



UNIVERSIDADE FEDERAL DO MARANHÃO-UFMA
CENTRO DE CIÊNCIAS DE CHAPADINHA-CCCh
CURSO DE ENGENHARIA AGRÍCOLA

ANTONIO EMANUEL SOUTA VERAS

**ANÁLISE E CLASSIFICAÇÃO DE IMAGENS DE RADAR PARA O MUNICÍPIO
DE AÇAILÂNDIA-MA**

CHAPADINHA-MARANHÃO-BRASIL

Julho de 2022

UNIVERSIDADE FEDERAL DO MARANHÃO-UFMA
CENTRO DE CIÊNCIAS DE CHAPADINHA-CCCh
CURSO DE ENGENHARIA AGRÍCOLA

ANTONIO EMANUEL SOUTA VERAS

**ANÁLISE E CLASSIFICAÇÃO DE IMAGENS DE RADAR PARA O MUNICÍPIO
DE AÇAILÂNDIA-MA**

Trabalho de Conclusão de Curso da Universidade Federal do Maranhão, como requisito para obtenção do grau de Bacharel em Engenharia Agrícola, sob orientação da Prof.^a Dr.^a Kamilla Andrade de Oliveira.

CHAPADINHA-MARANHÃO-BRASIL
Julho de2022

ANTONIO EMANUEL SOUTA VERAS

Monografia apresentada ao Colegiado do curso
de Engenharia Agrícola da Universidade Federal
do Maranhão como requisito para obtenção do
grau de Bacharel em Engenharia Agrícola.

Aprovado em:28/07/2022

BANCA EXAMINADORA

Prof.^a Dr.^a Kamilla Andrade de Oliveira
UFMA– Orientadora

Prof. Dr. Jordânio Inácio Marques
UFMA

Prof. Dr. Gustavo Macedo de Mello Baptista
UnB

FICHA CATALOGRÁFICA

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Souta Veras, Antonio Emanuel.

ANÁLISE E CLASSIFICAÇÃO DE IMAGENS DE RADAR PARA O
MUNICÍPIO DE AAILÂNDIA-MA / Antonio Emanuel Souta Veras.
- 2022.
43 f.

Orientador(a): Kamilla Andrade de Oliveira.
Monografia (Graduação) - Curso de Engenharia Agrícola,
Universidade Federal do Maranhão, Chapadinha-MA, 2022.

1. Algoritmos de classificação. 2. Mapeamentos por
SAR. 3. Uso do solo. I. Andrade de Oliveira, Kamilla.
II. Título.

DEDICATÓRIAS

Dedico o meu trabalho especialmente a
minha esposa que é minha base e meu
caminho. E a toda minha família e amigos

AGRADECIMENTOS

À Deus, pois sem minha fé eu não seria nada.

Aos meus pais Marília e Francisco, pelo dom da minha vida e suporte nos momentos que precisei.

A minha esposa, minha companheira de guerra por ser essencial na minha vida, por ser meu braço forte e meu bem mais precioso.

À Universidade Federal do Maranhão pela oportunidade de realizar esse curso.

À minha orientadora Prof.^a Dr.^a Kamilla Andrade de Oliveira pela confiança depositada, atenção e ensinamentos.

Aos meus irmãos e compadres Cícero, Simão, Augusto que sempre estiveram ao meu lado e torceram pelo meu sucesso.

As minhas irmãs Carla e Vanuza, pelo carinho e por sempre torcerem por mim.

Aos meus sogros Nivaldo e Amélia que torceram e acompanharam de perto essa minha caminhada de lutas e conquistas.

As minhas cunhadas e comadres pelo carinho e torcida.

Aos meus afilhados e sobrinhos que são como meus filhos por todo carinho e amor.

Aos meus avôs maternos e paternos pela contribuição afetiva.

Aos meus tios e primos que torceram por mim.

Aos amigos e a todos os familiares.

A minha banca examinadora.

Aos vizinhos de Chapadinha em especial Raimundo.

Muito obrigado!

Apesar de Deus dar o dom da visão para que as pessoas vejam o mundo, nem todas elas conseguem apreciá-lo.

RESUMO

O uso de geotecnologias para aprimoramento da agricultura vem sendo bastante estudado, neste sentido se faz importante mais aplicações de técnicas sobre sensoriamento remoto. Um dos procedimentos que vem sendo adotado para classificação e cobertura da terra, pode ser obtido por meio de sensores SAR, que servem tanto para identificação como para monitorar a cobertura da terra visando detectar as alterações ocorridas na superfície terrestre, como fazer reconhecimento do solo, vegetação natural e antrópica. Método exposto através do retroespalhamento e o efeito *double-bounce* dos alvos com a vantagem de adquirir imagens, independe da presença de nuvens ou fumaça, porém vai depender da faixa de frequência. As imagens de radar servem para obtenção de informações adicionais e características exclusivas da interação com os alvos da superfície terrestre, usam modo de imageamento por micro-ondas na qual os dados de radar na banca C apresentam frequências entorno de 5,5 GHz. Dessa forma, o presente trabalho tem como objetivo proporcionar uma aplicação do banco de dados, classificar o uso adequado do solo e suas aplicações, tanto para fins agrícolas como para um melhor manejo ambiental da área de estudo. Para tal foram utilizadas quatro etapas: (1) construção e manipulação do banco de dados geográficos; (2) pré-processamento dos dados das imagens SAR; (3) classificação das imagens e recorte para a área de estudo; (4) resultados e análise estatística do processamento. Para validação dos dados usou-se a correlação cruzada obtida pelo próprio SNAP, (acurácia, precisão, correlação e erro), gerados em cada algoritmo de classificação. Obteve-se resultados para classificação supervisionada, onde os melhores algoritmos classificadores foram Random Forest e KDTree KNN. Dessa forma, foi constatado que as condições climáticas e a condição fenológica da vegetação no período chuvoso geram grande dispersão dos pixels resultando em uma maior confusão entre as classes, quando relacionada às variáveis de avaliações.

Palavras chaves: Algoritmos de classificação, uso do solo, mapeamentos por SAR.

ABSTRACT

The use of geotechnologies to improve agriculture has been extensively studied, in this sense, more applications of techniques on remote sensing are important. One of the procedures that has been adopted for classification and land cover, can be obtained through SAR sensors, which serve both for identification and monitoring of land cover in order to detect changes that have occurred on the land surface, such as reconnaissance of the soil, natural and anthropic vegetation. Method exposed through backscatter and the double-bounce effect of targets with the advantage of acquiring images, regardless of the presence of clouds or smoke, but will depend on the frequency range. The radar images serve to obtain additional information and unique characteristics of the interaction with the Earth surface targets, they use microwave imaging mode in which the radar data in the C band have frequencies around 5.5 GHz. Thus, the present work aims to provide an application of the database, classify the proper use of the soil and its applications, both for agricultural purposes and for a better environmental management of the study area. For this, four steps were used: (1) construction and manipulation of the geographic database; (2) pre-processing of SAR image data; (3) classification of images and clipping to the study area; (4) results and statistical analysis of processing. For data validation, the cross-correlation obtained by the SNAP itself (accuracy, precision, correlation and error) generated in each classification algorithm was used. Results were obtained for supervised classification, where the best classification algorithms were Random Forest and KDTree KNN. Thus, it was found that the climatic conditions and the phenological condition of the vegetation in the rainy season generate a large dispersion of pixels, resulting in greater confusion between the classes, when related to the evaluation variables.

Keywords: Classification algorithms, land use, SAR mapping.

