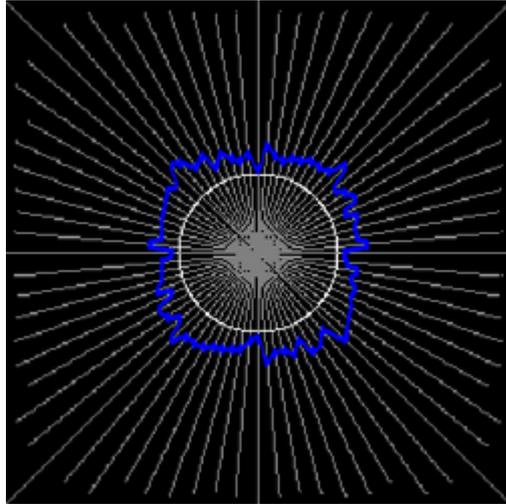


Figura 3 – Imagem da aplicação do método considerando o modelo GARCH no Experimento 1 com região de borda predita destacada em vermelho.

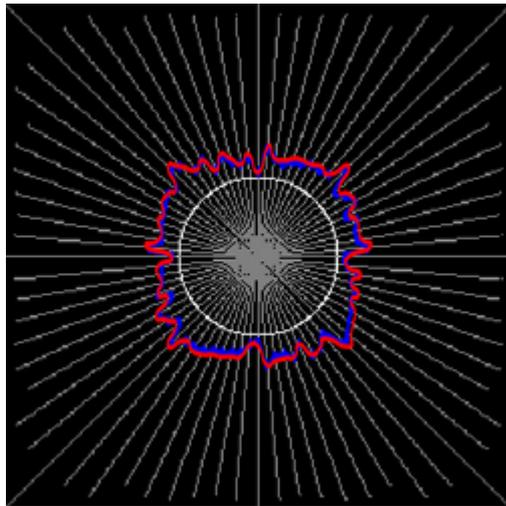
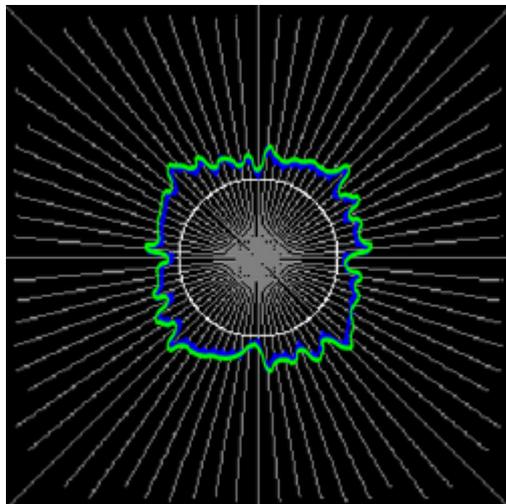


Figura 4 – Imagem da aplicação do método considerando o modelo ARCH no Experimento 1 com região de borda predita destacada em verde.



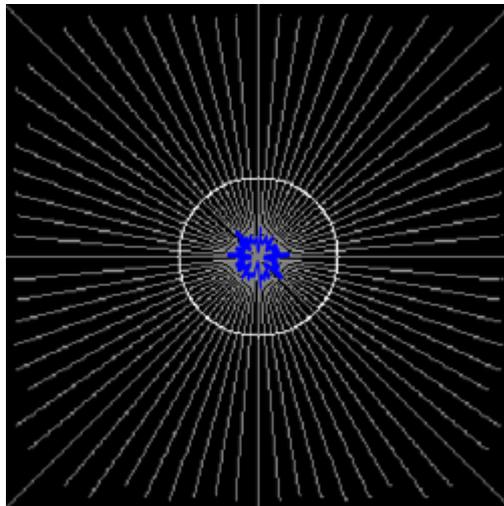
As métricas referentes ao Experimento 1 estão apresentadas na Tabela 1. Nota-se que o Modelo GARCH apresentou desempenho superior nas métricas avaliadas para o Experimento 1, e é importante destacar que ambos os modelos foram eficazes na detecção de mudanças de estado, sem registrar falhas nesse aspecto.

Tabela 1 – Métricas de avaliação de detecção de pontos de mudança do Experimento Simulado 1

| Modelo | Distância Média | Distância Mediana | Taxa de Falso Negativo |
|--------|-----------------|-------------------|------------------------|
| GARCH | 1,35 | 2,00 | 0,00% |
| ARCH | 2,07 | 2,24 | 0,00% |

A Figura 5 exibe a imagem simulada pertencente ao Experimento 2, onde a região de borda é realçada em azul. Esse cenário tem pequeno tamanho amostral e, portanto, a predição do ponto de borda será influenciada negativamente por essa condição. As Figuras 6 e 7 demonstram os ajustes aplicados pelos modelos GARCH e ARCH, respectivamente. Uma análise visual revela que, em comparação com os resultados do Experimento 1, os desempenhos observados neste experimento não foram igualmente satisfatórios.

Figura 5 – Imagem simulada do Experimento 2 com região de borda destacada em azul.



Os valores das medidas de avaliação são apresentados na Tabela 2 e indicam que o modelo GARCH superou o modelo ARCH em termos de desempenho, especialmente ao considerar a discrepância significativa entre as distâncias medianas dos dois modelos. No entanto, o modelo ARCH se sobressai ao apresentar uma taxa de falso negativo consideravelmente mais baixa em comparação ao modelo GARCH.

Embora esteja fora do escopo deste primeiro trabalho, parece razoável entender que (i) o uso de métodos robustos, (ii) de outras formas de modelos de volatilidade e (iii) de distribuições não normais pode solucionar este problema.

Figura 6 – Imagem da aplicação do método considerando o modelo GARCH no Experimento 2 com região de borda predita destacada em vermelho.

