



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E
GEODINÂMICA

TESE DE DOUTORADO

Nº 70

Tahisa Neitzel Kuck

Mapeamento da degradação florestal causada pela exploração seletiva de madeira na
Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de
Aprendizado de Máquina

Brasília/DF
2021



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E
GEODINÂMICA

Mapeamento da degradação florestal causada pela exploração seletiva de madeira na
Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de
Aprendizado de Máquina

TAHISA NEITZEL KUCK

Orientador: Prof. Dr. Edson Eyji Sano
Co-orientadora: Profa. Dra. Polyanna da Conceição Bispo

Tese apresentada junto ao curso de Pós-graduação em Geociências Aplicadas (Área de concentração Geoprocessamento e Análise Ambiental) do Instituto de Geociências da Universidade de Brasília para obtenção do título de doutor em Geociências.

Brasília/DF
2021

FICHA CATALOGRÁFICA

Kuck, Tahisa Neitzel. Mapeamento da degradação florestal causada pela exploração seletiva de madeira na Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de Aprendizado de Máquina. Brasília, Instituto de Geociências, Universidade de Brasília, 2021, 143p. Tese de Doutorado.

CESSÃO DE DIREITOS

NOME DO AUTOR: Tahisa Neitzel Kuck

TÍTULO DA TESE DE DOUTORADO: Mapeamento da degradação florestal causada pela exploração seletiva de madeira na Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de Aprendizado de Máquina.

GRAU: Doutor

ANO: 2021

É concedida à Universidade de Brasília a permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Esse direito poderá ocorrer somente após a publicação dos artigos contidos no documento. O autor reserva-se a outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor.

NT128m Neitzel Kuck, Tahisa
Mapeamento da degradação florestal causada pela exploração seletiva de madeira na Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de Aprendizado de Máquina / Tahisa Neitzel Kuck; orientador Edson Eyji Sano; co-orientador Polyanna da Conceição Bispo. -- Brasília, 2021. 142 p.

Tese (Doutorado - Doutorado em Geociências Aplicadas) -- Universidade de Brasília, 2021.

1. Sensoriamento remoto em microondas. 2. Aprendizado de Máquina. 3. Extração seletiva de madeira. I. Eyji Sano, Edson, orient. II. da Conceição Bispo, Polyanna, co-orient. III. Título.

TAHISA NEITZEL KUCK

**Mapeamento da degradação florestal causada pela exploração seletiva de madeira na
Amazônia Legal por meio de dados SAR multitemporais em banda X e técnicas de
Aprendizado de Máquina**

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora
composta pelos seguintes membros:

Prof. Dr. Edson Eyji Sano
Orientador/Presidente

Profa. Dra. Suzan Waleska Pequeno Rodrigues
Instituto de Geociências - Universidade de Brasília

Dra. Claudia Maria de Almeida
Instituto Nacional de Pesquisas Espaciais

Dr. Yosio Edemir Shimabukuro
Instituto Nacional de Pesquisas Espaciais

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado
adequado para obtenção do título de doutor em Geociências Aplicadas e Geodinâmica.

Brasília/DF
2021

Dedico a todos os professores que passaram pela minha vida, em especial aos primeiros: meus pais. Dedico também a todas as mulheres, em especial às mães, que escolheram a ciência como profissão.

AGRADECIMENTOS

Agradeço, sobretudo, a Deus, que me concedeu a vida e por Sua infinita bondade e graça a mantém.

Ao meu orientador, Dr. Edson Sano, que prontamente se dispôs a embarcar nessa jornada comigo, tendo sido, para além de um orientador, um exemplo de serenidade e bom humor.

À minha coorientadora, Dra. Polyanna da Conceição Bispo, sempre pronta e disposta a ajudar, tanto tecnicamente quanto com seu exemplo de força para conquistar nosso espaço enquanto mulheres na ciência. Você é um exemplo para mim!

Ao meu colega e amigo, Dr. Elcio Shiguemori, que me conduziu pelo caminho da IA, abrindo novas janelas de possibilidades em minha carreira acadêmica e profissional.

À minha amiga e colega Bárbara Hass, sempre pronta a ajudar com as ‘cabulosas’ análises estatísticas, de astral elevadíssimo e palavras certas nas horas certas, tanto na UnB quanto no meu tempo de Censipam.

Aos demais colegas do Censipam que sempre ‘seguraram as pontas’ para que eu pudesse me dedicar ao doutorado, bem como aos colegas do IEAv que, por meio de amplas e frutíferas discussões, me ajudaram a ampliar os horizontes deste trabalho.

Ao Dr. Luís Gomez, da Universidad de Las Palmas de Gran Canaria, pelo auxílio nas análises de filtragem das imagens, cessão dos códigos em Matlab para cálculo do estimador $\alpha\beta$ e dezenas de e-mails trocados, explicando muitas vezes o óbvio para que eu conseguisse realizar as análises. Muito obrigada!

Ao amigo Domingos, do Greenpeace, que é ‘o cara’ que mais entende de extração madeireira na Amazônia que conheci! Nossas conversas, lá no começo de tudo, me deram grandes ideias.

Ao amigo e colega José Humberto, do Serviço Florestal Brasileiro, pela cessão dos dados LiDAR e inventário florestal da FLONA do Jamari, pela disponibilidade em ajudar sempre, e pelo apoio na missão de campo na FLONA do Jamari.

Ao Censipam, pela cessão das imagens SAR utilizadas neste trabalho.

À SULSOFT, pela cessão de licença temporária do *software* ENVI, em especial, ao querido Michael Steimeyer e sua equipe, sempre muito dedicada e atenciosa.

À SARMAP, em especial ao Dr. Paolo Pasquali, pela cessão da licença temporária do SARSCAPE, fundamental para a execução deste trabalho.

Aos meus filhos, Isabelle, Otto e Lia, que pacientemente (às vezes nem tanto!) suportaram a falta da mamãe, mesmo que presente de corpo, mas com a cabeça na tese. Vocês são minhas razões para tudo!

Aos meus pais, meus primeiros professores, que plantaram a semente da importância do conhecimento em minha vida. Todos os agradecimentos seriam insuficientes para demonstrar minha gratidão.

À sociedade brasileira, que, com seus tributos, financiou minha formação.

Obrigada a todos que, lembrados ou não aqui, de alguma forma contribuíram para a realização deste trabalho e para a minha formação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Interrupção, incoerência, surpresa são as condições comuns de nossa vida. Elas se tornaram mesmo necessidades reais para muitas pessoas, cujas mentes deixaram de ser alimentadas ... por outra coisa que não mudanças repentinas e estímulos constantemente renovados ... Não podemos mais tolerar o que dura. Não sabemos mais fazer com que o tédio dê frutos. Assim, toda a questão se reduz a isto: pode a mente humana dominar o que a mente humana criou?” (Paul Valéry, citado por Zygmunt Bauman em *Modernidade Líquida*)

RESUMO

Uso da terra, mudanças de uso da terra e degradação de florestas têm sido historicamente os setores que mais contribuem com as emissões de gases de efeito estufa no Brasil, segundo o Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG). Por isso, a necessária contenção do aumento das emissões está intimamente relacionada com o controle e combate do desmatamento e degradação florestal. O Brasil, através do Instituto Nacional de Pesquisas Espaciais (INPE), monitora o desmatamento na Amazônia brasileira desde a década de 1980 (projeto PRODES). Desde 2012, percebe-se um aumento nas taxas de desmatamento, principalmente nos últimos dois anos (2019 e 2020), o que evidencia o risco de não atingimento da meta de redução de emissões assinada pelo país no Acordo de Paris em 2015. O INPE também conta com um sistema de emissão de alertas de degradação florestal para a Amazônia (projeto DEGRAD) e para fins de fiscalização em campo. Apesar de não ter a finalidade principal de quantificar área degradada, dados desse projeto têm apresentado taxas semelhantes às do desmatamento por corte raso. A degradação ocorre majoritariamente pela queima florestal e atividade madeireira. A limitação de ambos os sistemas reside no fato de serem baseados em dados de sensores ópticos, os quais sofrem interferência da cobertura de nuvens, principalmente na estação chuvosa, que vai de outubro a abril. Para suprir essa deficiência, esta pesquisa busca o desenvolvimento de metodologia de detecção e qualificação da intensidade de degradação proveniente da atividade de extração madeireira na Amazônia brasileira baseado em dados de radares de abertura sintética (SAR) em banda X do satélite italiano COSMO-SkyMed. Os dados SAR são capazes de imagear a superfície terrestre mesmo em condições meteorológicas adversas. A área de estudo selecionada está localizada na Floresta Nacional do Jamari, estado de Rondônia, onde são encontradas concessões florestais em que a exploração florestal é feita de forma planejada e controlada por empresas autorizadas. As imagens de radar foram processadas pelos seguintes métodos de classificação não-paramétrica baseados em Aprendizado de Máquina: *Random Forest*, *AdaBoost* e *Multilayer Perceptron* (MLP), o qual é baseado em Redes Neurais Artificiais (*Artificial Neural Networks* - ANN), incluindo redes convolucionais pré-treinadas sobre atributos extraídos pelo analista e pela própria rede neural. Esses métodos de Aprendizado de Máquina foram selecionados por serem capazes de classificar dados não linearmente separáveis e por permitirem aumentos significativos na acurácia e precisão da classificação em relação aos métodos tradicionais, de acordo com a literatura atual. Os melhores resultados foram obtidos quando a MLP-ANN foi aplicada com 50 neurônios na camada oculta, utilizando a função de ativação *Rectified Linear Unit* (ReLU) e otimizador de

peso *Stochastic Gradient Descent* (SGD), apresentando 88% de acurácia tanto para o par de imagens utilizado para o treinamento da rede (imagens adquiridas em junho e outubro) quanto para o teste de generalização, aplicado em um segundo conjunto de dados (imagens adquiridas em janeiro e junho). Nos testes utilizando redes neurais convolucionais, embora as diferenças entre os *embedders* testados tenham sido inferiores a 5%, os testes sobre a composição RGB (R = coeficiente de variação; G = valores mínimos; e B = gradiente) apresentaram os melhores resultados, em particular utilizando o *embedder* Painters (acurácia: 92%; e precisão: ~ 92%), mesmo nos testes de capacidade de generalização, que apresentaram índice de exatidão global de 87%, e no teste sobre os RGB provenientes do par de imagens não-filtradas (acurácia e precisão em torno de 90%). Este estudo mostrou que as imagens SAR na banda X, em conjunto com técnicas de Aprendizado de Máquina, podem ser usadas com precisão para detectar atividades de extração seletiva na Amazônia brasileira. Métodos de agrupamento dessas detecções podem permitir ainda estimar a intensidade de exploração, desde que se obtenha a correlação entre essa intensidade e as áreas de clareiras decorrentes de exploração seletiva legal ou ilegal.

Palavras-chave: extração seletiva de madeira; radar de abertura sintética; banda X; monitoramento de floresta tropical; Aprendizado de Máquina.