LISTA DE FLUXOGRAMA

Fluxograma 1 - Representação dos processos metodológicos seguindo as quatro etapas.	22
Fluxograma 2 - Etapas de processamento das imagens de SAR.	24
Fluxograma 3 - Montagem do processo para a execução dos algoritmos de classificação das imagens de radar.	26

LISTA DE TABELAS

Tabela 1 - Datas que as imagens Sentinel 1A foram selecionadas para execução do trabalho.....	22
--	----

LISTA DE FIGURAS

Figura 1 - Mapa de localização da área de estudo.	21
Figura 2 - Imagem geral sem recorte do município de Açailândia-Ma, utilizada para criar os vetores da classificação supervisionada.	25
Figura 3 (A, B, C, D, E, F, G e H) - Representação dos vetores de cada classe (A-corpos hídricos; B-floresta plantada; C-infraestrutura urbana; D-agricultura; E-área não vegetada; F-pastagem; G-floresta natural e H- geometria).	25
Figura 4 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açailândia-MA para os meses de dezembro de 2020 e janeiro de 2021.	28
Figura 5 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açailândia-Ma nos meses de junho e julho de 2021.....	29
Figura 6 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açailândia-Ma nos meses de novembro e dezembro de 2021.	30
Figura 7 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de dezembro de 2020 e janeiro de 2021.	31
Figura 8 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de junho e julho de 2021.....	32
Figura 9 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de novembro e dezembro de 2021.....	33
Figura 10 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de dezembro de 2020 e janeiro de 2021.	35
Figura 11 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de junho e julho de 2021.....	36
Figura 12 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de novembro e dezembro de 2021.....	37

SUMÁRIO

1-INTRODUÇÃO	13
2-REVISÃO DE LITERATURA.....	14
2.1. Uso e importância de imagens de radar SAR	14
2.2- Software SNAP™	16
2.3. Imagens Sentinel 1-A	17
2.4. Modo de imageamento IW e banda C	17
2.5. Polarização	18
2.6. Algoritmos de classificação	19
3-OBJETIVOS	20
3.1-Objetivo geral	20
3.2-Objetivos específicos	20
4-MATERIAL E MÉTODOS.....	20
4.1-Área de estudo	20
4.1 -Atividade desenvolvidas	21
4.3 -Pré-processamento	23
4.4 - Processo de classificação.....	24
4.5-Dados estatísticos.....	27
5-RESULTADOS E DISCUSSÃO.....	27
6-CONCLUSÃO.....	39
7-CONSIDERAÇÕES FINAIS.....	39
REFERÊNCIA.....	40

1-INTRODUÇÃO

O sensoriamento remoto vem sendo muito utilizado com intuito de obter dados para uso e cobertura da terra com monitoramento e análises dos recursos naturais tem sido amplamente difundida (SILVA, 2021). O uso de dados obtidos de sensores remotos em estudos de identificação e monitoramento da cobertura da terra visam detectar as alterações ocorridas na superfície terrestre. Através da identificação desses fatores as imagens são produzidas pelos sensores, na qual torna-se possível realizar análises e mapeamentos em diversas escalas (MARTINS, 2012).

Para a cobertura e uso da terra é indispensável o uso de dados dos sistemas de informações geográficas (SIG) e do sensoriamento remoto (SR). Pois, fornecem métodos e técnicas para armazenar, organizar e extrair informações temáticas para aplicar no mapeamento do alvo de interesse na paisagem do estudo. Além disso, possuem técnicas que fazem o uso de séries temporais, proveniente das imagens de satélite, tornando possível a classificação das imagens, ou detecções de mudança, entre outros (SALGADO, 2019).

As imagens SAR são consideradas um sistema com grandes vantagens pois não dependem do tempo e horário, porém as nuvens podem apresentar um pouco de interferências nas imagens. Além disso, os erros que podem surgir nas imagens, estão relacionados a topografia do terreno e sua declividade local na qual afeta o brilho da imagem, por outro lado a topografia acentuada, ocasiona a diminuição no retroespalhamento e aumento do ângulo de incidência (ALENCAR, 2013).

A utilização de imagens de radar torna possível a obtenção de informações adicionais e características exclusivas da interação com os alvos da superfície terrestre em relação aos sensores ópticos. Tendo seu destaque para mapeamentos de cobertura vegetal, mas seu uso eficiente depende das características do sistema, da vegetação, amplitude e da extensão da inundação (CECHIM JÚNIOR et al., 2020). Além disso, possuem sua independência da radiação solar, e certos comprimentos de onda capazes de atravessar as nuvens, com a capacidade de imageamento quase independente das condições climáticas. (SILVA, 2021).

As imagens de sensoriamento remoto vêm passando pelo processo de evolução das resoluções espacial e espectral, por conta dos avanços tecnológicos de imagem, na qual vem permitindo um aumento da eficiência no que desrespeita a obtenção de dados de cobertura de solo em ambientes urbanos (BARROS, 2015). De acordo com Meneses et al. (2012), as técnicas de processamento vêm se desenvolvendo para se tornar mais acessível, garantindo a

interação homem-máquina, com a extração de informações com métodos de fácil interpretação.

A dinâmica do uso e cobertura da terra é uma área de estudo na qual o sensoriamento remoto, vem apresentando reconhecimento para avaliação de impactos ambientais, monitoramentos ecológicos e mudanças globais, planejamento territorial para identificação e prevenção da expansão irregular da malha urbana (BARBOSA et al., 2021). Considerando os estudos de sensoriamento remoto em escala regional em ambiente urbano geralmente usam sensores óticos e termais, gerando soluções que agregam conhecimentos em diferentes características levando em consideração ao uso do SAR e abordagens metodológicas (BARBOSA, 2021).

A microrregião de Imperatriz do oeste maranhense possui uma posição geográfica que facilita a comunicação, dessa forma sempre teve muito potencial agrícola, na qual atualmente representa uma das mais importantes bacias leiteiras do Maranhão com uma produção que responde pela metade do leite produzido no estado (SILVA et al., 2012).

O presente trabalho realizou o processamento de imagens SAR para verificar a dinâmica e uso do solo em um dos municípios da microrregião do oeste maranhense, na cidade de Açailândia-MA com intuito de observar a eficiência de cada algoritmo utilizado para a verificação das classes correspondentes no trabalho. Tendo em vista que há pouco estudo para esta cidade, que possui um grande desenvolvimeto no setor agrícola e florestal.

2-REVISÃO DE LITERATURA

2.1. Uso e importância de imagens de radar SAR

As geotecnologias mais precisamente o sensoriamento remoto auxilia estudos geográficos, em relação a mapeamento dos fenômenos antrópicos e ambientais (MONTEIRO, 2019). Dessa forma destaca-se a utilização de dados de RADAR, mais especificamente SAR (*Synthetic Aperture Radar*), ou seja, radar de abertura sintética, produzidos pelos sistemas de sensores ativos de visada lateral que operam na faixa de micro-ondas (OLIVEIRA, 2013).

O sensoriamento remoto permite obter informações sobre a superfície da Terra sem contato físico direto entre sensor e alvo. Observa-se interações entre a radiação e o alvo de interesse. Usa-se energia através de radiação eletromagnética (REM), para o

sensoriamento remoto, apresentando como características essenciais à frequência (ν) e o comprimento de onda da radiação (λ). Os sensores ativos emitem energia e medem as propriedades de sinais que retornam para o equipamento, depois de absorver, refletir e espalhar as informações sobre o alvo imageado (OLIVEIRA, 2016).

Diferente de imageamento óptico, o retroespalhamento do radar, pode ser influenciado pela topografia do terreno. Tendo interferência no sinal por causa da geometria e rugosidade encontradas no terreno pois, a forma de emissão da onda é refletida pelo objeto que é determinante quantitativo de energia que vai voltar para a antena. Na qual há filtros espectrais adaptativos usados para diminuir efeitos que podem surgir quanto a interferência da radiação nos alvos (FROTA, 2019). Por isso é muito importante conhecer como as micro-ondas interagem com os alvos de interesse para obtenção de informações desejadas (FORMAGGIO; SANCHES, 2017).

Por meio do uso de radares de abertura sintética (SAR) é possível aumentar a resolução espacial da imagem do alvo, independente da altitude da plataforma, nesse sentido permite a obtenção de imagens bidimensionais de alta resolução, que não dependem da luz do dia, cobertura de nuvens e condições atmosféricas. É possível o aumento de resolução do imageamento devido ao sistema ativo de micro-ondas que sintetiza o processador de sinal através de uma antena com grande tamanho (OLIVEIRA, 2016).

Há novos sistemas e sensores lançados frequentemente para garantir mais confiabilidade de informações. Tem-se como exemplo a constelação o Copeérnicus, um sistema europeu que tem como objetivo monitorar a Terra, na qual possui subsistemas que fazem coletas de dados de múltiplas fontes, onde seus serviços estão relacionados a temas ambientais e segurança. A resolução espectral depende do alvo, que implicará em distintos e específicos comportamentos em relação à sua interação com REM (FORMAGGIO; SANCHES, 2017).

O comportamento do alvo, serve como características de identificação quando obtidos por sensores remotos. Além disso, alguns alvos possuem grande facilidade de serem discriminados, como a água, solos e vegetação, com auxílio de bandas espectrais, já outros, como grupos específicos de classificação quanto ao tipo de solo e vegetação, nem sempre há uma facilidade de discriminá-los. Demandando intervalos espectrais mais estreitos. Visto isso, as variações de largura de bandas espectrais quanto a sua posição ao longo do espectro REM, pode ser classificado quanto ao número de bandas com alta resolução e baixa resolução (FORMAGGIO; SANCHES, 2017).