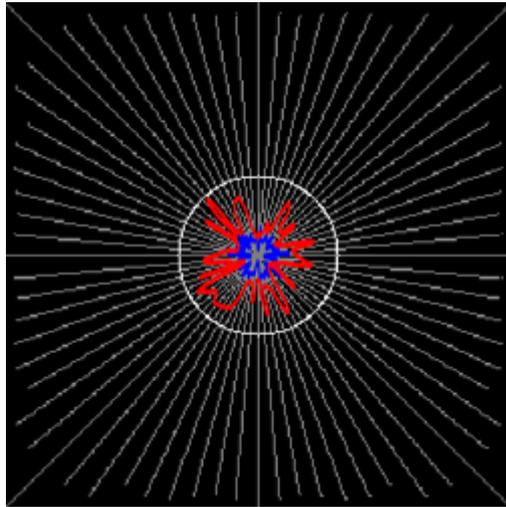


Figura 7 – Imagem da aplicação do método considerando o modelo ARCH no Experimento 2 com região de borda predita destacada em verde.

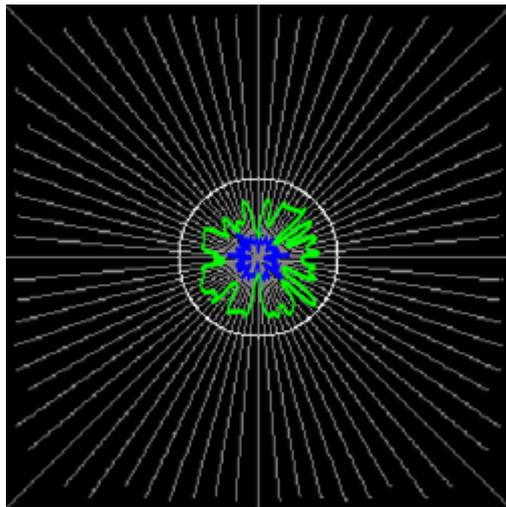
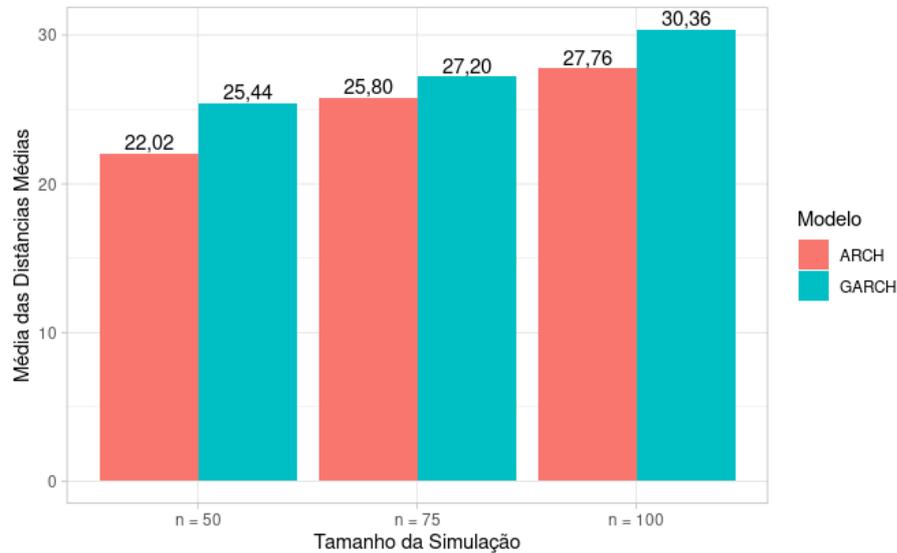


Tabela 2 – Métricas de avaliação de detecção de pontos de mudança do Experimento Simulado 2

| Modelo | Distância Média | Distância Mediana | Taxa de Falso Negativo |
|--------|-----------------|-------------------|------------------------|
| GARCH | 11,72 | 9,22 | 31,94% |
| ARCH | 15,57 | 18,25 | 15,28% |

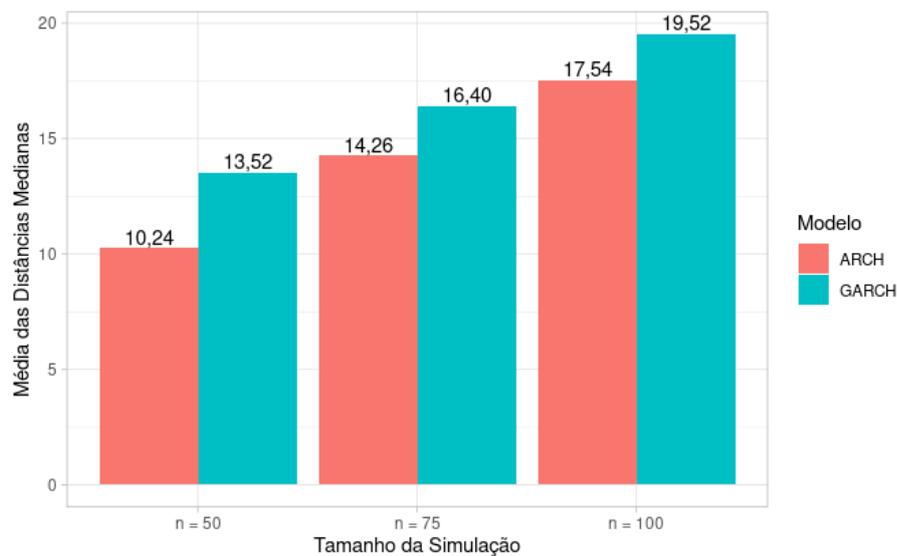
A presença de discrepâncias significativas entre os resultados do primeiro e segundo experimento destaca a importância de realizar simulações adicionais para uma compreensão abrangente do desempenho do método. Essa estratégia é fundamental para assegurar a consistência e a confiabilidade do método, dada a variação nos níveis de eficácia observados. Portanto, serão executadas simulações Monte Carlo considerando tamanhos amostrais 50, 75 e 100 experimentos, com o objetivo de consolidar os resultados e proporcionar uma visão global mais precisa sobre o comportamento do método.