ABSTRACT

Land use, land use changes and forest degradation have historically been the sectors that contribute mostly to the greenhouse gas emissions in Brazil, according to the Greenhouse Gas Emissions and Removal Estimates System. Therefore, the necessary reduction of the increase of emissions is closely related to the control and combat of deforestation and forest degradation. Brazil, through the National Institute for Space Research (INPE), has monitored deforestation in the Brazilian Amazon since the 1980s (PRODES project). Since 2012, there is an increase in the deforestation rates, mainly in the last two years (2019 and 2020), showing a risk of not achieving the emission reduction target signed by the country in the Paris Agreement in 2015. INPE also has another system of forest degradation alerts for the Brazilian Amazon (DEGRAD project), mainly to attend the purposes of environmental law enforcements in the field. Though it does not have purpose of quantifying the rates of forest degradation, data from this project have shown rates similar to those of clear-cut deforestation. The degradation occurs mainly due to the forest burning and selective logging. The limitation of both systems is related to the fact that they are based on optical data, which are sensitive to the cloud cover conditions, mainly in the rainy season, from October to April. In order to overcome such limitation, this research proposes the development of a system for detecting and qualifying degradation intensity from the logging activity in the Brazilian Amazon based on X-band synthetic aperture radar (SAR) data acquired by the Italian COSMO-SkyMed satellite. SAR data are able to image the Earth surface even in adverse weather conditions. The study area is located in the National Forest of Jamari, Rondônia State, where we can find forest concessions in which timber exploration by authorized companies is planned and controlled. The SAR images were processed by the following non-parametric classifiers: Random Forest, AdaBoost and Multilayer Perceptron Artificial Neural Networks (MLP-ANN), including pre-trained convolutional networks of attributes extracted by the analyst and by the neural network itself. These machine learning methods were selected because they are able to classify non-linearly separable data and to present improved accuracies and precisions in the image classification, in comparison with the traditional methods, according to the current literature. The best results were obtained when MLP-ANN was applied with 50 neurons in the hidden layer, using the Rectified Linear Unit (ReLU) activation function and Stochastic Gradient Descent (SGD) weight optimizer. We found 88% accuracy for both pairs of images used in the network training (images acquired in June and October) and in the generalization test, applied to a second data set (images acquired in January and June). In tests using convolutional neural networks, although the differences

between the tested embedders were lower than 5%, the tests on the RGB composition (R = coefficient of variation; G = minimum values; and B = gradient) showed the best results, particularly those using the embedder painters (accuracy: 92%; and precision: ~ 92%), even in the generalizability tests, which presented an overall accuracy index of 87%, and in the test on the RGB from the pair of non-filtered images (accuracy and precision of approximately 90%). This study showed that X-band SAR images, in conjunction with machine learning techniques, can be used accurately to detect selective logging activities in the Brazilian Amazon. The clustering methods of these detections can allow estimation of exploration intensity, as long as the correlation between this exploration and the area of clearings is obtained for different types of legal and illegal selective loggings.

Keywords: Selective logging; synthetic aperture radar; X-band; rainforest monitoring, machine learning.

LISTA DE FIGURAS

Figura 1. Dinâmica de uma floresta tropical..	22
Figura 2. Cinco formas de definição de dossel.....	23
Figura 3. Variáveis da geometria de aquisição de um radar.....	28
Figura 4. Conceito do imageamento SAR.....	30
Figura 5. Representação do pixel em formato complexo.....	31
Figura 6. Representação dos coeficientes de retroespalhamento.....	32
Figura 7. Tipos de espalhamento da radiação em micro-ondas.....	34
Figura 8. Representação complexa do sinal medido como sendo a resultante (r) dos sinais coerentes individuais.....	36
Figura 9. Fontes dominantes de retroespalhamento florestal.....	44
Figura 10. Esquema ilustrativo mostrando a tendência de incremento do coeficiente de retroespalhamento em relação ao aumento de biomassa.....	45
Figura 11. Efeitos de sombreamento em imagens SAR.....	46
Figura 12. Ilustração do efeito de sombreamento de uma imagem SAR em área de borda entre floresta e não-floresta em uma órbita satelital descendente e ascendente.....	46
Figura 13. Diagrama esquemático da estrutura de classificação direta.....	50
Figura 14. Diagrama esquemático de estrutura baseada em transformação de atributos de mapeamento.....	51
Figura 15. Diagrama esquemático da estrutura Siamesa.....	51
Figura 16. Diagrama esquemático de estrutura baseada em transferência de aprendizado.....	52
Figura 17. Diagrama esquemático da estrutura de pós classificação.....	52
Figura 18. Diagrama conceitual do classificador Random Forest.....	55
Figura 19. Diagrama conceitual do classificador Adaboost.....	56
Figura 20. Diagrama esquemático de um neurônio artificial.....	57
Figura 21. Diagrama esquemático do algoritmo MLP.....	58
Figura 23. Diagrama esquemático de uma arquitetura de rede recorrente.....	60
Figura 22. Diagrama esquemático de uma Rede Neural Convolutacional.....	70
Figura 24. Esquemas dos operadores de <i>crossover</i> e mutação.....	75
Figura 25 - Localização da FLONA do Jamari em relação aos estados e municípios brasileiros, e da Unidade de Manejo Florestal III.....	77
Figura 26. Localização das cenas COSMO-SkyMed em relação à área de estudo. UMF = Unidade de Manejo Florestal.....	78
Figura 27. Fluxograma geral das etapas metodológicas.....	79
Figura 28. Metodologia de obtenção das amostras de extração seletiva de madeira através das imagens LiDAR.....	80

Figura 29. Fluxo metodológico do processamento das imagens COSMO-SkyMed e obtenção dos polígonos candidatos à extração madeireira seletiva.	81
Figura 30. Fluxo metodológico da geração dos atributos texturais e espectrais das feições candidatas à extração seletiva de madeira.	83
Figura 31. Fluxo metodológico dos testes de classificação por meio de técnicas de Aprendizado de Máquina.....	84
Figura 32. Sub-imagens covmingrad de extração e não extração usadas para treinamento da CNN.....	89
Figura 33. Fluxograma apresentando as etapas do teste de classificação pelas CNNs.	90
Figura 34. Sub-região da imagem COSMO-SkyMed selecionada para testar o desempenho do filtro.	93
Figura 35. Perfil arbitrário em uma área de floresta para a imagem original e os filtros Mean, De Grandi e GammaMAP.	95
Figura 36. Limiarização do produto coeficiente de variação classificado como extração (em vermelho) e não extração (em amarelo).	96
Figura 37. Exemplos de distribuição de alguns atributos gerados sobre as imagens SAR. Em vermelho, a classe extração e em azul, não extração.....	97
Figura 38. <i>Boxplots</i> de um atributo com parâmetros estatísticos semelhantes entre as classes extração e não extração (à esquerda) e um com parâmetros estatísticos divergentes para as mesmas classes (à direita).....	97
Figura 39. Matrizes de confusão dos resultados das classificações pelas topologias <i>Random Forest</i>	99
Figura 40. Matrizes de confusão dos resultados das classificações pelas topologias AdaBoost.	100
Figura 41. Matrizes de confusão dos resultados das classificações pelas topologias NN-MLP.	101
Figura 42. Polígonos gerados pela limiarização do coeficiente de variação (em amarelo) antes e depois da classificação, para os pares de imagens janeiro-junho e junho-outubro.....	102
Figura 43. Imagens COSMO-SkyMed mostrando uma extração não identificada.	103
Figura 44. Polígonos gerados cortando o coeficiente de variação (em amarelo) das imagens de janeiro a junho mostrando listras indicando problemas de sensor/aquisição.	104
Figura 45. Polígonos (em amarelo) classificados como extração (corte) e polígonos (em magenta) fornecidos pelo SFB delimitando a área de corte ilegal, mostrando áreas coincidentes.	105
Figura 46. <i>Boxplots</i> de feições classificadas incorretamente, exemplificando suas diferenças em um atributo selecionado aleatoriamente.	106
Figura 47. Modelos digitais de superfície gerados a partir de dados LiDAR de antes e depois da exploração mostrando uma árvore não detectada pelo método proposto.	106
Figura 48. Candidatos à extração seletiva antes e após a classificação.....	112
Figura 49. Comparação entre a extração seletiva detectado pelo CNN (magenta) e pelo DETEX (amarelo).....	115

Figura 50. Distribuição das distâncias entre clareiras na extração seletiva legal e ilegal.	116
Figura 51. Polígonos classificados como extração (agrupados - cada cor representa um grupo). Em vermelho, limite da Floresta Nacional do Jamari.	117

LISTA DE TABELAS

Tabela 1. Bandas de radar e seus respectivos comprimentos de onda e frequências.	33
Tabela 2. Sistemas SAR comerciais em operação.....	35
Tabela 3. Resumo da relação geral entre os componentes de dispersão da floresta e o comprimento de onda. '++': fonte principal de retroespalhamento, '+' fonte secundária de retroespalhamento, '-' fonte atenuante.	44
Tabela 4. Características das cenas COSMO-SkyMed utilizadas nesse estudo.....	78
Tabela 5. Parâmetros das topologias Random Forest testadas.....	85
Tabela 6. Parâmetros das topologias AdaBoost testadas.....	85
Tabela 7. Parâmetros das topologias das Redes Neurais Artificiais do tipo MLP testadas.	86
Tabela 8. Valores calculados para uma área homogênea na imagem COSMO-SkyMed. Os valores em negrito representam os melhores resultados. μ = média; σ = variância; ENL = número equivalente de looks; $\mu_{\text{razão}}$ = média da imagem da razão; O estimador $\alpha\beta$ e a $\beta_{\text{razão}}$ são descritos em GOMEZ et al. (2016).	94
Tabela 9. Resultados do classificador Random Forest. Em negrito, os melhores resultados obtidos.	98
Tabela 10. Resultados do classificador AdaBoost.....	100
Tabela 11. Resultados do classificador NN-MLP. Em negrito, os melhores resultados obtidos.	101
Tabela 12. Os resultados dos testes de classificação por CNNs pré-treinadas na imagem <i>covmingrad</i> são mostrados em A, na imagem <i>cov</i> em B, e na imagem <i>razão</i> em C.....	110
Tabela 13. Matrizes de confusão dos melhores resultados obtidos através das CNNs testadas para cada tipo de imagem de entrada.....	111
Tabela 14. Matriz de confusão contendo os resultados (porcentagem em relação à previsão) do teste de generalização.	111
Tabela 15. Resultados dos testes de classificação por CNNs pré-treinadas na imagem <i>covmingrad</i> do par não filtrado de imagens CSK.....	112
Tabela 16. Matriz de confusão contendo os resultados (porcentagem em relação à previsão) do teste com o Painters na imagem <i>covmingrad</i> do par não filtrado de imagens CSK.....	112