2.2- Software SNAP™

O SeNtinel *Application Platform* (SNAP), é um software livre e de código aberto (FOSS - Free and Open Source Software) utilizado para processar e analisar imagens digitais pela multiplataforma disponibilizado pela Agência Espacial Europeia (ESA) da missão Sentinel. Foi desenvolvida pela ESA e outras empresas, como *Brockmann Consult*, *Array Systems Computing* e C-S. (ESA, 2022).

A imagem de satélite sempre precisa de um tratamento inicial para corrigir as distorções que possam conter. O SNAP pode corrigir as possíveis distorções atmosféricas que associadas às imagens em análise. É caracterizado por apresentar um conjunto de ferramentas que auxiliam na utilização, visualização e processamento de dados de Detecção Remota. A função deste software, podem ser obtidas pela caixa de ferramentas do Sentinel, complementam suas funções de manuseio de dados resultantes dos satélites de observação da Terra (NANDAIA, 2020).

Há pesquisas voltadas para a viabilidade econômica do ensino e uso das técnicas de sensoriamento remoto por meio de imagens de satélite, que estão sendo disponibilizadas gratuitamente como as imagens do SAR Sentinel-1, imagens ópticas Landsat-8, e o sistema de processamento digital de imagens SNAP (DIAS; MENDONÇA, 2020). O SNAP possui ferramentas específicas para processar, estimar métricas de intensidade e coerência interferométrica do satélite Sentinel (BARBOSA et al., 2021).

Geralmente o ruído *speckle* é um dos responsáveis pelas distorções radiométricas em imagens de radar. Isso ocorre devido a interferências nos sinais de retorno ocasionada pelos elementos de alvo da superfície, dessa forma pode gerar um fenômeno ruidoso, que se apresenta nas intensidades dos pixels, provocando variações no padrão granular da imagem dificultando a interpretação (PENNA, 2014).

Além disso, a aplicação de filtros específicos é necessária para o tratamento do ruído *speckle*, na qual os mais usados são os *Lee*, *Frost*, *Gamma*, dentre outros. A mudança da tecnologia dos Radares imageadores de abertura real (RAR) para os Radares de abertura sintética (SAR), ocorreu para se ter uma melhor resolução azimutal. Na qual os Radares orbitais são recursos tecnológicos muito completos, bastantes utilizados atualmente, para extrair informações, tendo como aliado o sensoriamento remoto, permitindo a elaboração de diagnósticos ambientais (DIAS, 2020).

2.3. Imagens Sentinel 1-A

O sensor SENTINEL 1 faz parte do programa *Copernicus* da Agência Espacial Europeia (ESA), que conta com 6 missões diferentes abrigando várias faixas do espectro eletromagnético, de forma gratuita e sem hiato. É composta por uma constelação de dois satélites (Sentinel 1A e 1B) que usam sensores de radar, através das series temporais permite-se obter informações não disponibilizadas em sensores óticos (SALGADO, 2019).

Desde 2015, a ESA (*European Space Agency*) disponibiliza imagens de satélite com alta resolução espacial. O Sentinel 1A foi lançado em 2014, com a banda C do radar SAR, as suas imagens possuem várias aplicações, como o mapeamento da cobertura da terra. Além disso, possui operação nos modos *Interforometric Wide Swath* (IW) e *Mode Wave* (WV) (MONTEIRO, 2019). As unidades da missão Sentinel contam com SAR, com ângulo de incidência de 29,1° à 46,0°, opera na banda C com frequência de 5,405 GHz (COSTA, 2021).

As imagens SAR geradas pelo satélite Sentinel-1 possuem resolução espacial de 10 metros e com intervalo de tempo de doze dias, mas pode-se obter no intervalo de seis dias quando se utiliza as passagens dos satélites Sentinel-1A e Sentinel-1B (CECHIM JÚNIOR et al., 2020). Este sensor suporta polarização simples (VV e HH) e dupla polarização conhecida como dual pol (VV+VH e HH+HV), e *full pol* ou *quad pol*. Dessa forma, pode transmitir e receber radiação de micro-ondas em duas polarizações, permitindo mais informações em relação a rugosidade da superfície e o arranjo geométrico dos componentes do terreno (COSTA, 2021).

2.4. Modo de imageamento IW e banda C

O radar é um sensor que usa a fonte de radiação eletromagnética artificial, que usa a região das micro-ondas para obtenção de imagens, considerada sensor ativo, pois emite uma baixa quantidade de radiação eletromagnética para região espectral. Quando comparado aos sensores óticos e termais tem como vantagem o grande comprimento das micro-ondas que permite obter imagens, mesmo quando há cobertura de nuvens, tendo em vista que o, imageamento pode ser feito a qualquer momento do dia e da noite. Mas quanto a escolha do comprimento de onda deverá ser compatível com o tamanho das feições do alvo de interesse (MENESES et al., 2012).

O comprimento de onda serve para determinar uma propriedade macroscópica do terreno, que em relação ao radar é conhecida como rugosidade da superfície. Na qual pode ser lisa ou rugosa. Numa imagem com superfície rugosa há um retorno do sinal de retroespalhamento, deve-se levar em consideração que o tamanho da onda deve ser menor devido às variações de altitude da superfície. Já em uma superfície lisa quando não há o retorno do sinal retroespalhado em direção à antena, o tamanho da onda é às vezes maior que as variações de altitude da superfície. Os alvos com refletores de canto são conhecidos como fenômeno *double bounce* (MENESES et al., 2012).

As radiações emitidas por sensores ativos são conhecidas como bandas e reconhecidas por letras, que quanto ao comprimento das suas ondas, se for menor estará sujeita a um maior nível de interferência atmosférica (DIAS, 2020). Satélites com SARs seguem órbitas síncronas e os sistemas mais comuns utilizam comprimento de onda (λ) nas bandas X (3 cm), C (5 cm) ou L (23 cm) (PARADELLA et al., 2015). A banda C foi fornecida, por meio de programas espaciais da União Europeia e o satélite canadense RADARSAT-2. Vem sendo muito utilizada para estudo de respostas polarimétricas com diferentes usos e coberturas da terra em floresta tropical amazônica no Brasil (SERVELHO, 2010).

Os dados do satélite Sentinel-1 (banda C) tornaram-se disponíveis desde 2015, na qual tornou-se um grande aliado a pesquisas por causa do seu potencial, dando ênfase para regiões tropicais (DINIZ, 2019). Independentemente do tipo de polarização, os coeficientes de retroespalhamento terão seus valores maiores quando apresentarem uma estrutura de vegetação maior (FREITAS et al., 2014). O modo de imageamento por *Interferometric Wide Swath* (IW) é o padrão de aquisição de dados terrestres da missão Sentinel, além disso possui uma faixa de 250 km com resolução espacial de 5 x 20 metros (COSTA, 2021).

2.5. Polarização

No radar, para ocorrer a polarização é necessário que um pulso de energia seja emitido por uma antena, para que o vetor de campo elétrico possa ser controlado por um cristal polarizador, onde sua transmissão pode estar situada na horizontal (H) ou na vertical (V), dessa forma a onda é chamada de polarizada. Mas depois que o pulso atinge o alvo ocorre a despolarização, podendo o sinal retornar à antena com intensidade maior em direção diferente quando comparada a da polarização emitida (MENESES et al., 2012).

A polarimetria, nos sistemas SAR classificam-se de acordo com o tipo de polarização escolhida para emitir e receber a onda eletromagnética. Os primeiros satélites SAR eram single pol, pois podem transmitir e receber uma única polarização: horizontal HH ou vertical VV. Contemporaneamente há modos de operação dual pol coerente, que emite polarização do eixo ortogonal e recebe em HH e HV ou VV e VH, já na dual pol incoerente, a transmissão e recepção dos canais HH e VV, na *full pol* ou *quad pol*, emitem e recebem ambas as polarizações ortogonais na qual os dados são gravados (FALQUETO et al., 2021).