Figura 8 – Gráfico de barra com os valores médios da distância média para tamanho da simulação e segregado por modelo.



A Figura 8 ilustra claramente uma tendência ascendente na distância média à medida que o tamanho da simulação se expande. Notavelmente, nesta análise, o modelo ARCH exibiu um desempenho superior ao do modelo GARCH, o que representa uma inversão em relação aos padrões observados nos primeiros e segundos experimentos.

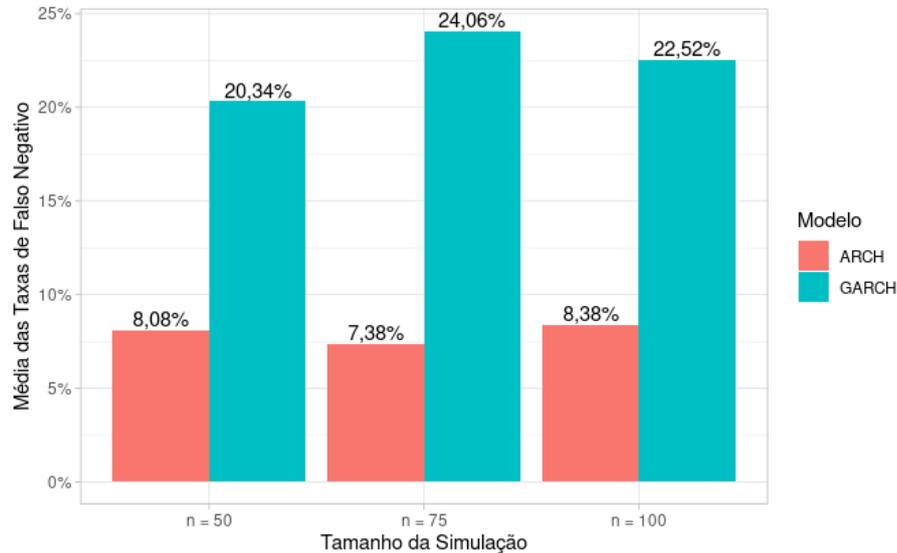
Figura 9 – Gráfico de barra com os valores médios da distância mediana para cada tamanho da simulação e segregado por modelo.



Na Figura 9, observa-se uma tendência de crescimento na distância mediana, similar ao comportamento notado para a distância média, à medida que o tamanho da simulação aumenta. O modelo ARCH se mostrou superior em desempenho quando observado tamanho maiores de observações. Além disso, notou-se que a distância mediana é significativamente

menor que a distância média, fenômeno este atribuído principalmente à influência de valores muito altos de distância média, que acabam por elevar a média geral.

Figura 10 – Gráfico de barra com os valores médios da taxa de falso negativo para tamanho da simulação e segregado por modelo.



O resultado exibido na Figura 10 é particularmente notável, evidenciando uma grande discrepância na capacidade dos modelos ARCH e GARCH de detectar mudanças no raio ajustado. Para a simulação de tamanho 75, a diferença chega a ser de 3 vezes maior, destacando uma distinção significativa na eficácia entre os dois modelos nesse aspecto específico.

A partir das simulações realizadas, constatou-se que o modelo ARCH demonstrou ser mais eficaz na detecção de pontos de mudança em comparação ao modelo GARCH. No entanto, o método proposto não alcançou o nível de consistência e eficácia esperado, indicando que há espaço para melhorias e ajustes a fim de otimizar seu desempenho.

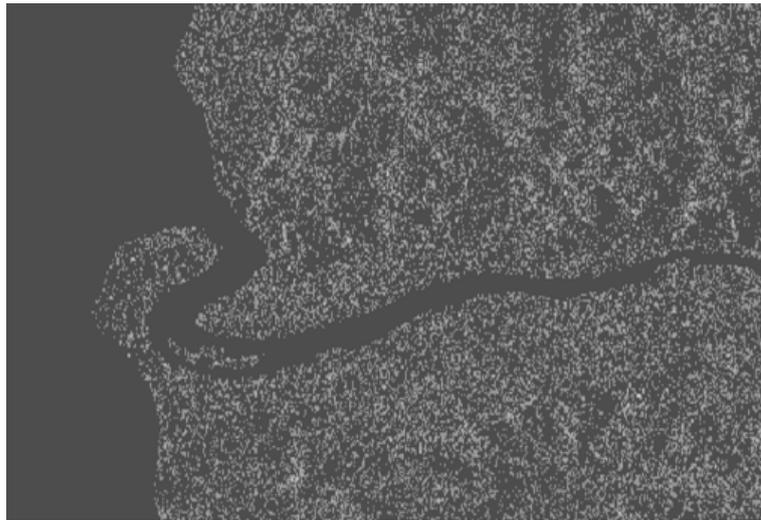
3.3 APLICAÇÃO

No estudo em questão, para a aplicação prática do método proposto, utilizou-se uma imagem SAR capturada na Banda C pelo satélite Sentinel-1, em 17 de abril de 2023. Esta imagem, que apresenta capacidades de polarização dupla (dual-pol), foi disponibilizada pelo Laboratório de Propulsão a Jato da NASA através da sua plataforma aberta do *Uninhabited Aerial Vehicle Synthetic Aperture Radar - UAVSAR*. A área de cobertura da imagem abrange a região costeira de Japaratinga, localizada em Alagoas, bem como as proximidades do Rio Manguaba. Visando a redução do ruído *speckle*, um fenômeno comum em imagens SAR,

procedeu-se à aplicação de uma técnica de multilook, ajustando o fator para 3 no eixo range e para 1 no eixo azimutal.

O método proposto opera em uma única dimensão, enquanto a imagem em questão é multiespectral, incluindo polarizações Vertical-Vertical - VV e Vertical-Horizontal - VH. Portanto, apenas o espectro correspondente à polarização VH será considerado na análise. A imagem gerada por essa polarização pode ser observada na Figura 11.