LISTA DE ABREVIATURAS E SIGLAS

ANLD - Anisotropic Non-Linear Diffusion

ANN – Artificial Neural Network

CNN – Convolutional Neural Network

CV – Coeficiente de Variação

ENL - Equivalent Number of Looks

ERS – European Remote Sensing Satellite

ESA – European Space Agency

FFF – First Fundamental Form

HDF – Hierarchical Data Format

IA – Inteligência Artificial

INPE – Instituto Nacional de Pesquisas Espaciais

ML – Machine Learning

MLP – Multi Layer Perceptron

PRODES – Programa de Monitoramento do Desmatamento

RAR - Real Aperture Radar

RADAR – Radio Detecting and Ranging

RCS – RADAR CROSS SECTION

RELU – Rectified Linear Unit

SAR – Synthetic Aperture Radar

SGD – Stochastic Gradient Descent

SLAR - Side-Looking Airborne Radar

TREES - TRopical Ecosystem Environment monitoring by Satellites

UMF – Unidade de Manejo Florestal

SUMÁRIO

1. INTRODUÇÃO.....	16
1.1 Objetivos.....	20
2. REVISÃO DE LITERATURA	21
2.1 Arquitetura do dossel de florestas tropicais.....	21
2.2 Degradação florestal e extração seletiva: conceitos	24
2.3 Monitoramento da degradação florestal por meio de sensores remotos.....	25
2.4 Fundamentos de sistemas SAR.....	27
2.5 Mecanismos de retroespalhamento SAR.....	33
2.6 Filtragem do efeito speckle em imagens SAR.....	36
2.7 Aplicação de SAR para estudos florestais	43
2.8 Detecção de mudanças em imagens SAR.....	47
2.9 O uso do Aprendizado de Máquina para detecção de mudanças em imagens SAR	49
2.9.1 Estruturas dos modelos de Aprendizado de Máquina para detecção de mudanças	50
2.9.2 Principais métodos de Aprendizado de Máquina	53
2.9.2.1 Random Forest.....	54
2.9.2.2 Adaboost.....	55
2.9.2.3 Redes Neurais Artificiais.....	56
2.9.2.3.1 Arquiteturas das ANNs.....	58
2.9.2.3.2 Aprendizagem das Redes Neurais Artificiais	60
2.9.2.3.2.1 Funções de ativação	61
2.9.2.3.2.2 Algoritmos de aprendizagem	63
2.9.2.3.2.3 Critérios de parada	66
2.9.2.3.3 Conjunto de dados de entrada para Aprendizado de Máquina	67
2.9.2.4 Redes Neurais Convolucionais.....	70
2.9.3 Meta-heurística para otimização do conjunto de dados: os algoritmos genéticos.	73
3. MATERIAIS E MÉTODOS	76
3.1 Área de estudo	76
3.2 Imagens SAR utilizadas	77
3.3 Metodologia.....	79
3.3.1 Processamento das nuvens de pontos LiDAR para obtenção das amostras de	
extração seletiva de madeira.....	79

3.3.2	Pré-processamento das imagens SAR (testes de filtragem do efeito <i>speckle</i>) e obtenção das feições candidatas à extração seletiva de madeira	80
3.3.3	Geração dos atributos texturais e espectrais das feições candidatas à extração seletiva de madeira	82
3.3.4	Testes de classificação por meio de técnicas de Aprendizado de Máquina	84
3.3.5	Testes de classificação por meio de Redes Neurais Convolucionais	88
3.3.6	Estimativa da intensidade de exploração	91
4.	RESULTADOS E DISCUSSÃO	92
4.1	Desempenho de filtros de <i>speckle</i> para imagens COSMO-SkyMed da Amazônia brasileira	92
4.2	Preparação dos dados e análise exploratória	95
4.3	Testes de classificação por meio de técnicas de Aprendizado de Máquina	98
4.3.1	Testes com o classificador Random Forest	98
4.3.2	Testes com o classificador AdaBoost	100
4.3.3	Testes com Redes Neurais Artificiais do tipo MLP	100
4.3.4	Teste de generalização	102
4.3.5	Avaliação comparativa entre as técnicas de Aprendizado de Máquina	105
4.4	Testes de classificação por meio de Redes Neurais Convolucionais	109
4.5	Estimativa da intensidade de exploração	115
5.	CONCLUSÕES	118
6.	REFERÊNCIAS	120
7.	ANEXOS	135
7.1	Lista das espécies comerciais da FLONA do Jamari	135
7.2	Artigos Publicados	136

1. INTRODUÇÃO

Estima-se que as atividades antropogênicas tenham causado aumento de 1,0 °C na temperatura global em relação aos níveis pré-industriais. Se continuar a subir na mesma proporção, deverá atingir 1,5 °C entre 2030 e 2052. Elevação do nível do mar, temperaturas extremas, aumento da frequência, intensidade e quantidade de temporais e secas, perda de biodiversidade, redução da concentração de oxigênio nos oceanos, risco à produção de alimentos e à saúde humana são alguns dos potenciais impactos e riscos associados ao aumento da temperatura (IPCC, 2018; ALLEN et al., 2018). Limitar o aumento da temperatura requer limitar as emissões de CO₂ relacionadas com atividades antrópicas. O desmatamento e degradação florestal somam a segunda maior fonte antropogênica de emissões de CO₂ na atmosfera, através da combustão da biomassa florestal e da decomposição do material vegetal remanescente. A redução das emissões antropogênicas de CO₂ é obrigatória para controlar a elevação global da temperatura.

O desmatamento e a degradação florestal são as segundas maiores fontes antrópicas de emissão de CO₂ na atmosfera, pois estão relacionadas à combustão da biomassa florestal e à decomposição de materiais vegetais remanescentes. Aproximadamente 65% das emissões brasileiras de CO₂ em 2019 vieram do desmatamento e degradação florestal (SEEG, 2021). De acordo com Qin et al. (2021), a degradação florestal contribui três vezes mais para a perda bruta de biomassa acima do solo do que o desmatamento na Amazônia brasileira. Isso ocorre porque a extensão da área de degradação excede a do desmatamento, indicando que a degradação florestal é o processo mais importante para a perda de carbono nessa região (QIN et al., 2021). A degradação pode ocorrer em função da exploração madeireira de espécies de alto valor comercial, pela queima de biomassa ou ainda pela retirada de madeira de menor valor comercial previamente ao desbaste total. Em qualquer um dos casos, seu conceito está relacionado à perda parcial de cobertura florestal ou de biomassa acima do solo por ação antrópica, que causa a abertura de dossel (LAURANCE et al., 1997; ASNER et al., 2005; ASNER et al., 2006; INPE, 2008b).

A exploração madeireira é uma atividade econômica importante na Amazônia brasileira, representando, muitas vezes, uma etapa de capitalização para a progressão para outros tipos de uso da terra (MERRY et al., 2009). De acordo com esses últimos autores, com o estabelecimento de uma indústria florestal produtiva e responsável na Amazônia, a exploração seletiva de madeira nessa região pode se tornar uma fonte de desenvolvimento social e econômico para o Brasil, sem necessariamente causar a degradação do meio ambiente (LOCKS, 2017). Porém, a crescente exploração predatória, além de reduzir a competitividade das

empresas que operam legalmente, arcando com os custos socioambientais e tributários inerentes à atividade, causam impactos negativos ao ambiente natural (MERRY et al., 2009; LOCKS, 2017).

Como apenas um número limitado de espécies de árvores comercializáveis é cortado na exploração seletiva, provocando um desbaste espacialmente difuso, os sistemas de monitoramento baseados em sensoriamento remoto apresentam dificuldade de detecção dessas áreas (ASNER et al., 2005). Ao mesmo tempo, expedições de campo para tal finalidade são inviáveis em função da grande extensão territorial da Amazônia e da insegurança nas áreas de conflitos fundiários nas fronteiras de ocupação (LOUREIRO & PINTO, 2005). Portanto, a detecção por meio de sensores remotos ainda é a melhor opção, apesar de suas limitações.

Diversos autores têm explorado imagens de sensoriamento remoto como ferramenta para monitoramento de supressão vegetal de florestas tropicais, em sua maioria, utilizando produtos de sensores ópticos para detecção de desmatamento (FERRAZ et al., 2005; INPE, 2008a; ASNER et al., 2009; RENÓ et al., 2011; HANSEN et al., 2013; FAWZI et al., 2018; PICKERING et al., 2019). Uma importante limitação desse tipo de sensor reside na sua dependência da energia solar. Dado que existe uma grande concentração de nuvens em determinadas épocas do ano nessas regiões, há o impedimento de imageamento com frequência e extensão regulares (ASNER, 2001). A extração ilegal de madeira tem ocorrido também durante o período chuvoso a fim de evitar a detecção com sensores ópticos (HERZOG & VIEIRA, 2017).

Uma das alternativas às imagens ópticas são as imagens provenientes dos radares de abertura sintética (*synthetic aperture radar* - SAR) que, por serem sensores ativos, possuem a habilidade de operar sob quaisquer condições meteorológicas e de dia ou de noite. Porém, a aplicação de dados SAR para monitoramento sistemático de florestas tropicais é limitada se comparada com o uso de dados de sensores ópticos. Isso se deve à complexidade de processamento, interpretação e análise dos dados SAR, além da menor disponibilidade relativa (BOUVET et al., 2018). A disponibilização gratuita das imagens em banda L do satélite ALOS PALSAR (2006–2011) pela Agência de Exploração Aeroespacial do Japão (JAXA) resultou em um avanço na aplicação florestal de dados SAR. Shimada et al. (2014) produziram quatro mosaicos globais anuais de imagens ALOS, de 2007 a 2010, a partir dos quais se geraram quatro mapas de floresta e não-floresta. Devido à alta penetração no dossel, os dados em banda L têm sido

amplamente aplicados em estudos de estimativa de biomassa acima do solo (WATANABE et al., 2006; SANTORO et al., 2009; SAATCHI et al., 2011; MERMOZ et al., 2014).

Outro grande avanço do sensoriamento remoto de radar está relacionado temporalmente à disponibilização gratuita dos dados do satélite Sentinel-1, em banda C, pela Agência Espacial Europeia (ESA), que permitem o monitoramento sistemático com ciclo de repetição entre 6 e 12 dias. Desde então, diversos estudos têm explorado a aplicação florestal desses dados. Lohberger et al. (2018) estimaram as áreas de queimadas florestais em Sumatra, Kalimantan e Papua Ocidental durante o ano de 2015 baseadas em imagens Sentinel-1. Reiche et al. (2018) utilizaram a combinação de dados multitemporais dos satélites Sentinel-1, ALOS-2, Landsat 7 ETM+ e Landsat 8 OLI para detecção de desmatamento em uma floresta tropical seca boliviana, demonstrando o potencial de dados SAR em detectar mais rapidamente o desmatamento em relação aos do Landsat. Os autores citaram, como questão chave, até que ponto a alta densidade temporal dos dados Sentinel-1 seria capaz de compensar a menor sensibilidade em detectar desmatamento em banda C em relação à banda L. A conclusão foi a de que a garantia de um maior número de observações é fundamental para melhorar os sistemas de detecção em tempo quase real de desmatamento nos trópicos.

Devido ao seu maior comprimento de onda, os dados SAR em banda L são mais frequentemente aplicados em estudos florestais, incluindo estimativas de biomassa, detecção de alterações antrópicas como desmatamento, degradação e classificação da cobertura da terra (CASTEL et al., 2002; KUPLICH et al., 2005; MITCHARD et al., 2009; WALKER et al., 2010; CUTLER et al., 2012; RYAN et al., 2012; WHITTLE et al., 2012; LAURIN et al., 2013; REICHE et al., 2013; SHIMADA et al., 2014; JOSHI et al., 2016), em função da sua maior penetração no dossel.

Uma lacuna científica reside na utilização de sensores remotos orbitais SAR em banda X para detecção de degradação florestal por extração seletiva de madeira. Presume-se que a utilização dessa tecnologia possibilitaria o monitoramento constante de regiões tropicais, em especial da Amazônia brasileira, alvo desse estudo, dado que uma alta frequência de revisita é obtida com as atuais constelações de satélites SAR, como são os casos dos satélites COSMO-SkyMed, Iceye, e os satélites gêmeos TanDEM-X e TerraSAR-X, que operam em banda X. Dados SAR em bandas C e X já têm apresentado potencial utilização na estimativa de biomassa (SCHLUND et al., 2015; TREUHAFT et al., 2015; TREUHAFT et al., 2017) e mapeamento de distúrbios florestais a partir de técnicas avançadas de dados interferométricos (DEUTSCHER et al., 2013), ou combinados com a banda L (BERNINGER et al., 2018), ou ainda explorando atributos de

textura (DELGADO-AGUILAR et al., 2017). Porém, são técnicas que exigem dados interferométricos, polarimétricos ou associação com outras bandas. No Brasil, a aplicação operacional de dados SAR em banda X na Amazônia, adquiridos por sensores aerotransportados, está restrita ao projeto Cartografia da Amazônia (CENSIPAM et al., 2015), cujo objetivo é mapear, em escala de 1:50000, o vazio cartográfico existente na região.