Há sensores orbitais de radar que operam com polarizações paralelas e cruzadas como o RADARSAT e PALSAR tendo em vista que se pode obter quatro modos de polarização a HH, HV, VV e V *dual pol* ou *quad pol*, resultando em um aumento de chances da discriminação dos materiais em função das variações de rugosidade da superfície estudada. Na qual a vegetação por exemplo mostra diferentes respostas quanto às respostas das polarizações, isso ocorre, pois, a despolarização da radiação eletromagnética pelos múltiplos retroespalhamentos dos galhos e folhas (MENESES et al., 2012).

2.6. Algoritmos de classificação

A classificação é definida como o processo de extração das informações que neste caso são em imagens para que seja possível reconhecer os padrões e objetos homogêneos, dessa forma o mapeamento das áreas da superfície terrestre correspondem aos temas de interesse. Além disso essa classificação é realizada por escolha de características que se descrevem para ser possível fazer a diferença entre si, podem dividir-se em "pixel a pixel" ou por regiões que utilizam informações espectrais de cada pixel (SARGIMENTO, 2014). A classificação dos trabalhos depende de acordo com os tipos de dados que estão sendo utilizados, variam quanto à sua capacidade polarimétrica de cada imagem (CHO et al., 2021).

A presente pesquisa, adotou a proposta de classificação da tabela do MapBiomias. Classificação de cores que facilita o entendimento do leitor e adotado pelo autor do estudo para mostrar os resultados obtidos por meio das classificações. Somando-se um método dinâmico e processual, com intuito de aperfeiçoar e classificar cada tipologia de uso classificado. (MAPBIOMAS BRASIL, 2021).

O reconhecimento dos padrões dos pixels resulta na classificação das imagens processadas por algoritmos classificadores. Os classificadores são individuais, mas podem ser combinados

em vários classificadores. As imagens SAR contribuem para melhorar a precisão da classificação, identificando o de melhor desempenho.

Contexto em que encontra-se disponíveis distintos classificadores como, *Maximum Likelihood Classifier* (MLC), *Artificial Neural Network* (ANN), *k-Nearest Neighbour* (KNN), *Support Vector Machine* (SVM), *Classification Tree Analysis* (CTA) e *Object-Based Classification* (OBC), e depois faz-se avaliação da acurácia, que indica a qualidade da classificação (LU et al., 2014). Também existem outros classificadores como o *Random Forest*, na qual obteve bons resultados para o mapeamento do bioma Cerrado (CHO et al., 2021). E *KDTree-KNearest Neighbors* (KDT-KNN), *Maximum Likelihood* (ML), Distância Mínima (MD).

3-OBJETIVOS

3.1-Objetivo geral

Classificar e analisar a cobertura do solo com imagens SAR para o município de Açailândia Maranhão no período de dezembro de 2020 a 2021.

3.2-Objetivos específicos

- Criar banco de dados para cidade de Açailândia-MA;
- Diferenciar classes de uso antrópicos e naturais;
- Indicar o melhor classificador da cobertura do solo na região em análise;
- Verificar a precisão e acurácia dos algoritmos para classificação das imagens SAR.

4-MATERIAL E MÉTODOS

4.1-Área de estudo

O estudo foi realizado no município de Açailândia-MA que pertence a microrregião de Imperatriz localizada no oeste do estado do Maranhão. A microrregião de Imperatriz-MA é considerada privilegiada, pois encontra-se num ponto estratégico entre a soja que vem do

sul do estado, a extração de madeira que vem do Pará, a siderúrgias em Açailândia-MA. A microrregião possui o clima tropical superúmido com médias anuais de 1500 mm de chuvas. A temperatura média está entre 24 °C e 29 °C. A vegetação é bastante diversificada com o cerrado, florestas ou matas e os campos (MENEZES, 2009).


Figura 1 - Mapa de localização da área de estudo.



4.1 -Atividade desenvolvidas

As atividades deste trabalho foram divididas em quatro etapas: (1) Construção e manipulação do banco de dados geográficos do município de Açailândia-Ma usando os programas SIG (SNAP; QGIS); (2) Pré-processamento dos dados; (3) Seleção das Amostras de Treinamento (AT), Classificação das imagens e recorte para à área de estudo e (4) Resultado e análise estatística do processamento (Figura 2). Os tópicos a seguir detalham os instrumentos e procedimentos adotados para realizar a pesquisa apresentada.

Fluxograma 1 - Representação dos processos metodológicos seguindo as quatro etapas.



O trabalho adotou o processamento de imagens de radar (SENTINEL-1A) com o tipo de arquivo *Ground Round Detection* (GRD) e detecção de alta resolução em HD de polarização dupla VV-VH e modo de faixa IW, direção de voo do satélite descendente ao hemisfério sul em banda C com resolução espacial de 10 metros/pixels do sensor SAR adquiridos no site da Agência Espacial Europeia (ESA) Copernicus. As imagens utilizadas pertencem ao intervalo de dezembro de 2020 a dezembro de 2021, na qual fez-se uso de doze imagens, visto que as datas são referentes ao período chuvoso, a transição entre o chuvoso e o seco, e período seco, como mostra a Figura 3.

Tabela 1 - Datas que as imagens Sentinel 1A foram selecionadas para execução do trabalho.

DIA	MÊS	ANO
27	dezembro	2020
08	janeiro	2021
25	junho	2021
07	julho	2021
28	novembro	2021
10	dezembro	2021

4.3 -Pré-processamento

Para a classificação, as imagens passaram por correções no programa da (ESA) denominado SNAP™ (*SeNtinel Application Platform*). A correção envolve aplicação de órbita, calibração para sigma zero (*Módulo Calibrate*), correção de terreno e definição da projeção (*Range doppler terrain correction*) com o uso de Projeção Universal Transversa de Mercator (UTM) e o sistema de projeção SIRGAS 2000 UTM zona 23S. O pré-processamento de sinal em radar tem como função reduzir distorções radiométricas, geométricas e corrigir as imagens SAR. Considerando as aplicações no programa SNAP, com ferramentas específicas para processar e estimar as métricas de intensidade e coerência interferométrica do satélite Sentinel 1 (BARBOSA et al., 2021).


Este programa apresenta ainda a possibilidade de filtragem do *speckle* em bandas separadas (*single product speckle filter*) ou *multitemporal* (*multi-temporal speckle filter*), na qual foi utilizado o filtro Lee Sigma e com duas calibrações para sigma zero (07-05) aplicando-o na polarização dupla VV-VH. São disponibilizados vários tipos de filtros, entre eles, Mediana, *Lee*, *Refined Lee*, *Frost*, dentre outros (SALGADO, 2019).

Com as imagens e arquivos baixados, as imagens SAR terão que passar por um procedimento de correção que será feito no programa SNAP™, no qual vai ser aplicado o coeficiente de retroespalhamento dos dados de quadratura. Seguindo as etapas de processamento com os primeiros passos realizou-se a aplicação de órbita do arquivo (*apply orbit file*), que segundo Rodrigues (2018), esta aplicação serve para atualizar informações de metadados de órbita, que realiza uma restituição, remoção de ruídos termais podendo remover faixas escuras próximas às bordas da cena. Na qual prosseguirá com a calibração em sigma zero (*Calibrate*) que de acordo com Barbosa et al. (2020) tem o objetivo transformar os valores de retroespalhamento, em níveis digitais (ND) para sigma (σ) e depois em níveis de decibéis (db). Posteriormente fez-se remoção do ruído termal (*Thermal noise removal*), e a aplicação do filtro *Lee Sigma* com uma matriz de 5 x 5 e o valor de *sigma* de 0,7 e posteriormente a correção do terreno.

Para assim, conseguir reduzir o efeito *speckle* inerente a dados SAR. Pois, se o processo não for executado pode causar uma diferenciação nos valores de retroespalhamento que pode não está relacionada a mudanças reais de objetos na paisagem, ocasionando o padrão granulado do tipo “sal e pimenta”. Sendo necessário a transformação original das imagens,

projetada *slant-range* para uma grade regular, chamado de *multilooking* (BARBOSA et al., 2021). O Fluxograma 2 demonstra as etapas de pré-processamento para as imagens.

Fluxograma 2 - Etapas de processamento das imagens de SAR.



4.4 - Processo de classificação

Com as correções e processamento das imagens SAR realizadas prosseguiu-se com a utilização da ferramenta *Coregistration* posteriormente a aplicação de filtro em várias cenas “multi temporal *speckle filter*” e logo em seguida fez-se a transformação das cenas em decibéis (dB), que de acordo com Barbosa et al. (2020) essa etapa garante melhor representação dos valores no intervalo de distribuição de frequências das imagens, a partir de sua expansão. Todo o processo é disponibilizado pelo SNAP™. Contudo a utilização da aplicação da função “*multi-temporal speckle filter*” teve como intuito reduzir o ruído natural das imagens, em contrapartida foi utilizado o filtro *Lee Sigma* com a matriz de 5 x 5, mas com o valor do sigma para 0,5 com intenção de suavizar as imagens de modo padrão.