Figura 11 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL.



As áreas aquáticas são caracterizadas por sua homogeneidade, enquanto as áreas terrestres exibem uma notável heterogeneidade. Com base nessa distinção, serão adotadas duas abordagens distintas: a primeira envolve o uso do algoritmo *K-means* para identificar um ponto de referência, e a segunda, a seleção manual de um ponto de referência situado em uma área homogênea. Essas abordagens permitirão avaliar o desempenho do método em questão, observando como ele se comporta quando o ponto de referência está localizado tanto em áreas homogêneas quanto heterogêneas.

A Figura 12 ilustra o ponto de referência localizado em uma área heterogênea, com raios tracejados cruzando o Rio Manguaba, destacando o objetivo de detectar precisamente as margens do rio. Neste cenário, apresenta-se uma condição atípica com uma transição para três estados, divergindo da proposta inicial do método. Essa abordagem não convencional permite não apenas testar o método em condições desafiadoras, mas também oferece uma oportunidade para observar possíveis melhorias. Os modelos ARCH, GARCH, EGARCH e GJR serão utilizados para prever as regiões de borda.

A região prevista pelo modelo ARCH é ilustrada na Figura 13. Observa-se que a maioria dos pontos previstos situa-se nas proximidades do ponto de referência, com apenas uma exceção.

Figura 12 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL com raios tracejados considerando a primeira abordagem.

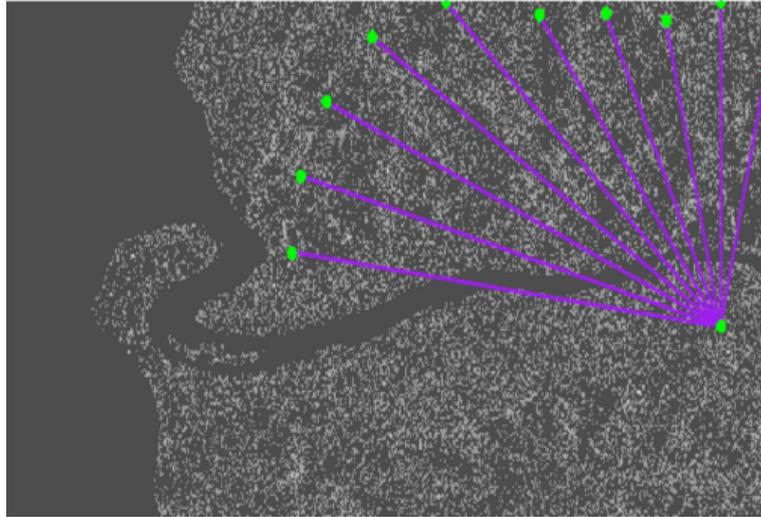
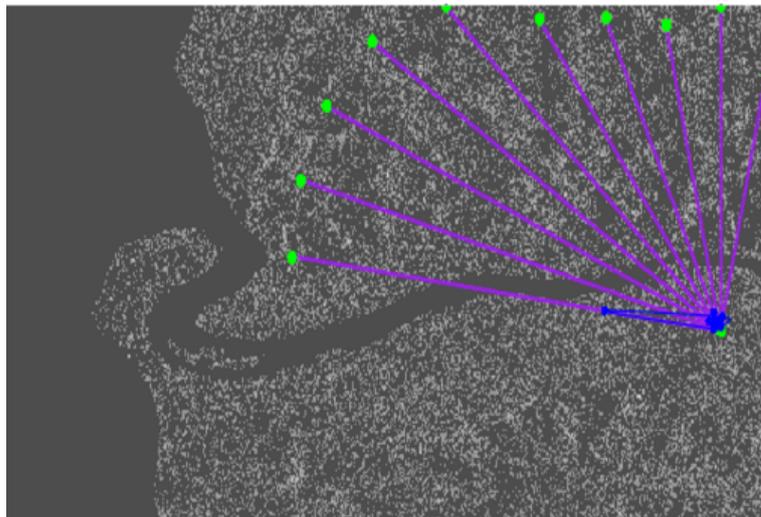


Figura 13 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em azul predita pelo modelo ARCH e considerando a primeira abordagem.



Contudo, é relevante destacar que nenhum dos pontos previstos se encontra na margem do rio.

Ilustrada pela Figura 14, a região prevista pelo Modelo GARCH revela um padrão interessante. Similarmente ao que foi notado no modelo ARCH, os pontos previstos concentram-se majoritariamente próximo ao ponto de referência. Entretanto, merece atenção o fato de que um ponto foi identificado nas imediações da margem do rio.

As regiões previstas pelos modelos EGARCH e GJR são ilustradas nas Figuras 15 e 16, respectivamente. Em ambos os casos, todos os pontos previstos encontram-se muito próximos ao ponto de referência.

A aplicação da primeira abordagem não resultou em êxito para nenhum dos modelos

Figura 14 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em vermelho predita pelo modelo GARCH e considerando a primeira abordagem.