A extração de informações como detecção de alvos e de mudanças em imagens SAR não é uma tarefa trivial, especialmente em função do efeito *speckle*, inerente a esse tipo de dado, da geometria de visada lateral do sensor e dos diferentes tipos de retroespalhamento que, no caso dos alvos florestais, é volumétrico. Essas características demandam métodos específicos de processamento, interpretação e análise dos dados SAR, mais complexos se comparados aos métodos relacionados com as imagens ópticas (BOUVET et al., 2018).

Uma das primeiras etapas de processamento das imagens para detecção de mudanças multitemporais em imagens SAR consiste na aplicação de filtros para redução do efeito *speckle*. A literatura científica tem explorado diferentes metodologias com o objetivo de apresentar soluções capazes de reduzir tal efeito e, ao mesmo tempo, manter a informação útil sobre os elementos imageados (MACEDO & OGASHAWARA, 2013; GOMEZ et al., 2016; MAHDAVI et al., 2018; KUCK et al., 2021), embora a seleção do filtro adequado se dê, muitas vezes, através de simples inspeção visual da imagem filtrada.

Já nas etapas de interpretação e análise, trabalhos recentes têm demonstrado bons resultados com a aplicação de técnicas computacionais de Aprendizado de Máquina para classificação e detecção de mudanças em imagens SAR (LIU et al., 2020; SHI et al., 2020a; SHI et al., 2020b). Exemplos dessas técnicas são o algoritmo Random Forest (GHOSH & BEHERA, 2018; SEO et al., 2018; YU et al., 2018), AdaBoost (ZHAO et al., 2017; ZHANG et al., 2020), as redes neurais artificiais do tipo *Multi Layer Perceptron* (MLP) (LEE et al., 2020) e as redes neurais convolucionais (*Convolutional Neural Network* – CNN) (CUI et al., 2019; DONG et al., 2019; JATURAPITPORNCHAI et al., 2019; LI et al., 2019). Entretanto, até o presente momento, não existem estudos analisando o desempenho da aplicação dos diferentes classificadores baseados em Aprendizado de Máquina em dados SAR em banda X adquiridos sobre a Amazônia brasileira.

Em resumo, dentre as diversas pesquisas envolvendo uso de dados SAR para o mapeamento de exploração seletiva de madeira em florestas tropicais, não existem estudos analisando o desempenho da aplicação dos diferentes classificadores baseados em Aprendizado de Máquina

sobre imagens SAR em banda X, tampouco estudos que avaliem, quantitativamente, o desempenho de diferentes filtros de speckle sobre tais imagens. Neste trabalho, foram avaliados quantitativamente diferentes métodos de filtragem de imagens SAR multitemporais em banda X dos sensores da constelação orbital COSMO-SkyMed para redução do efeito *speckle*. Posteriormente, foram testados e comparados os métodos de classificação baseados em Aprendizado de Máquina para identificação de cicatrizes de extração seletiva madeireira em uma região de extração controlada localizada na Floresta Nacional (FLONA) do Jamari, no estado de Rondônia.

1.1 Objetivos

Dada a importância do monitoramento da atividade madeireira na Amazônia, a pesquisa aqui apresentada tem como objetivo explorar o potencial de imagens SAR multitemporais em banda X para detecção, mapeamento e qualificação da intensidade de exploração madeireira. Para tanto, será utilizada, como estudo de caso, a FLONA do Jamari, localizada no estado de Rondônia, na qual é possível encontrar áreas de concessão florestal para exploração seletiva legal e controlada de madeiras e também áreas de exploração seletiva ilegal ao redor da referida FLONA. Para atingir o objetivo geral proposto, os seguintes objetivos específicos foram definidos:

- Avaliar diferentes métodos de filtragem para redução do efeito *speckle* nas imagens SAR COSMO-SkyMed de banda X com o objetivo de preservar informações fundamentais para a identificação de corte seletivo;
- Avaliar diferentes métodos de Aprendizado de Máquina para a identificação de corte seletivo usando atributos espectrais, espaciais e texturais extraídos das imagens multitemporais SAR COSMO-SkyMed de banda X; e
- Testar Redes Neurais Convolucionais pré-treinadas para a identificação de corte seletivo usando imagens multitemporais SAR COSMO-SkyMed de banda X.

2. REVISÃO DE LITERATURA


2.1 Arquitetura do dossel de florestas tropicais

As florestas tropicais concentram a maior parte da biodiversidade mundial e são responsáveis pelo sequestro e armazenamento de uma grande quantidade de carbono. A Amazônia é a maior floresta tropical do mundo, sendo que 60% de seu território localiza-se no Brasil. Essa grande biodiversidade resulta em uma estrutura complexa, dado que o mosaico de espécies proporciona uma composição tridimensional variável em forma e densidade, que também varia de acordo com o estágio da floresta (OLDEMAN, 1989). A Figura 1, adaptada de Oldeman (1989), representa pequenos transectos detalhados de uma floresta tropical, onde é possível observar um mosaico composto por pedaços de floresta de diferentes tamanhos e em diferentes estágios de desenvolvimento. Nela, o autor utiliza o termo eco-unidades (ecossistemas) para descrever todas as superfícies nas quais, em um dado momento, iniciou-se um processo de desenvolvimento vegetal, das quais a arquitetura, o funcionamento ecofisiológico e a composição das espécies são ordenadas por um conjunto de árvores.

Observando-se a Figura 2, é possível notar que a superfície formada pelo topo do dossel é heterogênea por ser dependente do ecossistema e do estágio em que a floresta se encontra. Apenas nas unidades pioneiras recentes há uma geometria monótona do conjunto de árvores, dada pela composição pobre de espécies. Essa superfície pode variar de 40 metros (ou mais) acima da superfície do solo até o nível do solo (nas áreas de lacunas). O limite inferior do dossel pode ser atribuído à parte mais baixa das copas que tocam a superfície do dossel ou à parte mais baixa de todas as copas. O dossel pode ser visto como o total de copas que tocam a superfície do dossel, mas também como o total de todas as copas em uma floresta. Outra forma é delimitar o dossel a partir do volume ocupado pelas copas superiores e inferiores, ou ainda pelo volume total de floresta acima do solo (BONGERS, 2001). A Figura 2 ilustra tais maneiras de delimitar o dossel.

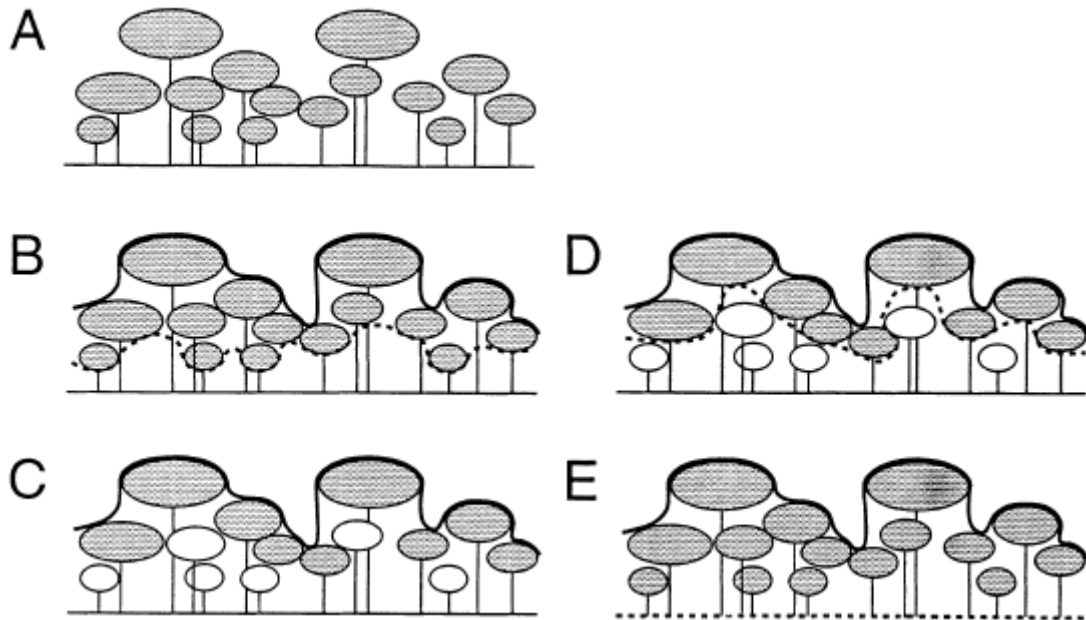
Neste estudo, o dossel será definido como o volume entre o limite superior (superfície das copas) (BIRNBAUM, 1997) e o limite inferior, definido pela capacidade máxima de penetração de uma onda em banda X neste dossel, como será apresentado na Subseção 2.7.

Figura 1. Dinâmica de uma floresta tropical. A - Mosaico de uma floresta nativa, composta por ecossistemas de diferentes tamanhos e formas, constituídos por diferentes grupos de espécies. Chablis* denota a fase de inovação de uma unidade ecológica, quando o banco de propagação é mobilizado. B - Fases de desenvolvimento de uma unidade ecológica. A fase de inovação não é mostrada, a sequência mostra a fase de classificação (crescente, Ba), a fase bioestática (Bb) e a fase de degradação em que a reorganização está ocorrendo (Bc). Observe que o diagnóstico da fase se baseia no estado dos subsistemas: árvores do passado (pontilhadas), do presente (hachura cruzada) e árvores em potencial (em branco). Observe os organismos associados (epífitas, alpinistas) e a zona de borda espessa em torno da unidade ecológica.



Fonte: adaptado de Oldeman (1989).

Figura 2. Cinco formas de definição de dossel. (A) conjunto de todas as copas. (B) volume total, incluindo as copas do limite inferior e superior; (C) coleção de copas que tocam a superfície do dossel; (D) volume total, incluindo as copas da superfície do dossel; e (E) volume total acima do solo.



Fonte: Bongers (2001).

A estrutura do dossel pode ser compreendida como estrutura física, ou seja, o arranjo espacial de todos os elementos acima do solo em uma comunidade florestal (CAMPBELL & NORMAN, 1989), como também como estrutura funcional, ou seja, a estrutura das relações entre os elementos no dossel da floresta, incluindo plantas e animais (REAGAN & WAIDE, 1996). Neste estudo, será adotado o conceito de estrutura física.