Em seguida, realizou-se a seleção dos vetores, na área de estudo (Figura 2). Para analisar os quatro algoritmos de classificação supervisionada, foi selecionado as classes criando vetores, ou AT (Figura 3), a saber: A-corpos hídricos; B-floresta plantada; C- infraestrutura urbana; D-agricultura; E-área não vegetada; F-pastagem; G-floresta natural e H- geometria


A partir da aferição das AT, testou-se os algoritmos classificadores de *Random Forest* (RFC), *KDTree-KNearest Neighbors* (KDT KNN), *Maximum Likelihood Class* (MLC),


Distância Mínima (MD). Adotando a metodologia indicada por Salgado (2019), porém ao invés de utilizar KNN usou-se o KDT KNN, devido seu desempenho.

Figura 2 - Imagem geral sem recorte do município de Açailândia-Ma, utilizada para criar os vetores da classificação supervisionada.




Figura 3 (A, B, C, D, E, F, G e H) - Representação dos vetores de cada classe (A-corpos hídricos; B-floresta plantada; C-infraestrutura urbana; D-agricultura; E-área não vegetada; F-pastagem; G-floresta natural e H- geometria).





Para apresentação em das imagens classificadas utilizou-se a paleta de codificação das cores indicadas pelo Projeto Map Biomas, indicativa das classes: agricultura, corpos hídricos, floresta natural, floresta plantada, geometria, infraestrutura, pastagem e áreas não vegetadas (MAPBIOMAS, 2022). Após a classificação das imagens houve a conversão de BEAM-DIMAP para camada *raster* que usa o formato (.tif), necessário para o processamento das imagens no QGIS. O Fluxograma 3 refere-se aos procedimentos para a classificação das imagens.

Fluxograma 3 - Montagem do processo para a execução dos algoritmos de classificação das imagens de radar.



4.5-Dados estatísticos

Para validação dos dados obtidos pelo processamento das imagens, usou-se a correlação cruzada obtida pelo próprio SNAP, os dados selecionados foram, acurácia, precisão, correlação e erro. Tendo em vista que, foram gerados em cada algoritmo de classificação. Após a validação, eles foram utilizados para a criação dos gráficos de barras, além disso, para demonstrar o comportamento das variáveis fez-se um gráfico com o intuito de verificar o valor da intensidade usando a polarização simples VV e a dupla polarização VV e VH em duas datas diferentes aplicadas nos períodos estudados.

5-RESULTADOS E DISCUSSÃO


O processamento do estudo fez uso de oito classes seguindo seus quatro respectivos algoritmos de classificação, obtendo-se doze imagens como detalhado na metodologia do trabalho. As etapas de correções executadas devem ser consideradas de extrema importância pois, de acordo com Meneses et al. (2012) os baixos contrastes espectrais de retroespalhamento da radiação eletromagnética dos alvos de referências, são um problema encontrado por alguns pesquisadores que devem ser cuidadosos com os processamentos computacionais para extrair a informação no limite mais ideal de análise. Tendo em vista que as ondas emitidas pelos sensores Sar, ao se encontrar com o alvo de interesse na superfície terrestre, refletem na rugosidade e produz diferentes formas de retroespalhamentos, dependentes da natureza física do alvo (MARQUES, 2017).

As variações dos pixels nas imagens geradas para os meses de dezembro de 2020 e janeiro de 2021 apresentaram resultados e comportamentos aleatórios, possivelmente relacionada com o começo do período chuvoso na região. Na qual mostrou-se com eficiência apenas as classes de mata nativa assim como as atividades de reflorestamento, pois de acordo com Salgado (2019) após a precipitação as classes envolvendo a vegetação e área não vegetada podem apresentar dispersões tornado as imagens semelhantes, além disso as florestas plantadas ou vegetação alterada é uma classe que apresenta distorções em dados orbitais se misturando com outras como área de como de cana-de-açúcar, usos antrópicos e floresta.

Visto que esse processo tem tendência a reduzir o espalhamento dos pulsos emitidos pelo radar, diminuindo a área de demonstração da classe citada e aumentando o efeito de

mistura dos vetores por causa das rugosidades das florestas. De acordo com Cougo (2019) o radar tem capacidade de penetrar no dossel através das micro-ondas, além disso à sensibilidade do retroespalhamento quanto ao conteúdo de água da vegetação. Resultando em uma reflexão especular da água isso ocorre devido ao efeito de reflexão de canto o *double-bounce* (NUNES et al., 2009). Além disso, o retroespalhamento volumétrico é considerado a principal fonte de radiação de polarização cruzada (HV ou VH), tendo em vista que a energia é rebatida diversas vezes antes do seu retorno para sensor (COSTA, 2021).


Figura 4 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açaílândia-MA para os meses de dezembro de 2020 e janeiro de 2021.



A classe corpos hídrico obteve maior destaque no estudo quando comparadas as demais classes. De acordo Chelotti (2017), é vantajoso monitorar corpos hídricos por imagens de satélite quando comparados aos das estações hidrológicas, pois é possível monitorar toda a superfície do corpo d'água, mas é dependente da resolução temporal do satélite que será utilizado. Entretanto, na Figura 4 os corpos hídricos não se destacaram, devido ao baixo nível de retroespalhamento, o que ocasiona uma variação maior dos pixels em relação a reflectância. Isso pode estar relacionado com a explicação de Salgado (2019) que a rugosidade da floresta gera um efeito de sombra resultando na confusão da classe de corpos hídricos.

As classes da floresta natural, floresta plantada, e geometria, apresentaram uma melhor distinção, porém as classes pastagem e agricultura obteve um imageamento mais instável para o retroespalhamento o que mostra nas Figuras 5 e 6 uma exatidão com comportamento inferior em relação aos pixels, além de uma razoável representação da infraestrutura urbana a qual é mais representada em pigmentos. Porém a dispersão da classe geometria e infraestrutura urbana se tornou mais densa onde a diferença é quase imperceptível, exceto pela à área de ocupação, o que nos mostra que houve uma sobreposição entre as classes. Também não há presença dos corpos hídricos na Figura 4 apesar de estar no começo do período das chuvas na região da área de estudo.

Figura 5 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açailândia-Ma nos meses de junho e julho de 2021.




Na Figura 5, as imagens tendem a ser mais nítidas, justamente por haver um melhor controle do efeito do tipo *double bounce* o que influencia o retroespalhamento quanto a sua área de expansão devido ao baixo índice de sombra está relacionada a superfície mais plana, ou seja, uma uniformidade entre as vegetações. Com o aumento da reflectância na área se tornou mais puro e percebeu-se um aumento na precisão, acurácia e diminuição do erro entre as classes em relação às imagens da Figura 4, como também há uma grande diferenciação

entre a utilização dos algoritmos testados se destacando como melhores classes a agricultura e floresta plantada natural como também apresenta diferença para pastagem e vestígios de corpos hídricos mais evidentes na Figura 5 (A, B e D), entretanto a floresta natural não fica tão perceptível quanto às demais classes.

De acordo com Meneses et al. (2019) a iluminação, sensor, vegetação e o solo são variáveis que afetam a refletância dos dosséis, que geralmente não apresentam fácil mensuração. Para se definir a arquitetura do dossel é necessário a distribuição dos elementos da vegetação, como no caso do reflorestamento é dependente dos arranjos do plantio e a vegetação natural da topografia que pode implicar no sombreamento e na altura do dossel, quanto a sua distribuição espectral.

De acordo com Moreira (2001) a reflectância expressa no pixel do alvo tende a ter um maior brilho ou maior área de ocupação. Dessa forma um determinado alvo, pode apresentar outros tipos de alvos com menor expressão. Tornando o erro inevitável, entretanto pode ser diminuído com o uso de sensores com melhores resoluções espaciais. Como os mapas representam planos reais deve-se ter confiabilidade estatística, para precisão, exatidão do mapeamento, que possa ser aceita pela comunidade.


Figura 6 (A, B, C e D) - Imagens geradas pelo programa da ESA para o município de Açailândia-Ma nos meses de novembro e dezembro de 2021.