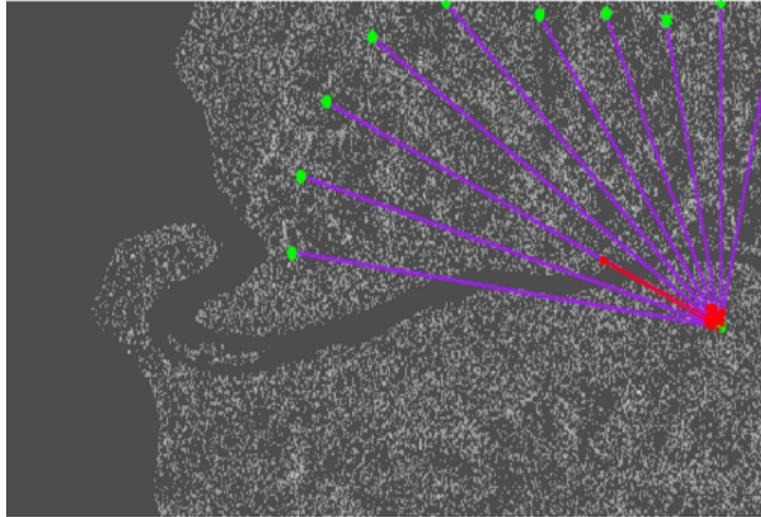
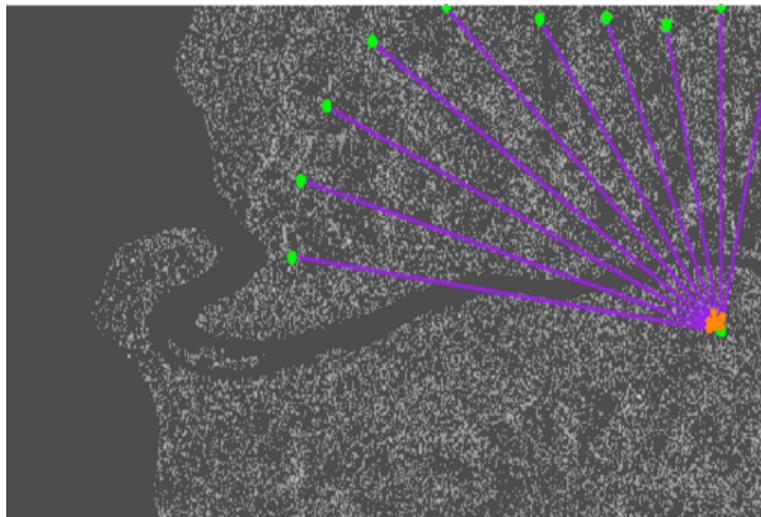


Figura 15 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em laranja predita pelo modelo EGARCH e considerando a primeira abordagem.



testados. Dentre eles, o modelo GARCH sobressaiu-se pela previsão de um ponto próximo à margem do rio, quando avaliado visualmente. Entretanto, apesar deste destaque, o desempenho geral do modelo GARCH não foi considerado satisfatório.

Como previamente discutido, a segunda abordagem se caracteriza pela seleção de um ponto de referência situado numa área de homogeneidade. Demonstrado na Figura 17, tal ponto é marcado, assim como os raios tracejados que dele se originam. O propósito é realizar uma detecção precisa das margens costeiras, as quais são cruzadas pelos raios mencionados.

Na Figura 18, a região de borda e os pontos previstos pelo modelo ARCH são destacados em azul. Observa-se que a maioria desses pontos localiza-se próximo à margem costeira, com exceção de um. É importante destacar que, para o último raio, não foi possível estimar os

Figura 16 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em amarelo prevista pelo modelo GJR e considerando a primeira abordagem.

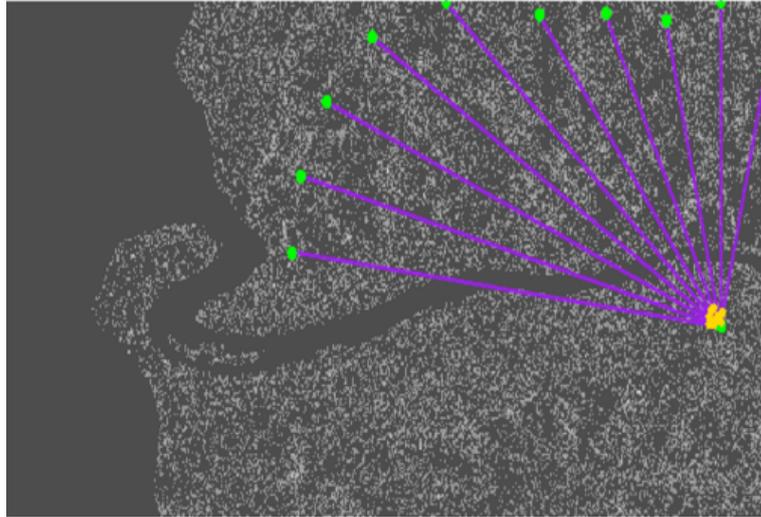
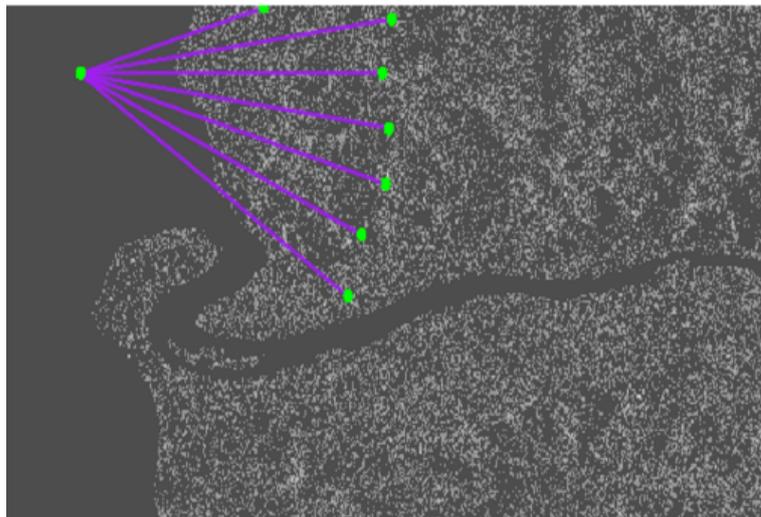


Figura 17 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com raios tracejados considerando a segunda abordagem.



parâmetros do modelo devido a um erro computacional.

A análise dos pontos de borda e da região de borda previstos pelo modelo GARCH, apresentados na Figura 19, revela resultados similares aos obtidos com o modelo ARCH. Nota-se que a grande maioria dos pontos previstos situa-se nas imediações da costa, com a exceção de um ponto que se encontra próximo ao ponto de referência.