Uma descrição completa da estrutura (*latu sensu*) de um dossel da floresta exigiria a especificação da posição, tamanho e orientação de cada elemento da superfície no dossel. Barkman (1979) distinguiu entre textura e estrutura (*strictu sensu*) da vegetação. Textura é a composição qualitativa e quantitativa da vegetação quanto a diferentes elementos morfológicos (no sentido mais amplo possível), independentemente de sua disposição. Estrutura é o arranjo espacial (horizontal e vertical) desses elementos. Essa distinção entre textura e estrutura não é generalizada. Na comparação de florestas e tipos de florestas, apenas as comparações de textura distinguem bem os espectros gerais de, por exemplo, formas de crescimento, tamanhos de folhas, famílias de plantas, modelos de árvores arquitetônicas, tipos de polinização e grupos ecológicos, permitindo mostrar quantitativamente as diferenças entre os elementos nas florestas

em questão. Os espectros fornecem, em um certo nível de abstração, os elementos construtivos da floresta. Para muitos objetivos de estudo, isso é detalhe suficiente. A medição da estrutura envolve a localização de todos esses elementos no espaço tridimensional (3D) e, portanto, envolve muito trabalho extra. Isso, no entanto, é importante para estudos sobre padrões ambientais abióticos na floresta (por exemplo, disponibilidade de luz), localização espacial de plantas e animais relacionados com habitats específicos das árvores da floresta e padrões de movimento dos animais (BONGERS, 2001).

Neste estudo, o termo textura estará associado a outro conceito, o de arquitetura do dossel. A arquitetura do dossel é a estrutura da floresta acima do solo em termos da arquitetura de copas de árvores individuais. A textura é governada pela arquitetura do dossel que define a rugosidade da superfície do dossel quando esta é imageada por sensores de alta frequência e alta resolução espacial (VAN DER SANDEN, 1997). A rugosidade da superfície superior de uma floresta é um parâmetro estrutural importante, indicando o comprimento da interface da floresta com o macroambiente e pode ser analisado usando várias técnicas. Fotografias aéreas podem ser usadas para detectar alturas relativas da superfície superior da floresta usando medidas estereoscópicas. Além disso, imagens de radar de alta resolução podem ser utilizadas para análise dessa rugosidade (BONGERS, 2001).

2.2 Degradação florestal e extração seletiva: conceitos

Para detecção de processos de degradação florestal, é fundamental, antes de mais nada, que se conceitue degradação. Várias são as definições utilizadas na literatura, passando por definições gerais, específicas e operacionais, sendo as operacionais aquelas quantificáveis, relacionadas a inventários e relatórios sobre emissões de gases do efeito estufa (PINHEIRO, 2015). No contexto do *Reducing Emissions from Deforestation and Degradation* (REDD), a degradação tem sido definida como a perda a longo prazo (persistindo por X anos ou mais) de uma porcentagem Y de estoque de carbono por atividades induzidas pelo homem (IPCC, 2003). Olander et al. (2008) definiram degradação como perda de densidade de biomassa sem envolver mudança na área de cobertura da floresta de até 70%. Já o INPE, que monitora as florestas brasileiras, a definiu como processo de perda da cobertura florestal pelo efeito da exploração de madeira e fogo, de pelo menos 6,25 ha da cobertura florestal e que não é qualificada como desflorestamento pelo sistema PRODES. Asner et al. (2005) definiram degradação florestal como distúrbio persistente no tempo (entre tempo 1 e tempo 2) e espaço, caracterizado pela extração madeireira ou ocorrência repetida de incêndios. Já Asner et al. (2006) utilizaram o termo ‘distúrbio florestal’ para nomear as áreas de abertura de dossel ocasionada pela extração

seletiva de madeira. Matricardi (2007) citou que, na Amazônia, a degradação florestal antropogênica tem sido relacionada à fragmentação florestal (SKOLE & TUCKER, 1993; COCHRANE, 2001), extração seletiva de madeira (NEPSTAD et al., 1999; HUTH & DITZER, 2001) e fogo florestal (COCHRANE & SCHULZE, 1998; COCHRANE et al., 1999).

Assim sendo, a extração seletiva de madeira é um meio de degradação florestal que também pode ser causada por outros meios e é definida como a extração direcionada a um grupo de espécies de alto valor comercial (VERÍSSIMO et al., 1995; UHL et al., 1997). Embora aparentemente menos impactante que o corte raso, definido como a retirada total da cobertura vegetal para conversão do solo em outro uso, a extração seletiva não manejada pode afetar uma grande parcela de floresta devido à abertura de trilhas de arraste da tora, abertura de pátios de estocagem e direção de queda da árvore, resultando na queda de outras que estão em sua proximidade (VERISSIMO et al., 1992).

A extração seletiva é geralmente classificada de acordo com sua intensidade e forma de exploração. Em relação à intensidade, Asner et al. (2004) apresentaram a intensidade da exploração seletiva como sendo o número de árvores extraídas por hectare, porém, não a qualificando em alta ou baixa. Matricardi et al. (2013) classificaram as intensidades de extração seletiva na Amazônia, identificadas por meio de cenas Landsat para os anos de 1996 e 1999, em alta para as cenas que apresentaram média das áreas de extração seletiva maior de $100 \text{ km}^2 \text{ ano}^{-1}$ e baixa para as cenas que apresentaram média das áreas de extração seletiva menor de $100 \text{ km}^2 \text{ ano}^{-1}$.

Em relação à forma de exploração, são citadas a exploração de impacto reduzido e a exploração convencional. Na exploração convencional, as árvores de interesse comercial são marcadas e posteriormente serradas e arrastadas para os pátios por um trator de esteira, onde são carregadas em caminhões que irão transportar as toras. Já na exploração de impacto reduzido, as áreas a serem exploradas são previamente inventariadas, as estradas e pátios planejados, os cipós cortados e a direção de queda das árvores determinada de forma a causar o menor impacto possível nas árvores vizinhas. As trilhas de arraste são planejadas considerando as árvores derrubadas e os troncos são extraídos com o apoio de um *skidder* (ASNER et al., 2004).

2.3 Monitoramento da degradação florestal por meio de sensores remotos

Apesar de amplamente explorado para mapeamento de desmatamento, a aplicação do sensoriamento remoto para monitoramento de degradação florestal ainda demanda avanços, especialmente pela complexidade da natureza desses processos (DEUTSCHER et al., 2013).

Uma das limitações da viabilidade de monitoramento por sensores remotos é, por exemplo, que nem todos os tipos de degradação representam alterações na estrutura dos dosséis (ELIASCH, 2008). Diversos estudos têm abordado o uso de dados ópticos para tal finalidade, em especial as imagens do satélite Landsat, que proporcionam uma ampla cobertura temporal e a possibilidade de detecção de distúrbios florestais através de métodos como índices de vegetação e análise de mistura espectral (MITCHELL et al., 2017). Porém, o uso desses dados em regiões tropicais é limitado pelo fato de serem sensores passivos, ou seja, dependem da luz solar pois registram a reflectância dos alvos, o que nem sempre é possível nessas regiões já que há grande persistência de cobertura de nuvens (ASNER, 2001), o que dificulta também a frequência de observações, importante em estudos de processos antrópicos.

Pesquisas têm explorado, como alternativa, o uso de sensores SAR. Além de não dependerem da luz solar para operar, o sinal retroespalhado contém informações sobre a estrutura do alvo, uma vez que, no caso da aplicação em florestas, ondas longas (banda L) penetram no dossel e são sensíveis às grandes estruturas (como troncos e galhos) e ondas curtas (bandas X e C) são sensíveis a estruturas pequenas como galhos menores e folhas (SUN et al., 1991; WULDER & FRANKLIN, 2003). Em função dessas características, dados SAR vêm sendo frequentemente utilizados em estudos florestais. Dados nas bandas P, L e C têm apresentado potencial para estimativa de biomassa florestal (KUPLICH et al., 2000; ROMSHOO & SHIMADA, 2001; CASTEL et al., 2002; PULLIAINEN et al., 2003; SANTOS et al., 2003; KUPLICH et al., 2005; SANTOS et al., 2006; MITCHARD et al., 2009). Mitchard et al. (2011) mediram perdas de biomassa por desmatamento e degradação na África Central usando dados multitemporais de retroespalhamento do sensor ALOS PALSAR.

De uma maneira geral, os requisitos dos sensores SAR para os propósitos de medição de biomassa e detecção de degradação são diferentes. Para degradação por extração seletiva de madeira, os métodos são geralmente baseados na detecção de clareiras e outras feições que indicam a presença da atividade, como ramais e trilhas de arraste (MITCHELL et al., 2017). Neste caso, a frequência temporal de aquisição das imagens pode ser um importante aliado, permitindo detectar as mudanças ao longo do tempo. Já para estudos que buscam estimar biomassa, a alta capacidade de penetração no dossel própria das ondas mais longas é fundamental. Nesse caso, análises multitemporais não são demandadas (MITCHELL et al., 2017).

Por sua pouca penetração na estrutura dos dosséis, os sensores que operam em banda X não são os mais adequados às estimativas de biomassa acima de 30 Mg ha⁻¹ (LE TOAN et al., 1992).

Todavia, estudos aplicando técnicas complexas utilizando dados de fase, como a interferometria SAR, têm demonstrado resultados interessantes na detecção de alterações na estrutura vertical e biomassa florestal (TREUHAFI et al., 2017). Dados interferométricos também foram utilizados por Deutscher et al. (2013) para detecção de degradação florestal na República do Congo e em Camarões.


2.4 Fundamentos de sistemas SAR

O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) recomenda, para estimativa de área florestal, estoques de carbono e mudanças de cobertura da terra, uma combinação de dados provenientes de satélites de observação da Terra e inventários de campo (GOFI-GOLD, 2016). As atuais abordagens brasileiras de monitoramento florestal, especificamente voltadas à Amazônia, utilizam imagens provenientes de sensores satelitais e podem ser divididas em duas classes: a de emissão de alertas de supressão florestal e a de quantificação anual de desmatamento. Em ambos os casos, os sistemas oficiais governamentais adotam como dados de referência, as imagens provenientes de sistemas ópticos de observação da Terra (INPE, 2008b; DINIZ et al., 2015), que possuem observação limitada pela cobertura de nuvens. Como alternativa a esses sistemas, que capturam a energia refletida ou irradiada, têm-se as imagens provenientes de sensores ativos que operam na faixa espectral de micro-ondas, denominados *Radio Detection And Ranging* (RADAR).

Os radares possuem fonte própria de energia, transmitindo pulsos de radiação micro-ondas e medindo a energia retroespalhada dos alvos através de um sistema receptor. Eles operam geralmente com comprimentos de onda superiores a 3 cm, o que permite a alta transmissão das ondas eletromagnéticas na atmosfera independente da iluminação solar, mesmo quando a atmosfera se apresenta nublada ou durante precipitações, podendo assim gerar imagens sob as condições mais adversas. Os radares são baseados no princípio da ecolocalização, ou seja, a medida de tempo entre o sinal transmitido e o eco de retorno permite estimar a distância do objeto observado, dado que a velocidade do sinal é conhecida. Para compensar o baixo poder de resolução angular inerente ao sistema radar, que praticamente não consegue alcançar as larguras de feixe estreitas necessárias para produzir uma imagem detalhada da superfície, a antena é apontada lateralmente, obtendo-se uma visada oblíqua da superfície imageada. Assim, na primeira dimensão da imagem radar está a distância da superfície em alcance, relacionada ao atraso do eco, enquanto a segunda dimensão da imagem resulta da utilização do movimento do instrumento para varrer o solo ao longo da trajetória de voo, em azimute (WOODHOUSE, 2006a).

As variáveis geométricas de um imageamento por radar são (Figura 3): o ângulo de visada θ_v , que representa o ângulo entre o nadir e a linha de visada do sensor radar; o ângulo de depressão θ_d , entre a linha de visada e a horizontal local do sensor radar; e o ângulo de incidência θ_i , entre a linha de visada e a normal de uma superfície local de referência.