Enquanto na Figura 6, o comportamento dos pixels foi semelhante em relação a Figura 5, o que mostra que os períodos a quais estão sujeitos à análise acabam que se tornam diretamente interligados, apresentando pequenas variações, e em setores que não há alterações, mantendo-se os resultados próximos. Porém o destaque da floresta plantada e pastagem se tornaram mais nítidas em relação às outras figuras, pois observamos que por ainda ser o início do período chuvoso, observa-se que o solo e a vegetação ainda estão secos, influenciando diretamente no retroespalhamento e as reflectâncias dos alvos, tornando as classes mais nítidas com exceção da infraestrutura urbana e as áreas não vegetadas que permanecem com seus valores individuais de acordo com o período citado.

A classe da agricultura, foi perceptível, porém se comportou de maneira dispersa, mas para cada imagem gerada houve características diferentes quanto a questão do retroespalhamento e o efeito *double bounce* onde apresentou maior expressividade no período de dezembro de 2020 a janeiro de 2021, levando em consideração ao estudo de Meneses et al (2019), o aumento da umidade do solo diminui a reflectância. Já para infraestrutura urbana a sua presença ficou de certa forma alinhada nas imagens, porém de uma forma menos perceptível visualmente, devido a sua classificação e menor efeito negativo em seu vetor de seleção, o que não é caso de geometria e área não vegetada que apresentou grande sobreposição entre as camadas, ou seja, os alvos em que a confusão com a reflectância e retroespalhamento são mais aparentes, o que influencia na hora de gerar classificação.

Figura 7 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de dezembro de 2020 e janeiro de 2021.




As classes de floresta natural, floresta plantada, geometria e área não vegetada, foram as mais instáveis nesse período (Figura 7 - A, B, C e D) apresentando um erro maior entre 6,37% a 26,32%, onde os classificadores *Random Forest* e Distância Mínima, para essas classes foram as que mais obtiveram o erro chegando em torno de 25,14% e 26,32%, com exceção do classificador *Maximum Likelihood* que obteve 100 % de exatidão para floresta natural.

No período de dezembro de 2020 a janeiro 2021 o êxito ocorreu para quatro classes, verificando também que a pastagem entre todas as outras classes, é a que mais apresenta resultados positivos, pois se encontra com valores mais expressivos nos quatro algoritmos de classificação, isso ocorre, devido sua uniformidade na área o que facilita o retroespalhamento na mesma. Entretanto dentre todas as classes a mais efetiva com 100% de exatidão é a corpos hídrico.

De acordo com Jesus e Kuplich (2021) as avaliações realizadas no período chuvosa e no período seco permite uma maior compreensão da variabilidade do retroespalhamento, porém no período chuvosa foi observado um maior retroespalhamento nas polarizações HH e HV relacionado a maior constante dielétrica, e também devido ao maior volume da vegetação, em contrapartida para estação seca destacou-se uma exposição do solo. Além disso, o retroespalhamento não depende do tipo de polarização, pois quanto maior a estrutura da vegetação, maior será o retroespalhamento.

Figura 8 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de junho e julho de 2021.




Os resultados dos classificadores apresentados em A e B se assemelham-se a Figura 7, porém na Figura 8 também é perceptível que a classe agricultura teve uma redução em ambas as análises para ficar com valores de 45,42% a 69,64% para precisão e 55,31% a 70,61% na correlação, o que também influenciou para o crescimento do erro que variou 4,67% há 9,64% o que é um efeito significativo comparado ao anterior, porém a acurácia teve um decréscimo com variações de 90,36% a 95,08%.

As demais classes (Figura 8) com exceção de corpos hídricos que permaneceu com valores de 100%, porém no classificador *Random Forest* e *KDTree KNN* a pastagem obteve valores de 100%, perdendo eficiência apenas no classificador Distância Mínima. Para as demais classes observamos que houve efeito no classificador *Maximum Likelihood* para floresta plantada e geometria com valores de porcentagem próximos de 100%, tendo em vista que nas duas classes a variação do erro permanece em torno de 5%.

Nas demais classes (Figura 8) os valores ficaram mais instáveis principalmente em relação a floresta natural e infraestrutura urbana, sendo que no classificador Distância Mínima, obteve sua eficiência para classe de infraestrutura ficou em 100% em todas as análises executadas. De acordo com Barbosa et al. (2021), afirma que essas áreas possuem dupla ou tripla reflexão de quanto à interação com objetos de superfícies planas e ortogonais inerentes como as fachadas de prédios, permitindo o efeito *double-bounce*, favorecendo a identificação desses alvos.

Figura 9 (A, B, C e D) - Gráfico de barras representando valores de acurácia, precisão e erro, obtidos pela correlação cruzada de cada algoritmo de classificação no período de novembro e dezembro de 2021.




Observa-se (Figura 9) que o desempenho dos classificadores não supervisionados nesse período leva em consideração o final do período chuvoso e o começo do período seco, tornando mais preciso quanto a questão da instabilidade dos valores obtidos, isso quer dizer que os pixels nas imagens tiveram um efeito mais significativo, na qual o período mais seco tende a influenciar no retroespalhamento de maneira mais ampla, pois de certa forma, o efeito de sombreamento em relação ao retroespalhamento diminui, induzindo uma melhor refletância no local.

Na Figura 9, os valores de agricultura, corpos hídricos, infraestrutura urbana e pastagem obtiveram o mesmo valor em relação a Figura 7, pois as mesmas classes tiveram valores significativos nos classificadores *Random Forest*, *KDTree KNN* e *Maximum Likelihood*, porém só não houve êxito na infraestrutura urbana no classificador *Maximum Likelihood* na Figura 9-B, em relação às quatro classes citadas.

A demais classes (Figura-9) continuaram com grande dispersão, com uma instabilidade maior, apresentando variações de erro nos quatro algoritmos de classificação usados no trabalho. Além disso, é frequente nas classes de floresta natural, floresta plantada e geometria, isso ocorre devido a sobreposição dos pixels, causado pela interferência do sombreamento, como também a alturas das vegetações em função do relevo, o que diminui o retroespalhamento. Tendo em vista que de acordo com Marques (2017), as diferentes feições do alvo na superfície são determinantes para as características de retorno da onda refletida. Na qual as superfícies lisas geralmente apresentam imagens escuras, pois o retroespalhamento é especular, já as superfícies rugosas apresentam-se mais claras, visto que o retroespalhamento é de forma multivariada.

Quando envolve o sombreamento das vegetações a taxa de refletância diminui diferentemente da classe corpos hídricos que aumenta a taxa de refletância, criando uma confusão dentro das demais classes, dispersando os valores reais de referência. Além disso, foi notado que houve nesse período (Figura 9-A) uma perda significativa, nos valores de acurácias para as demais classes apresentando valores 98,49% (floresta natural) a 85,04% (floresta plantada) usando *Random Forest*, 96,82% (floresta natural) a 89,25% (floresta plantada), *KDTree KNN* 95,48% (floresta natural) a 73,97%(geometria), *Maximum Likelihood* 95,8% (floresta natural) a 67,51% (geometria) para Distância Mínima, isso mostra que houve uma sensibilidade na precisão dos dados.


Figura 10 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de dezembro de 2020 e janeiro de 2021.



Na Figura 10, observamos diretamente a dispersão dos pixels de uma forma mais ampla, os valores do eixo X que vai desde 5 positivo ao 25 negativo, onde esses valores representam a intensidade em que aqueles pixels estão representados na área, os valores no eixo Y que vão de 10 positivo ao 32,5 negativo. Dessa forma, a primeira superfície que se encontra no centro do gráfico possui dados que representa características de alvos com comportamento mais sólidos, como a vegetação nativa ou atividades antrópicas, porém à medida que aumenta os valores no eixo Y, a dispersão tende a aumentar.

A gura 10 (A e B) representa uma ótima avaliação das classes usadas no trabalho onde a agricultura, corpos hídricos, infraestrutura urbana, pastagem e área não vegetada e as demais classes são bem representadas em relação a entrada do período chuvoso na região. Isso mostra que o retroespalhamento estar inteiramente ligados à questão da intensidade dos pixels na área selecionada.

Figura 11 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de junho e julho de 2021.