A Figura 20 ilustra os pontos e a região de borda previstos pelo método considerando o modelo EGARCH. Os resultados são consistentes com os de modelos anteriores, exibindo a maioria dos pontos previstos próximos à costa, exceto por um ponto. No entanto, este ponto se encontra menos afastado da costa do que aqueles previstos pelos outros modelos.

Os pontos e a região de borda previstos pelo modelo GJR são evidenciados na Figura 21.

Figura 18 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em azul predita pelo modelo ARCH e considerando a segunda abordagem.

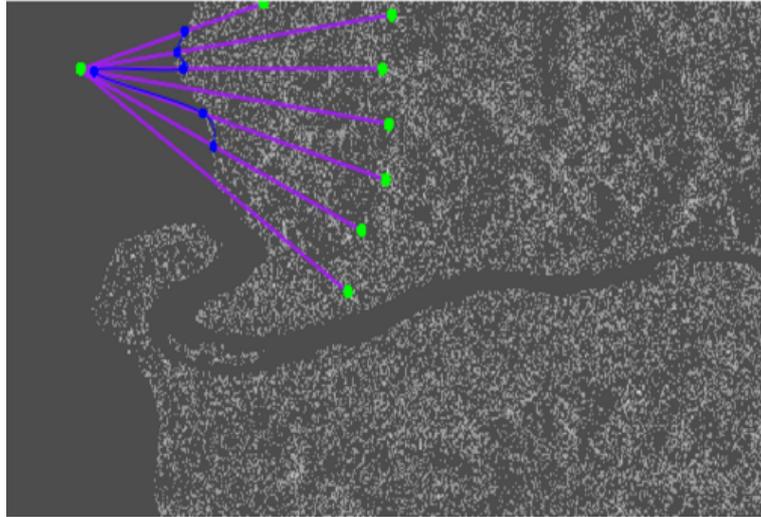
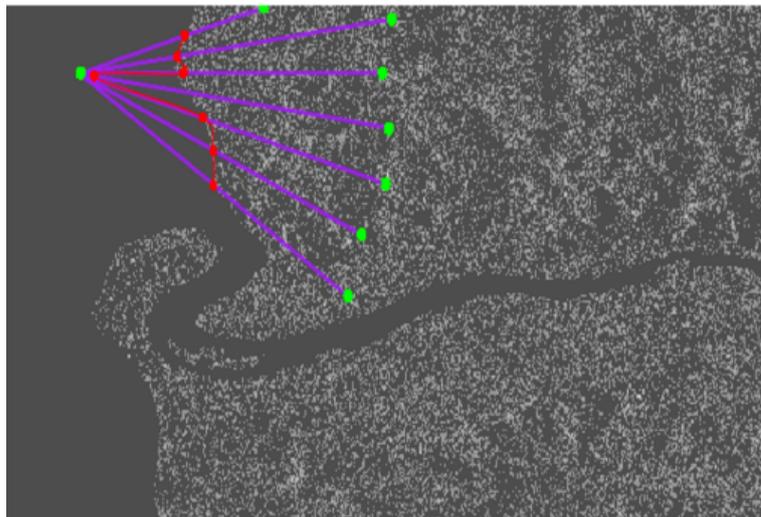


Figura 19 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em vermelho predita pelo modelo GARCH e considerando a segunda abordagem.



Os resultados são consistentes com aqueles obtidos pelos modelos ARCH e GARCH, com a maioria dos pontos localizados próximos à costa, exceto por um ponto que se encontra significativamente mais distante.

Os resultados mais satisfatórios do método proposto, adotando a estratégia de posicionar o ponto de referência manualmente em uma área homogênea, foram observados com o modelo EGARCH. No entanto, os desempenhos de todos os modelos testados mostraram-se bastante similares entre si. Em comparação com a primeira abordagem, na qual o ponto de referência iniciava em uma região heterogênea, os resultados alcançados pela segunda abordagem foram significativamente melhores. Isso leva a indicar que o método proposto neste estudo enfrenta consideráveis desvantagens quando aplicado partindo de uma área heterogênea.

Figura 20 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em laranja predita pelo modelo EGARCH e considerando a segunda abordagem.

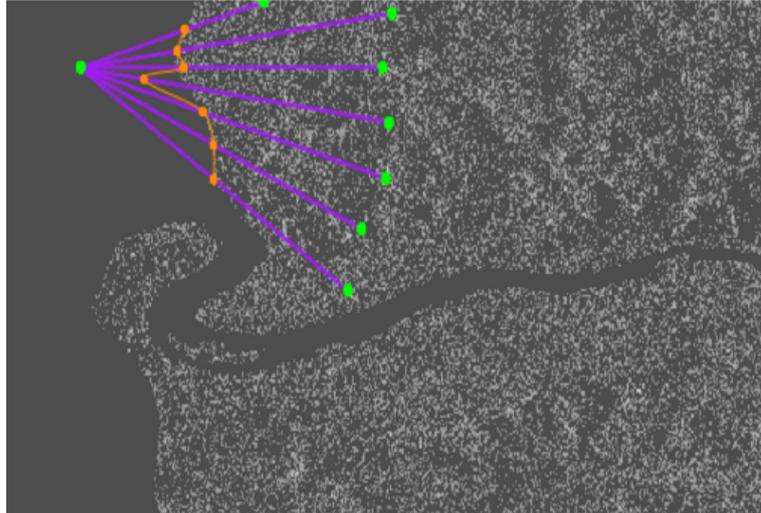
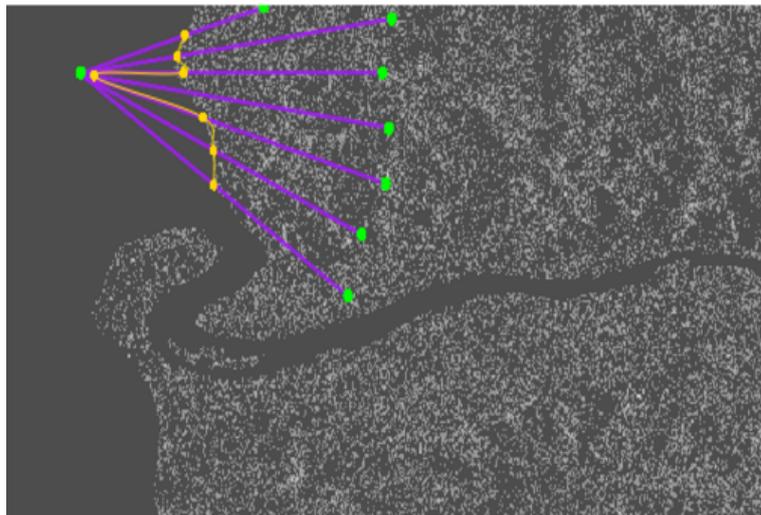