Figura 3. Variáveis da geometria de aquisição de um radar.



Fonte: Adaptado de Woodhouse (2006a).

A altura da plataforma refere-se à distância vertical entre esta e um ponto da superfície imediatamente abaixo dela, e o alcance à direção de transmissão do pulso. O azimute, à direção no terreno paralela ao deslocamento da plataforma. A distância inclinada, ou *slant range*, é a distância entre sensor e alvo na direção de alcance, também conhecida como distância percebida pelo radar, enquanto a distância no terreno, ou *ground range*, representa a distância inclinada projetada sobre o terreno, também conhecida como distância real ou geográfica. O *near range* é a região mais próxima ao nadir, enquanto o *far range*, a mais distante.

Inicialmente, os radares, então denominados de *Real Aperture Radar* (RAR) ou *Side-Looking Airborne Radar* (SLAR), possuíam limitada capacidade de resolução espacial na direção azimutal. Conforme mostrada na Equação 1, a resolução espacial na direção de azimute (no sentido de deslocamento da plataforma) depende do tamanho físico da antena e da distância inclinada da plataforma em relação ao alvo (RICHARDS, 2009). Assim, como exemplificado por Woodhouse (2006a), para se obter uma resolução espacial em azimute aproximada de 50 m com um RAR a 800 km de altitude em banda X, seria necessária uma antena com mais de 700 m de comprimento.

$$r_a = \frac{\lambda}{l_a} R_o \quad m \quad (\text{Equação 1})$$

Sendo: r_a = resolução espacial na direção azimutal;
 R_o = distância em alcance inclinado;
 λ = comprimento de onda da radiação transmitida pela antena; e
 l_a = comprimento da antena.

Já a resolução espacial em alcance é dependente da duração do pulso transmitido (Equação 2), e representa a metade da duração do pulso. Assim, se dois objetos estão distanciados entre si na direção de alcance a uma distância menor que a metade da duração do pulso, os sinais retroespalhados desses objetos irão se misturar, não sendo possível discriminá-los como alvos distintos (RICHARDS, 2009).

$$r_g = \frac{c\tau}{2 \text{ sen } \theta_i} \quad m \quad (\text{Equação 2})$$


Sendo: r_g = resolução espacial na direção de alcance no terreno (*ground range*);
 c = velocidade do pulso na faixa espectral em micro-ondas (velocidade da luz);
 τ = comprimento ou duração do pulso; e
 θ_i = ângulo de incidência.

Para solucionar as limitações impostas pelos sistemas RAR, estes foram substituídos pelo SAR. No SAR, a necessidade de aumento do tamanho físico da antena para obtenção de maior resolução espacial na direção de azimute, em uma plataforma localizada em altitude alta, é substituída pela sintetização, através de um processador de sinal digital, de uma antena de grande dimensão. Essa síntese é realizada pelo registro acumulado do retroespalhamento do sinal de um alvo da superfície durante todo o tempo que este alvo é “iluminado” pelo SAR durante o deslocamento da plataforma. Isso é possível pelo fato de que toda a informação de fase dos pulsos incidentes sobre determinado alvo da superfície ficar registrada em uma matriz bidimensional (alcance e azimute). Esse histórico de fases é combinado (sintetizado) em uma série temporal, conformando uma “assinatura” de fases, que, através de um processamento complexo, é transformada em informação de azimute e alcance (RICHARDS, 2009).

O imageamento SAR é baseado em um sistema radar instalado em uma plataforma que se desloca em uma velocidade V , contendo um transmissor que envia pulsos em intervalos regulares de micro-ondas, modulados linearmente em frequência. Os sinais retroespalhados na direção do sensor são gravados a bordo e posteriormente processados para a geração da imagem. A resolução em alcance é obtida pela largura de banda dos pulsos, que é determinada pela variação de frequência transmitida pelo pulso. Por sua vez, a resolução em azimute é obtida

pela técnica de abertura sintética. Para compreensão dessa técnica, utiliza-se, como modelo, o comportamento de um alvo pontual (Figura 4), onde se observa um ponto P, desde sua entrada no campo visual da antena no instante azimutal τ_e até sua saída no instante τ_s . No intervalo entre τ_e e τ_s , o radar envia N pulsos, coletando N amostras de ecos do ponto P durante o deslocamento da plataforma, que é dado por $V(\tau_s - \tau_e)$, o que dá origem ao conceito de abertura sintética, sendo este o comprimento virtual da antena definido pelo tempo em que o ponto P pode ser observado pelo radar (RICHARDS, 2009).

Figura 4. Conceito do imageamento SAR.



Fonte: adaptado de Mura (2000).

Devido à velocidade da plataforma (V) e à variação de distância entre o intervalo ($\tau_s - \tau_e$), o eco recebido de cada pulso sofre uma modificação de frequência e fase, denominado efeito Doppler. A largura da banda Doppler (B_D) definida pela variação de frequência define a resolução da imagem SAR em azimute (Equação 3).

$$r_a = \frac{V}{B_D} \quad (\text{Equação 3})$$

Sendo: r_a = resolução espacial na direção de azimute;
 V = velocidade da plataforma; e
 B_D = Banda Doppler.

Para que os dados de cada ponto da cena sejam transformados em informações sobre os alvos da superfície, a imagem bruta deve ser submetida a diversos processamentos computacionais complexos, que transformam a informação bruta em uma imagem que contém a distribuição da refletividade complexa do terreno (NOVO, 2008). O detalhamento desse processamento está descrito, por exemplo, em Mura (2000). O processamento *multilook* consiste em dividir a abertura sintética em visadas (*looks*). A imagem final é composta pela média das imagens de


cada *look*, assumindo-se serem estatisticamente independentes. A técnica de *multilook* aumenta a relação sinal-ruído da imagem, proporcional à raiz quadrada do número de *looks*, diminuindo o efeito *speckle*. Ao mesmo tempo, provoca degradação na resolução em azimute, dado que a imagem de cada *look* (B_{look}) possui largura de banda menor que a largura total da banda Doppler (B_D) (Equação 4).

$$B_{look} = \frac{B_D}{nl} \quad (\text{Equação 4})$$

Sendo: nl = número de *looks*.

As imagens geradas pelos sistemas SAR são fornecidas em formato complexo, com a informação de fase de cada pixel da imagem. Na Figura 5, o pixel é representado no formato complexo, onde U_q e U_i são as componentes real e imaginária, respectivamente; A é o módulo do número complexo representando a amplitude do pixel; e α a fase do pixel complexo. Em geral, as componentes U_q e U_i são codificadas em 16 bits, sendo necessários 32 bits para representação de um pixel complexo.

Figura 5. Representação do pixel em formato complexo.



As imagens *multilook* geralmente são representadas em imagens de amplitude (Equação 5), que são também conhecidas como imagens detectadas linearmente. Para estas, utiliza-se geralmente uma representação de 16 ou 8 bits por pixel. Essas imagens também podem ser representadas em intensidade (Equação 6), e por serem quadráticas, em geral necessitam de 32 bits para representá-las.

$$A = \sqrt{U_i^2 + U_q^2} \quad (\text{Equação 5})$$

$$I = U_i^2 + U_q^2 \quad (\text{Equação 6})$$

A geração da imagem SAR apresenta um resultado radiometricamente descalibrado, com variações de intensidade, dada a visada lateral do radar, as características da antena utilizada e os movimentos da plataforma na qual o sensor está acoplado (aérea ou orbital). Para correção desses efeitos e para aplicações como reconhecimento de alvos e uso das informações


quantitativas dos pixels (retroespalhamento), é necessário proceder-se à calibração radiométrica. A calibração radiométrica provê a conversão dos valores dos pixels da imagem SAR, para que estes sejam qualitativamente representativos do sinal retroespalhado e quantitativamente representativos da seção cruzada do radar σ (*radar cross section – RCS*).

A seção cruzada do radar (σ) é o parâmetro que representa a capacidade de objetos isolados refletirem as ondas de radar e é função do comprimento da onda do radar e das características dos alvos (tamanho, forma, orientação e composição) (VAN DER SANDEN, 1997). A seção cruzada de radar pode ser definida, em sua forma simplificada, pela equação de radar (Equação 7).

$$\sigma = 4\pi \cdot \frac{\text{energia refletida por unidade de angulo sólido}}{\text{densidade de energia incidente}} \text{ [m}^2\text{]} \quad (\text{Equação 7})$$

As imagens calibradas são geralmente representadas em σ^0 , β^0 e γ^0 (EL-DARYMLI et al., 2014). O β^0 é uma medida adimensional conhecida como coeficiente de brilho do radar. É o RCS por unidade de área na linha de visada do radar, ou seja, no alcance inclinado; σ^0 é o RCS por unidade de área na projeção do terreno; e γ^0 é o RCS por unidade de área da frente da onda incidente, ou seja, perpendicular à faixa de inclinação (Figura 6). Tanto o σ^0 quanto o γ^0 são geralmente representados em escala logarítmica, em decibéis (dB).

Figura 6. Representação dos coeficientes de retroespalhamento.



Devido às variações topográficas do terreno imageado e à posição inclinada do sensor SAR, as distâncias e feições aparecem distorcidas na imagem. As principais distorções geométricas nas imagens SAR são a inversão de relevo, o encurtamento de rampa e o sombreamento (WOODHOUSE, 2006a). São necessárias, portanto, correções de terreno, cujo objetivo é compensar tais distorções para que a representação geométrica da imagem seja o mais próximo possível do mundo real. A principal limitação para a integridade geométrica de uma imagem SAR é a superfície de referência utilizada para fazer a projeção no alcance do solo. Idealmente,

a superfície de referência deve representar a própria topografia do terreno para que cada pixel da imagem SAR seja projetado em sua coordenada real. Quanto maior a diferença entre a superfície de referência e a superfície real, maior a distorção geométrica na imagem projetada. Portanto, um produto perfeito, sem distorção, só pode ser produzido quando informações topográficas estão disponíveis para serem utilizadas como superfície de referência. Uma imagem projetada na topografia real é conhecida como um produto "geocodificado" e é equivalente a uma imagem ortorretificada no sensoriamento remoto óptico (WOODHOUSE, 2006a).

Porém, apesar de a geocodificação compensar algumas distorções, ao contrário das sombras das imagens ópticas, que são regiões da imagem com iluminação fraca, as sombras do radar são áreas de uma imagem que são, em princípio, completamente pretas, pois correspondem a áreas onde há uma completa falta de informações recebidas. Elas correspondem à região que fica atrás de objetos na cena imageada e da qual não há eco de retorno (WOODHOUSE, 2006a).

2.5 Mecanismos de retroespalhamento SAR

Conforme já abordado anteriormente, os radares medem a energia em micro-ondas que retorna ao sensor após interagir com os alvos da superfície. Essa interação é proporcional ao comprimento de onda da energia emitida, que varia, considerando os sensores em operação atualmente, de 0,75 cm a 120 cm, aproximadamente. A Tabela 1 apresenta a nomenclatura convencional das bandas SAR, seus comprimentos de onda e frequências.

Tabela 1. Bandas de radar e seus respectivos comprimentos de onda e frequências.

Nomenclatura	Comprimento de onda (cm)	Frequência (GHz)
K _a	0,75 – 1,15	40 – 26
K	1,15 – 1,67	26 – 18
K _u	1,67 – 2,5	18 – 12
X	2,4 – 3,8	12 – 8
C	3,8 – 7,5	8 – 4
S	7,5 – 15,0	4 – 1,5
L	15,0 – 60,0	1,5 – 0,5
P	60,0 - 120	0,5 – 0,25

Fonte: Jensen (2014).