Para a Figura 11 (A e B) os valores são mais concentrados que na Figura 10 (A e B),

onde para o eixo X percebe-se uma variação desde o 17,5 dB a -25 dB a qual se manteve padrão para o eixo Y. Onde a concentração dos dados está em torno -25 dB a 0 dB para X e Y, à medida que se eleva os valores simultaneamente se aumenta a concentração dos dados até aproximadamente 1,7dB, depois desse valor os pixels tendem a se afastar com mais frequência, ou seja, se dispersa entre os valores 5 a 17,5 dB. Esse fenômeno descrito comparado ao anterior está mais estável, o que explica a melhor uniformidade nas classes, quanto a questão do aumento gradual da precisão, correlação e diminuição do erro. Esse processo está relacionado também à questão do retroespalhamento, que de certa forma foi mais eficiente que o começo do período chuvoso na região entre dezembro de 2020 e janeiro de 2021.

Também através da Figura 11 (A e B), é possível determinar que os efeitos tiveram uma coexistência única, o que mostra que o retroespalhamento juntamente com a reflectância tiveram comportamento estáveis assim como o efeito *double-bounce*, isso pode estar relacionado com o nível de radiação na área, devido está passando por um período de transição, acaba que as interseções criadas pelas condições climáticas ao mesmo tempo que não interfere na emissão dos pulsos do radar, favorecendo um melhor captação dos pixels. Portanto, as variáveis estão correlacionadas com o aumento da intensidade dos pixels no alvo, podendo variar de acordo com o efeito predominante que está atuando na área, na qual influencia diretamente nos valores de resposta observados nos vetores de cada classe, levando em consideração o efeito de cada classificador nas amostras selecionadas.

Figura 12 (A e B) - Gráfico de dispersão representando valores intensidade obtidos pela ferramenta Scartt plot disponibilizada pelo programa da ESA SNAP™ no período de novembro e dezembro de 2021.





Na Figura 12 (A e B), a dispersão dos dados segue o mesmo formato da Figura 10, porém é notório que a variação é menor, onde observa-se que a intensidade no eixo X varia de 0 a -27,5 dB e no eixo Y varia de 2,5 dB a -32,5dB, desta forma a agregação dos valores dispersos tendem a maior instabilidade em valores negativos baixos no eixo X e valores inferiores negativamente no eixo Y. A representação do ponto de massa de maior valor está relacionada às classes que apresentam vegetação mais adensada ou condensada de maneira que a resposta dos alvos está correlacionada igualitariamente.

O comportamento das polarizações simples (VV), e dupla (VV e VH) são semelhantes em termos de aparência só que uma tem o volume maior do que a outra, porém em modo geral a intensidade da dupla polarização na Figura 12-A tende-se a se igualar com a Figura 10-A, só que na última Figura 12-A observa-se melhor a dispersão dos valores.

Porém a borda da massa de dados, está relacionada às classes com maior reflectância ou mesmo retroespalhamento, dentre elas a classe de área não vegetada ou infraestrutura urbana, e acima desses valores observamos os dados que corresponde a superfícies com mais variações quanto a sua posição, como a classe geometria, que apresentou maior erro em quase todos os períodos estudados.

A época de avaliação está relacionada a questão da resposta dos alvos, ou seja, de acordo com o processo em que está sendo executado, pode haver ou não sobre posição dos alvos, visto que, a presença de área com topo sequências mais abundantes como é o caso da região de estudo tendem a ter maior instabilidade, no que diz respeito à altura da vegetação que influencia diretamente no efeito de sombreamento.

6-CONCLUSÃO

O presente trabalho obteve resultados satisfatórios no que diz respeito a classificação do uso do solo utilizando imagens SAR (Sentinel 1-A) para os algoritmos classificadores. Também foi evidenciado que as condições climáticas e o incremento da vegetação/fase fenológica no período chuvoso geram grande dispersão dos pixels o que resulta em um maior erro, quando relacionada às variáveis de avaliações do trabalho acurácia, precisão e erro, ou seja, o período não chuvoso é o melhor período para executar tais avaliações.

Quanto aos algoritmos de classificação, nos períodos de estudo a melhor eficiência foi o *KDtree KNN* e o *Random Forest* de junho a julho com exatidão em 5 classes, corpos hídricos, floresta plantada, geometria, infraestrutura urbana e pastagem. Enquanto para as classes a melhor foi corpos hídricos e pastagem, dentre as 12 imagens geradas 12 foram expressivas para corpos hídricos e 10 para pastagem.

Por fim, com análise dos *Scatter plot* foi possível observar valores constantes para as todas as classes apresentadas, e ainda as polarizações simples (VV) e dupla (VV e VH) se comportaram de modo semelhante, porém a polarização dupla (VV e VH) indicou junção das variáveis, ou seja, os pixels agrupados tiveram retorno mais significativos do que na polarização simples (VV). Sendo assim, apresentou diferenciação satisfatória entre as classes.

7-CONSIDERAÇÕES FINAIS

Realizar este trabalho foi um grande desafio pessoal e profissional, tendo em vista que a acromatopsia, é um fator limitante rotineiro. Desde a infância, sendo filho de lavrador, com dificuldades de identificar as cores, na qual está dificuldade foi aumentada durante a graduação, pois as cores estavam presentes em todos os locais, desde pincéis a marcadores coloridos limitando a identificação. Para trabalhar com imagens de RADAR fez-se necessário muitos estudos, pesquisas, teste de metodologias para verificar o comportamento e resposta do RADAR, mas quando chegou na metodologia de classificação a dificuldade foi maior, pois todo estudo não serviu para o desenvolvimento do presente trabalho, apenas para conhecimento pessoal. Além disso, para trabalhar com todas as imagens fez-se necessário criar uma metodologia usando imagens com cores preto, branco e cinza opção disponível no notebook, para construções dos vetores.

REFERÊNCIA

ALENCAR, B. P. B. **Análise de áreas de sombras em imagens ALOS/PALSAR**. 2013. 74f. Dissertação (Mestre em Ciências Geodésicas e Tecnologias da Geoinformação) - Universidade Federal de Pernambuco, 2013.

BARBOSA, F. L. R. **Potencialidades e limitações das novas tecnologias de sensoriamento remoto aplicado no ambiente urbano do Distrito Federal**. 2021. 69 f. Tese (Doutorado em Geografia) – Universidade de Brasília, 2021.

BARBOSA, F. L. R.; GUIMARÃES, R. F.; CARVALHO JÚNIOR, O. A. GOMES, R. A. T. Classificação do uso e cobertura da terra utilizando imagens SAR/Sentinel 1 no Distrito Federal, Brasil. **Sociedade & natureza**, Uberlândia. v.32, n.1, p.1-18, 2020.

BARROS, D. L. **Identificação de padrões de uso do solo urbano em São Paulo/SP utilizando parâmetros de variogramas**. 2015. 86 f. Dissertação (Mestre em Ciência) – Escola Politécnica da Universidade de São Paulo, 2015.

CECHIM JÚNIOR, C.; PEREIRA, G. H. A., DEPPE, F.; FRONZA, G. Fundamentos e aplicações de SAR no estudo de mapeamento de uso do solo e de áreas alagadas. In: SUTIL, T.; PEREIRA, J. R.; LADWIG, N. I.; ZOCHE, J. J.; PEREIRA, J. L. **Geoprocessamento na análise ambiental**. 1ª ed. Criciúma: UNESC, 2020, p. (69-80).

CHELOTTI, G. B. **Análise espaço-temporal da concentração de sedimentos em suspensão no reservatório do descoberto (DF), por meio de sensoriamento remoto**. 2017, Dissertação (Mestrado em Geociências Aplicadas) - Instituto de Geociências da Universidade de Brasília, 2017.

CHO, D. F.; SCHWAIDA, S. F.; CICERELLI, R. E.; ALMEIDA, T.; RAMOS, A. P. M.; SANO, E. E. Desempenho do Algoritmo de Classificação de Imagens Random Forest para Mapeamento do Uso e Cobertura do Solo no Cerrado Brasileiro. **Embrapa Cerrados-Artigo em periódico indexado (ALICE)**, 2021.

COSTA, V. L. **Deteção de estágios sucessionais por sensoriamento remoto em fragmentos florestais de Altos de Canguçu-RS**. 2021. 64 f. Dissertação (Mestrado em Sensoriamento Remoto e Geoprocessamento) - Universidade Federal do Rio Grande do Sul, 2021.

COUGO, M. F. **O potencial do sensoriamento remoto SAR no mapeamento, discriminação de gêneros e estudo da dinâmica de floresta de mangue na região Amazônica**. 2019. 131f. Tese (Doutorado) - Universidade Federal do Pará, 2019.