Figura 21 – Imagem SAR da região próxima à costa da cidade de Japaratinga - AL, com região de borda em amarelo predita pelo modelo GJR e considerando a segunda abordagem.



4 CONCLUSÕES E TRABALHOS FUTUROS

O estudo visou analisar a eficácia de um método de detecção de bordas utilizando modelos *Markov Switching* GARCH em imagens SAR. Em experimentos projetados para avaliar a precisão na detecção de pontos de mudança em séries simuladas, baseando-se em um processo GARCH(1,1) com transição entre dois estados, observou-se que o método não alcançou uma precisão elevada, apresentando distâncias relativamente grandes entre os pontos de mudança preditos e os reais. Nesse contexto, o modelo ARCH mostrou-se superior ao GARCH, este último com uma taxa média de falso negativos significativamente mais alta.

Na aplicação prática em uma imagem SAR da região próxima à costa da cidade de Japaratinga - AL, constatou-se uma limitação do método, quando os raios originaram-se de um ponto em área heterogênea, os resultados ficaram aquém do esperado. Por outro lado, partindo de um ponto em área homogênea, os resultados foram mais promissores, com a detecção de pontos de borda ocorrendo de maneira relativamente precisa. Essa sensibilidade do método proposto, em relação à característica da área de origem dos raios, representa um aspecto negativo a ser considerado.

Para futuros estudos, recomenda-se explorar séries temporais que incorporem mudanças de nível, utilizando distribuições capazes de gerenciar o efeito multiplicativo do ruído *speckle*. Uma possibilidade é a aplicação da distribuição G (Freitas; Frery; Correia, 2005), que demonstrou potencial para lidar com tais características. A adoção dessa abordagem poderá contribuir significativamente para o avanço da precisão e da aplicabilidade dos métodos de detecção de bordas em imagens SAR utilizando técnicas analíticas de séries temporais.

REFERÊNCIAS

- ABDEL-GAWAD, A. H.; SAID, L. A.; RADWAN, A. G. Optimized edge detection technique for brain tumor detection in mr images. *IEEE Access*, v. 8, p. 136243–136259, 2020.
- ALMEIDA JUNIOR, P.; NASCIMENTO, A. G0I ARMA process for speckled data. *Journal of Statistical Computation and Simulation*, p. 1–29, 05 2021.
- AMIRMAZLAGHANI, M.; AMINDAVAR, H.; MOGHADDAMJOO, A. Speckle suppression in SAR images using the 2-D GARCH model. *IEEE Transactions on Image Processing*, v. 18, n. 2, p. 250–259, 2009.
- ARDIA, D. *Financial Risk Management with Bayesian Estimation of GARCH Models: Theory and Applications*. [S.l.: s.n.], 2009. v. 612. ISBN 978-3-540-78656-6.
- ARDIA, D.; BLUTEAU, K.; BOUDT, K.; CATANIA, L.; TROTTIER, D.-A. Markov-switching GARCH models in R: The MSGARCH package. *Journal of Statistical Software*, v. 91, 2019.
- BLANC, C.; SCHLICK, C. X-splines: a spline model designed for the end-user. Association for Computing Machinery, New York, NY, USA, p. 377–386, 1995.
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, v. 31, p. 307–327, 1986.
- CAMPBELL, J.; WYNNE, R. *Introduction to Remote Sensing, Fifth Edition*. [S.l.]: Guilford Publications, 2011. ISBN 9781609181772.
- CHIN, R. T.; JAU, J. Y. C.; WEINMAN, J. A. The application of time series models to cloud field morphology analysis. *American Meteorological Society*, v. 26, p. 363–373, 1987.
- DUTRA, L. V.; MASCARENHAS, N. D. A. Some experiments with spatial feature extraction methods in multispectral classification. *International Journal of Remote Sensing*, Taylor Francis, v. 5, p. 303–313, 1984.
- ENGLE, R. F. Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica*, v. 50, p. 987, 1982.
- FABREGAS, X.; POTTIER, E. Multidimensional speckle noise model. *EURASIP Journal on Applied Signal Processing*, v. 2005, p. 3259–3271, 12 2005.
- FRANKE, R. Scattered data interpolation: tests of some methods. *Mathematics of Computation*, v. 38, p. 181–200, 1982.
- FREITAS, D. D. C.; FRERY, A.; CORREIA, A. The polarimetric G distribution for SAR data analysis. *Environmetrics*, v. 16, p. 13 – 31, 02 2005.
- FRERY, A.; WU, J.; DENIZ, L. *SAR Image Analysis – A Computational Statistics Approach: With R Code, Data, and Applications*. [S.l.: s.n.], 2022. ISBN 9781119795292.
- FU, X.; YOU, H.; FU, K. A statistical approach to detect edges in SAR images based on square successive difference of averages. *IEEE Geoscience and Remote Sensing Letters*, v. 9, n. 6, p. 1094–1098, 2012.

- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the relation between the expected value and the volatility of the nominal excess return on stocks. *The Journal of Finance*, v. 48, p. 1779–1801, 1993.
- GORDON, W. J.; RIESENFELD, R. F. B-spline curves and surfaces. Academic Press, p. 95–126, 1974.
- HAAS, M.; MITTNIK, S.; PAOLELLA, M. S. A New Approach to Markov-Switching GARCH Models. *Journal of Financial Econometrics*, v. 2, n. 4, p. 493–530, 09 2004.
- HAMILTON, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, [Wiley, Econometric Society], v. 57, n. 2, p. 357–384, 1989. ISSN 00129682, 14680262. Disponível em: <<http://www.jstor.org/stable/1912559>>.
- JENSEN, J. *Remote Sensing of the Environment: An Earth Resource Perspective: Pearson New International Edition*. [S.l.]: Pearson Education, 2013. ISBN 9781292034935.
- JING, J.; LIU, S.; WANG, G.; ZHANG, W.; SUN, C. Recent advances on image edge detection: A comprehensive review. *Neurocomputing*, v. 503, p. 259–271, 2022.
- JING, W.; JIN, T.; XIANG, D. SAR image edge detection with recurrent guidance filter. *IEEE Geoscience and Remote Sensing Letters*, v. 18, n. 6, p. 1064–1068, 2021.
- KAMUSOKO, C. *Remote Sensing Image Classification in R*. 1st. ed. [S.l.]: Springer Publishing Company, Incorporated, 2019. ISBN 9789811380112.
- KASSAMBARA, A. *Practical Guide to Cluster Analysis in R: Unsupervised Machine Learning*. [S.l.]: STHDA, 2017. v. 1.
- LEESE, J. A. Remote sensing applications in the meteorology and operational hydrology programmes of wmo. *Advances in Space Research*, v. 7, n. 3, p. 49–57, 1987. ISSN 0273-1177.
- LI, J.; PEI, Y.; ZHAO, S.; XIAO, R.; SANG, X.; ZHANG, C. A review of remote sensing for environmental monitoring in China. *Remote Sensing*, v. 12, n. 7, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/7/1130>>.
- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*. [S.l.: s.n.], 1967. v. 1, n. 14, p. 281–297.
- MANTOVANI, F.; SOETERS, R.; Van Westen, C. Remote sensing techniques for landslide studies and hazard zonation in europe. *Geomorphology*, v. 15, n. 3, p. 213–225, 1996. ISSN 0169-555X.
- MCCORMICK, B. H.; JAYARAMAMURTHY, S. N. Time series model for texture synthesis. *International Journal of Computer & Information Sciences*, v. 3, p. 329–343, 1974. ISSN 1573-7640.
- MEISSNER, B. Remote sensing cartography: Following the basic rules of cartography guaranties the optimum use of remote sensing data for topographic and thematic maps. *GeoJournal*, Springer, v. 32, n. 1, p. 71–79, 1994. ISSN 03432521, 15729893. Disponível em: <<http://www.jstor.org/stable/41146068>>.

NASCIMENTO, A.; SILVA, K.; FRERY, A. Distance-based edge detection on synthetic aperture radar imagery. *Chilean Journal of Statistics*, v. 12, n. 1, p. 71–82, Apr 2021.

NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, v. 59, p. 347, 1991.

PASCUAL, J. P.; ELLENRIEDER, N. von; HURTADO, M.; MURAVCHIK, C. H. Adaptive radar detection algorithm based on an autoregressive GARCH-2D clutter model. *IEEE Transactions on Signal Processing*, v. 62, n. 15, p. 3822–3832, 2014.

PEI, T.; XU, J.; LIU, Y.; HUANG, X.; ZHANG, L.; DONG, W.; QIN, C.; SONG, C.; GONG, J.; ZHOU, C. Giscience and remote sensing in natural resource and environmental research: Status quo and future perspectives. *Geography and Sustainability*, v. 2, n. 3, p. 207–215, 2021. ISSN 2666-6839.

PETROU, M.; PETROU, C. *Image Processing: The Fundamentals*. [S.l.]: Wiley, 2010. ISBN 9780470745861.

R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2024. Disponível em: <<https://www.R-project.org/>>.

RANGAYYAN, R. M. *Biomedical Image Analysis*. [S.l.]: CRC Press, 2004. (Biomedical Engineering). ISBN 9780429209093.

SILVA, W. B. F. da; ALMEIDA-JUNIOR, P. M.; NASCIMENTO, A. D. C. Generalized gamma ARMA process for synthetic aperture radar amplitude and intensity data. *Environmetrics*, v. 34, n. 7, p. e2816, 2023.

VITERBI, A. Error bounds for convolutional codes and an asymptotically optimum decoding algorithm. *IEEE Transactions on Information Theory*, v. 13, n. 2, p. 260–269, 1967.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, v. 236, p. 111402, 2020. ISSN 0034-4257.

WELLMANN, T.; LAUSCH, A.; ANDERSSON, E.; KNAPP, S.; CORTINOVIS, C.; JACHE, J.; SCHEUER, S.; KREMER, P.; MASCARENHAS, A.; KRAEMER, R.; HAASE, A.; SCHUG, F.; HAASE, D. Remote sensing in urban planning: Contributions towards ecologically sound policies? *Landscape and Urban Planning*, v. 204, p. 103921, 2020. ISSN 0169-2046.

ZHANG, Y.; DENG, Z.; SHI, J.; ZHANG, Y.; LIU, H. Sea clutter modeling using an autoregressive generalized nonlinear-asymmetric GARCH model. *Digital Signal Processing*, v. 62, p. 52–64, 2017. ISSN 1051-2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1051200416301890>>.

ZHANG, Y.; LIU, H.; HUANG, Y.; DENG, Z. A nonlinear ARMA-GARCH model with johnson s_u innovations and its application to sea clutter modeling. *IEEE Access*, v. 6, p. 11888–11896, 2018.

ZHANG, Y.; SHI, J.; DENG, Z.; PAN, P. Detection in sea clutter based on nonlinear ARCH model. *Digital Signal Processing*, v. 50, p. 162–170, 2016. ISSN 1051-2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1051200415003656>>.