O retroespalhamento é também função das variáveis do terreno/objeto, como rugosidade, conteúdo hídrico (ou constante dielétrica) e orientação (geometria). A rugosidade de um objeto ou superfície é função da escala de observação que, para o radar, está relacionada ao comprimento de onda utilizado e à geometria de aquisição dos dados (PONZONI et al., 2012).

Assim, uma superfície pode ser lisa para um sensor que opera em um determinado comprimento de onda e rugosa para um comprimento de onda menor. Henderson & Lewis (1998) relataram três escalas de rugosidade: a microescala, associada ao tom da imagem radar, a mesoescala, associada à textura da imagem, e a macroescala, associada às variações topográficas do terreno.

A intensidade do retroespalhamento também é determinada pelo conteúdo hídrico, que altera a constante dielétrica, indicando a refletividade ou condutividade de determinado alvo. Quanto maior o conteúdo hídrico de um alvo da superfície, maior o retroespalhamento gerado. O dossel vegetal, cujo conteúdo de umidade é alto, apresenta um alto espalhamento das micro-ondas incidentes (PONZONI et al., 2012).

Os mecanismos de espalhamento da radiação eletromagnética (REM) na região das micro-ondas podem ser superficiais, quando ocorrem na superfície dos objetos, ou volumétricos, quando correm no interior e incluem o espalhamento entre os componentes do objeto, como no caso do espalhamento da radiação incidente em um dossel florestal. Quando a superfície é lisa em relação ao comprimento de onda usado pelo radar, o espalhamento ocorre na direção contrária ao sensor, sendo denominada de espalhamento especular. Já uma superfície rugosa em relação ao comprimento da onda incidente gera um espalhamento difuso, em várias direções. Em alguns casos, quando há duas superfícies lisas perpendiculares, como é o caso de prédios em áreas urbanas, ocorre o espalhamento chamado de reflexão de canto, o qual resulta em alto retorno de sinal ao sensor. A Figura 7 exemplifica os tipos de espalhamento.

Figura 7. Tipos de espalhamento da radiação em micro-ondas.



O espalhamento que retorna ao sensor (retroespalhamento) também sofre influência da relação entre a polarização da onda e o formato do objeto observado. Como REM, as micro-ondas apresentam campos elétricos e magnéticos que se propagam em direções transversais entre si em relação à direção de propagação. A polarização é definida pela trajetória do campo elétrico em um plano, que pode ser linear, circular ou elíptica. Os radares de polarização linear são os

mais comuns, sendo os de polarização horizontal aqueles cujo campo elétrico se desloca paralelamente ao eixo de propagação, e os de polarização vertical, perpendicularmente.

Como é um sistema ativo, o radar transmite e recebe REM, sendo possíveis quatro combinações de polarizações lineares: transmitida e recebida verticalmente (VV), transmitida e recebida horizontalmente (HH), transmitida na vertical e recebida na horizontal (VH) e transmitida na horizontal e recebida na vertical (HV). A interação dessas ondas com os alvos depende, portanto, da polarização e do formato do alvo. Alvos estruturados verticalmente têm interação maior com a polarização vertical, gerando maiores sinais de retorno (HENDERSON & LEWIS, 1998).

Atualmente existem diversos sistemas SAR orbitais e aerotransportados em operação. A Tabela 2 apresenta os principais sistemas comerciais e suas características. Grande parte dos SAR comerciais operam em banda X, seguidos pelos que operam em banda C. Dos que operam em banda X, os satélites COSMO-SkyMed, TerraSAR-X e TanDEM-X e Iceye são constelações, o que permite o aumento da frequência de revisita a um alvo, além de possibilitarem a aquisição de imagens em alta resolução espacial. A missão Sentinel-1 compreende uma constelação de dois satélites SAR de órbita polar e representa um avanço no imageamento por radar, já que provê capacidade operacional independente de imageamento contínuo e disponibilização gratuita de imagens (ESA, 2021). Porém, os dados disponibilizados sobre o território brasileiro não contemplam a melhor resolução espacial possível do sensor, limitando o uso dessas imagens para determinadas aplicações.

Tabela 2. Sistemas SAR comerciais em operação.


Satélite	Agência	País	Lançamento	Banda	Polarização	Resolução (m)
COSMO-SkyMed	ASI	Itália	2007	X	Dual	1x1
TerraSAR-X	DLR	Alemanha	2007	X	Quad	1x1
TanDEM-X	DLR	Alemanha	2009	X	Quad	1x1
RADARSAT-2	CSA	Canadá	2007	C	Quad	3x3
Sentinel-1	ESA	EU	2014	C	Dual	5x5
ALOS-2	JAXA	Japão	2014	L	Quad	3x1
ICEYE	-	Finlândia	2018	X	VV	3x3
Kompsat-5	KARI	Coréia	2013	X	Single	1x1
Gaofen 3	CNSA	China	2016	C	Quad	1x1
Saocom	CONAE	Argentina	2018	L	Quad	<10m

2.6 Filtragem do efeito speckle em imagens SAR

Devido à natureza coerente dos sistemas imageadores que operam na faixa eletromagnética de micro-ondas, as imagens de radar apresentam o efeito *speckle*, que se assemelha visualmente a um ruído usualmente denominado “sal e pimenta”, e que é resultado da interferência entre os ecos coerentes dos retroespalhamentos individuais dentro de uma célula de resolução (WOODHOUSE, 2006a). O padrão do efeito *speckle*, dado que não se conhece a exata geometria dos alvos retroespalhadores, é aleatório. Dessa forma, o *speckle* é geralmente tratado como ruído, o que, de modo estrito, não é correto, por se tratar de um fenômeno determinístico e reproduzível.

Assim, um alvo aparentemente homogêneo e de dimensão maior que uma célula de resolução resultará em diferentes medidas de fase e amplitude para cada porção adjacente do alvo, resultando em pixels com valores diferentes, dadas as pequenas variações do alvo, que alterarão o padrão de interferência do sinal retroespalhado. A Figura 8 mostra a representação do vetor complexo das ondas retroespalhadas, e pode ser usada para melhor compreensão do efeito *speckle*. Considerando que uma célula de resolução radar contém uma coleção randômica de sinais retroespalhados, cada um proveniente de uma localização ligeiramente diferente do instrumento (e conseqüente diferente fase) e cada um com uma seção transversal do radar ligeiramente diferente (amplitude do sinal), então o sinal de retorno pode ser representado como a adição coerente de todos os sinais individuais (WOODHOUSE, 2006a).

Figura 8. Representação complexa do sinal medido como sendo a resultante (r) dos sinais coerentes individuais.



Fonte: Woodhouse (2006a).

O efeito *speckle* dificulta a discriminação dos alvos, tanto por métodos visuais quanto automáticos, já que atribui esse aspecto granuloso às imagens radar. A redução desse efeito

pode ser realizada através de duas técnicas: aplicação de filtros pós-processamento e processamento *multilook*. Este último é apresentado na Seção 2.3, e sua desvantagem consiste na redução de informação relacionada à textura, equivalente a um filtro passa-baixa (SHI & FUNG, 1994). Os filtros adaptativos são, portanto, mais adequados quando se quer reduzir o *speckle* preservando a informação textural das imagens. Diversos são os filtros de *speckle* descritos na literatura (SHI & FUNG, 1994; DE GRANDI et al., 1997; BOSE, 2003; ASPERT et al., 2007) bem como amplamente comparados através de diferentes metodologias que buscam avaliar, na maioria dos casos, a relação sinal-ruído da imagem filtrada (SHI & FUNG, 1994; GAGNON & JOUAN, 1997; MACEDO & OGASHAWARA, 2013; GOMEZ et al., 2016; MAHDAVI et al., 2018).

A motivação para o desenvolvimento do filtro De Grandi (DE GRANDI et al., 1997) surgiu da aplicação de imagens SAR para monitoramento de florestas tropicais, objetivo da Comissão Europeia *TRopical Ecosystem Environment monitoring by Satellites* (TREES). De acordo com os autores, as imagens do satélite ERS, em valores absolutos de intensidade, não eram suficientes para discriminar certos tipos de vegetação como de uma floresta primária ou secundária. Então, uma análise de contexto seria necessária, surgindo assim, como proposta, a decomposição multi-resolução wavelet. Porém, tal metodologia se apresentava sensível à contaminação pelo *speckle* das imagens SAR. Dado que os filtros convencionais de *speckle* que utilizam a estatística espacial local da vizinhança de um pixel tendem a suavizar a textura em escalas detalhadas (alta resolução espacial), o filtro De Grandi foi proposto como alternativa. Este filtro utiliza, portanto, uma série multitemporal de imagens SAR adquiridas sob mesmos parâmetros (mesmo modo e geometria de aquisição), de modo que o alvo, em tempos/aquisições diferentes, esteja sob as mesmas condições de iluminação, assumindo um modelo para o componente ruído e restringindo o sinal a estacionário.

O filtro De Grandi é baseado em dois estimadores, ambos lineares de variância mínima e assumem o modelo multiplicativo do ruído $z_i = x_i v_i$ $i = 1 \dots n$, em que v_i é o ruído de média única e desvio-padrão σ_v e x_i a refletividade a ser estimada (Equação 8). O primeiro estimador, que será referenciado como ponderação ideal, considera uma estimativa linear imparcial da refletividade no tempo t_0 como uma soma ponderada dos sinais na série temporal:

$$\hat{x}_{t_0} = \sum_1^n \alpha_i z_i \frac{E[z_{t_0}]}{E[z_{t_i}]} \quad (\text{Equação 8})$$

Os pesos α_i são encontrados impondo-se a variância mínima da refletividade e a condição adicional para áreas homogêneas (Equação 9):

$$x_i = E[x_i] \quad (\text{Equação 9})$$

Isso significa que o algoritmo de ponderação ideal só irá reconstruir a refletividade de maneira otimizada apenas se proveniente de um caso de distribuição uniforme (*speckle* totalmente desenvolvido). Para áreas com uma população flutuante de dispersores dentro da célula de resolução, que dão origem a uma distribuição K para o sinal de amplitude retroespalhado (a refletividade tem distribuição Gamma), o estimador não apresentaria variância mínima.

O segundo estimador é uma extensão vetorial do filtro Lee clássico (LEE, 1981), onde o estimador linear é dado por (Equação 10):

$$\hat{x} = A\bar{x} + Bz \quad (\text{Equação 10})$$

em que \hat{x} , z e \bar{x} são os n-vetores e as matrizes A e B são escolhidas para minimizar a variância da refletividade (LEE et al., 1991). Mais detalhes da implementação do filtro De Grandi podem ser encontrados em De Grandi et al. (1997).