DIAS, J. C. **Elaboração de diagnósticos ambientais com apoio de imagens de SAR Sentinel-1: uma proposta de ensino aprendizagem para cursos superiores relacionados ao meio ambiente**. 2020. 125 f. Dissertação (Mestrado Profissional em Ensino Tecnológico) - Instituto Federal de Educação, 2020.

DIAS, J. C.; MENDONÇA, A. P. A adoção de metodologias ativas, software livres e repositórios gratuitos no ensino do processamento e interpretação de imagens de SAR Sentinel-1. **Revista novas tecnologias na educação**, Rio Grande do Sul, v. 18, n. 1, 2020.

DINIZ, J. M. F. S. **Avaliação do potencial dos dados polarimétricos Sentinel-1A para mapeamento do uso e cobertura da terra na região de Ariquemes-RO.** 2019. 162 f. Dissertação (Mestrado em sensoriamento remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

ESA- European Space Agency. **Caixa de Ferramentas.** Disponível em:< [https:// step.esa. i nt/main/toolboxes/snap/](https://step.esa.int/main/toolboxes/snap/)>. Acesso em: 07 jul. 2022.

FALQUETO, L. E.; PAES, R. L.; PASSARO, A. A importância de dados polarimétricos para detecção de alvos artificiais no mar utilizando imagens SAR. **Aplicações operacionais em áreas de defesa**, São Paulo, v. 22, n.1, p. 53-58, 2021.

FORMAGGIO, A. R.; SANCHES, I., D. **Sensoriamento Remoto.** 1º ed: Oficina de textos, 2017, 85 p.

FREITAS, D. M. de; SANO, E. E.; SOUZA, R. A. de. Potencial das imagens multipolarizadas do satélite ALOS/PALSAR na discriminação de cobertura vegetal do bioma pantanal: estudo de caso na região do médio Taquari, MS. **Revista Brasileira de Cartografia**, Uberlândia, v. 66, n. 2, p. 209-221, 2014.

FROTA, S. M. N. **Relação entre área de inundação e cota fluviométrica na sub-bacia do Alto Rio Negro: uma análise baseada em dados de SAR (Sentinel-1A).** 2019. 52p. Dissertação (Mestre em Geografia) - Universidade de Brasília, Instituto de Geociências, 2019.

GOMES, K. A. S. **Análise dos dados obtidos pelos sensores de trânsito através de séries temporais.** 2021. 52 f. TCC (Bacharel em Engenharia de Computação) - Universidade Federal do Ceará, 2021.

JESUS, J. B.; KUPLICH, T. M. Utilização de imagens SAR na classificação de formações florestais brasileiras. **Ciência Florestal**, Santa Maria,v. 31, n. 3, p. 1547-1568, 2021.

LU, D.; GUIYING LI, E. M.; KUANG, W. A. Comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon. **GIScience & Remote Sensing**, v. 51, n. 6, p.695–709, 2014.

MAPBIOMAS BRASIL- **Mapeamento Anual do Uso e Cobertura da Terra no Brasil. Produtos.** Coleção 6 publicada em agosto de 2021. Disponível em: < <https://mapbiomas.org/produtos>>. Acesso em: 07 jul. 2022.

MARQUES, J. B. **Uso de série temporal de imagens Palsar-2/Alos 2 para classificação de uso e cobertura do solo e detecção de áreas úmidas na região da ilha do bananal, trecho médio do rio Araguaia.** 2017. 72 f. Dissertação (Mestrado em Geografia) - Universidade de Brasília, 2017.

MARTINS, M. H. B. **Dinâmica do uso e cobertura da terra com a utilização de geotecnologias: Estudo na Área de Proteção Ambiental da Margem Direita do Rio Negro, Setor Paduari-Solimões.** 2012. 92 f. Dissertação (Mestre. Área de Concentração: Ciências Florestais e Ambientais) – Universidade Federal do Amazonas, 2012.

MENESES, P. R.; ALMEIDA T.; ROSA, A. N. C. S.; SANO, E. E.; SOUZA, E. B.; BAPTISTA, G. M. M.; BRITES, R. S. **Introdução ao processamento de imagens de Sensoriamento Remoto**. 1 ed. Brasília: UNB, 2012. 276 p. Disponível em: <http://memoria.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso: 21 jun. 2022.

MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Refletância dos materiais terrestres: Análise e interpretação**. 1 ed. São Paulo: Oficina de Textos, 2019. 297 p.

MENEZES, R. H. N., 2009. 188 f. **Caracterização agroclimática e análise do rendimento agrícola do Estado do Maranhão**. Tese (Doutorado) – Universidade federal de Campina Grande, 2009.

MONTEIRO, T. R. R. **Proposta metodológica para mapeamento da cobertura da terra em grande escala no semiárido brasileiro: um estudo de caso em Serra Negra do Norte-RN**. 2019. 2019 f. Tese (Doutorado em geografia) - Universidade Federal do Rio Grande do Norte, 2019.

MOREIRA, A. M. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 1ª ed. São José dos Campos: INEP, 2001. 246 p.

NANDAIA, M. **Interpretação geográfica da classificação do uso e ocupação do solo resultante do processamento e análise de imagens de Satélite**. 2020. 278 f. Tese (Doutorado em geografia) – Universidade Nova de Lisboa, 2020.

NUNES, G. M.; DE SOUZA FILHO, C. R.; FERREIRA, L. G.; VICENTE, L. E. Utilização de Dados SAR R99-B na análise e caracterização de Florestas de Várzea e de Terra Firme em Ecossistemas Amazônicos. In: Simpósio Brasileiro de Sensoriamento Remoto, XIV, 2009, Natal. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, Natal: INPE, 2009, p. 7361-736.

OLIVEIRA, G. V. **Análise do coeficiente de retroespalhamento e classificação do uso do solo de áreas inundadas no Pantanal Norte - MT, por meio de imagens ALOS-PALSAR**. 2013. 76 f. Dissertação (Mestre em Geografia) - Universidade Federal de Mato Grosso, 2013.

OLIVEIRA, S. T. M. **Estimativa de vento utilizando imagens SAR do satélite Sentinel-1 da ESA**. 2016. 36 f. TCC (Bacharelado em Oceanografia) - Universidade Federal do Ceará, 2016.

PARADELLA, W. R.; MURA, J. C.; GAMA, F. F.; SANTOS, A. R.; SILVA, G. G. Radars Imageadores (SAR) orbitais: tendências em sistemas e aplicações. IN: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVII, 2015, João Pessoa. **ANais XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, João Pessoa: INPE, 2015, p. 2506-2513.

PENNA, P. A. A. **Filtragem de ruído speckle em imagens de radar de abertura sintética por filtros de média não local com transformação homomórfica e distâncias estocásticas**. 2014. 173 f. Dissertação (Mestre em ciência da computação) - Universidade Federal de São Carlos, 2014.

RODRIGUES, T. S. **Deteção de desmatamentos no oeste da Bahia com dados de radar (SENTINEL-1A) utilizando a plataforma Google Earth Engine.** 2018. 87 f. Dissertação (Mestrado em Geociências Aplicadas) - Instituto de Geociências da Universidade de Brasília, 2018.

SALGADO, C. B. **Emprego de séries temporais na Amazônia: análise de imagens MODIS e RADAR para mapeamento de uso e ocupação do solo no Estado do Acre.** 2019. 113 f. Dissertação (Doutorado em Geografia) - Universidade de Brasília, 2019.

SARMIENTO, C. M. **Mapeamento e caracterização de áreas cafejeiras utilizando imagens de alta resolução espacial.** 2014. 136 f. Dissertação (Mestre em Engenharia Agrícola) - Universidade Federal de Lavras, 2014.

SERVELHO, E. L. **Dados polarímetros do RADARSAT-2 (banda c) na discriminação de uso e cobertura da terra na região da floresta nacional do Tapajós.** 2010. 95 f. Dissertação (Mestre em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2010.

SILVA, A. G. P. **Integração de imagens ópticas e SAR com processamento em nuvem no mapeamento de uso e cobertura da terra no Cerrado.** 2021. 72 f. TCC (Bacharel em Engenharia Cartográfica e de Agrimensura) - Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2021.

SILVA, Z. F.; ANDRADE, A. C.; BENTO JÚNIOR, F. A.; SOUSA, R. S.; LOIOLA, F. M. L. Características do sistema de produção de leite da Microrregião de Imperatriz, no Estado do Maranhão. **Revista Ciências Agrárias.** Belém Portugal, v. 55, n. 2, p. 92-97, 2012.