No filtro Lee (LEE, 1980, apud SHI & FUNG, 1994), o modelo multiplicativo é primeiramente aproximado por um modelo linear e posteriormente o critério do mínimo erro quadrático médio (MMSE) é aplicado a esse modelo linear. De acordo com Shi & Fung (1994), o filtro Lee pode ser formulado como (Equação 11):

$$\hat{R}(t) = I(t)W(t) + \bar{I}(t)(1 - W(t)) \quad (\text{Equação 11})$$

em que a função de ponderação é dada por (Equação 12):

$$W(t) = 1 - \frac{C_u^2}{C_I^2(t)} \quad (\text{Equação 12})$$

e o coeficiente de variação do *speckle* $u(t)$ e da imagem $I(t)$, respectivamente dados por (Equação 13):

$$C_I(t) = \frac{\sigma_I(t)}{\bar{I}(t)} \quad C_u = \frac{\sigma_u}{\bar{u}} \quad (\text{Equação 13})$$

Sendo: u = a intensidade do *speckle*, dada por $A_R^2 + A_I^2$;

\bar{u} = média da intensidade u ;

$t = (x, y)$, a coordenada espacial da imagem;

$I(t)$ = imagem intensidade observada em $t = (x, y)$;

$R(t)$ = refletividade do terreno; e

$u(t) = speckle$ multiplicativo estatisticamente independente de $R(t)$ de média única \bar{u} e variância única σ^2 .

O filtro Frost (FROST et al., 1982) pressupõe a imagem observada como corrompida por ruído convolutivo multiplicativo, ou seja, o retroespalhamento do terreno é multiplicado por um processo aleatório estacionário que representa os efeitos de atenuação coerente. O sinal resultante é então processado (convoluído) com a função de espalhamento pontual do sistema de radar para produzir a imagem observada. De maneira simplificada, o filtro pode ser expresso como (Equação 14) (SHI & FUNG, 1994):

$$m(t) = e^{-K C_I^2(t_0)|t|} \quad (\text{Equação 14})$$

Sendo: K = constante que controla a taxa de amortecimento da função de resposta ao impulso; e

t_0 = pixel a ser filtrado.

Observa-se que quando o coeficiente de variação $C_I(t_0)$ é pequeno, o filtro se comporta como um filtro passa baixa, suavizando o *speckle*, e quando $C_I(t_0)$ é grande, tem tendência a preservar a imagem original observada, que é o recurso considerado na formulação dos filtros Lee e Kuan.

O filtro de média é aplicado deslizando-se uma janela de dimensão $P \times P$ pela imagem, substituindo o pixel central pela média dos pixels da janela. Sendo assim, P deve ser um número inteiro ímpar para que haja um pixel central (BOSE, 2003). É um dos filtros de formulação matemática mais simples e amplamente utilizado para filtragem de *speckle*, com a desvantagem de ‘borrar’ as bordas, já que suavizam a informação de alta frequência. É dado por (Equação 15):

$$g(x, y) = \sum_{ta=-a}^a \sum_{tb=-b}^b w(s, t) f(x + s, y + t) / \sum_{ta=-a}^a \sum_{tb=-b}^b w(s, t) \quad (\text{Equação 15})$$

Sendo: $w(x, y)$ = filtro de tamanho (m, n) , de forma que todos os elementos de w percorram cada um dos pixels de $f(x, y)$ (a imagem).

O filtro Gamma Map pressupõe o conhecimento, a priori, da função de densidade de probabilidade da cena. Em Kuan et al. (1987), assumiu-se o retroespalhamento como tendo distribuição Gaussiana. No entanto, essa afirmação não é realista, dado que assume valores de retroespalhamento negativos. Lopes et al. (1990) modificaram o filtro Kuan MAP assumindo

uma distribuição Gama para a cena e estabelecendo dois limiares (SHI & FUNG, 1994). O Gamma Map é dado por (Equação 16):

$$\hat{R}(t_0) = \begin{cases} \bar{I}(t_0), & \text{para } c_l(t_0) < c_u \\ \frac{(a-L-1)\bar{I}(t_0) + \sqrt{\bar{I}^2(t_0)(\alpha-L-1)^2 + 4aL\bar{I}(t_0)}}{2\alpha}, & \text{para } c_u \leq c_l(t_0) \leq c_{max} \\ I(t_0), & \text{para } c_l(t_0) > c_{max} \end{cases} \quad (\text{Equação 16})$$

Sendo: L = número de *looks*;

$$c_{max}(t_0) = \sqrt{2}C; \text{ e}$$

$$\alpha = \frac{1+c_u^2}{c_l^2(t_0)-c_u^2}.$$

Os filtros *Anisotropic Non-Linear Diffusion* (ANLD) foram inicialmente propostos para aplicação em imagens ópticas. De acordo com Aspert et al. (2007), esses filtros permitem um alto grau de regularização de áreas homogêneas enquanto preservam as feições estruturais (bordas ou outras descontinuidades). Para uma imagem contínua, a difusão na imagem pode ser representada pela equação diferencial parcial (Equação 17):

$$\frac{\partial I}{\partial t} = \text{div}[c(\|\nabla I_\sigma\|) \cdot \nabla I_\sigma] \quad (\text{Equação 17})$$

Sendo: ∇ = gradiente;

$\text{div}(\cdot)$ = operador de divergência; e

c = coeficiente de condução, uma matriz de coeficientes de difusão do mesmo tamanho que I .

O coeficiente c é projetado para ser uma função não linear da magnitude do gradiente da imagem suavizada $\nabla(I_\sigma)$. Como demonstrado em vários estudos, uma função ótima de difusividade é dada por (Equação 18):

$$c(\|\nabla I_\sigma\|, \lambda) = \begin{cases} \frac{1}{2} \left[1 - \left(\frac{\|\nabla I_\sigma\|^2}{\lambda} \right) \right]^2 & \text{se } \|\nabla I\| \leq \lambda \\ 0 & \text{caso contrário} \end{cases}$$

(Equação 18)

Sendo: λ = parâmetro de sensibilidade.

A principal desvantagem da difusão não linear é que essa técnica não filtra as feições estruturais (bordas). Para solucionar essa questão, uma difusão sensível à direção da borda foi implementada. A quantidade de difusão é controlada por uma matriz D (também chamada tensor de difusão) de valores que especificam a importância da difusão na direção das feições. A difusão anisotrópica é descrita por (Equação 19):

$$\frac{\partial I}{\partial t} = \text{div}[\mathbf{D}(\|\nabla I_{\sigma}\|) \cdot \nabla I_{\sigma}], \quad \mathbf{D} = \begin{pmatrix} a & b \\ b & c \end{pmatrix} \quad (\text{Equação 19})$$

Sendo: $a = \phi_1 \cos^2 \alpha + \phi_2 \sin^2 \alpha$ (Equação 20)

$$b = (\phi_1 - \phi_2) \sin \alpha \cos \alpha \quad (\text{Equação 21})$$

$$c = \phi_1 \sin^2 \alpha + \phi_2 \cos^2 \alpha \quad (\text{Equação 22})$$

α = direção do gradiente (ângulo máximo de variação);

ϕ_1 = parâmetro que controla a difusão ao longo do gradiente; e

ϕ_2 = parâmetro responsável pelo processo de filtragem perpendicular a esse gradiente.

Portanto, ϕ_1 será escolhido para se comportar da mesma maneira que c na difusão não linear e ϕ_2 será fixado em um valor constante, pois se exige que as arestas sejam suavizadas uniformemente (ASPERT et al., 2007).

No caso do filtro ANLD multitemporal, a diferença reside no cálculo da quantidade de difusão que não varia mais com um gradiente de imagem única. A escolha é feita para medir o gradiente usando todo o conjunto de imagens. A escolha mais natural é usar a formulação confiável para computação em gradiente com dados vetoriais, que toma o gradiente como coletor bidimensional incorporado em \mathfrak{R}^m , obtendo a seguinte primeira forma fundamental (*First Fundamental Form* - FFF) (Equação 23):

$$df^2 = \begin{pmatrix} dx \\ dy \end{pmatrix}^T \begin{pmatrix} g_{11} & g_{12} \\ g_{12} & g_{22} \end{pmatrix} \begin{pmatrix} dx \\ dy \end{pmatrix} \quad (\text{Equação 20})$$

Sendo:
$$\begin{cases} g_{11} = \sum_{i=1}^m \nabla I_{\sigma,(i,x)}^2, \\ g_{12} = \sum_{i=1}^m \nabla I_{\sigma,(i,x)} \nabla I_{\sigma,(i,y)}, \\ g_{22} = \sum_{i=1}^m \nabla I_{\sigma,(i,y)}^2. \end{cases} \quad (\text{Equação 24})$$

$I_{\sigma,(i,x)}^2$ e $I_{\sigma,(i,y)}^2$ = estimativa de gradiente ao longo de colunas e linhas, respectivamente.

A direção e magnitude da taxa máxima e mínima de alteração correspondente às direções de gradiente calculadas podem ser extraídas dos autovalores e autovetores de FFF. Finalmente, o quadro prático do processo de difusão anisotrópica pode ser escrito como (Equação 25):

$$\begin{cases} \frac{\partial I_1}{\partial t} = \text{div}[D \cdot \nabla \vec{I}], \\ \vdots \\ \frac{\partial I_n}{\partial t} = \text{div}[D \cdot \nabla \vec{I}], \end{cases} \quad (\text{Equação 21})$$

Sendo: \vec{I} = toda a sequência de imagens multitemporais; e

$I_i = i^{\text{th}}$ imagem da sequência.

Portanto, cada imagem é filtrada separadamente usando as informações da sequência global, levando em consideração as feições de todas as imagens (Aspert et al., 2007). De fato, avaliar a qualidade de um determinado filtro não é uma tarefa trivial, principalmente porque os valores de retroespalhamento livres de ruídos que se quer estimar são desconhecidos e, por esse motivo, não é possível comparar os resultados das filtrações com a ‘verdade de campo’. Outra questão importante é a relação entre qualidade e fidelidade da imagem filtrada, já que a qualidade dos filtros é geralmente avaliada em função do efeito de ‘embaçamento’ de áreas homogêneas e preservação de detalhes de áreas heterogêneas sem, contudo, considerar os valores relativos de retroespalhamento dos alvos, que representa uma parte fundamental da informação (ARGENTI et al., 2013).

Uma das abordagens usuais é a inspeção visual da imagem filtrada, que permite a detecção dos elementos perceptíveis aos olhos humanos como a preservação de bordas e homogeneidade. Contudo, tal abordagem não possibilita avaliar quantitativamente os efeitos da filtração nos valores de retroespalhamento dos alvos. Para superar tal limitação, são apresentadas diversas metodologias de avaliação da performance de filtros, as quais podem ser divididas em duas classes: índices com referência e sem referência (ARGENTI et al., 2013). A utilização dos índices com referência depende da disponibilidade de uma imagem de referência, livre de *speckle*, que pode ser proveniente de campo ou sinteticamente gerada. Esse método, apesar de amplamente utilizado, pode não ser suficiente, já que as imagens livres de *speckle* sinteticamente geradas podem diferir substancialmente, em termos de suas propriedades estatísticas, da verdade de campo (ARGENTI et al., 2013). Já os índices sem referência são baseados unicamente em hipóteses estatísticas do sinal modelado. Neste caso, como o modelo de sinal depende do grau de heterogeneidade da cena, podem ser demandadas a amostragem

supervisionada de áreas mais apropriadas para o cálculo de um índice específico, como regiões homogêneas, por exemplo (ARGENTI et al., 2013).

O número equivalente de looks (*Equivalent Number of Looks* - ENL) é um índice comumente utilizado para avaliar o nível de suavização de uma imagem filtrada. Ele é medido em uma área homogênea, onde se espera que as variações devido ao *speckle* sejam quase nulas. Para uma dada imagem I e uma dada região homogênea de média μ e desvio-padrão σ , o ENL é dado por μ^2 / σ^2 . Valores altos de ENL indicam alta suavização da imagem (GOMEZ et al., 2016).

Outra medida usual de performance de filtros é computada através da imagem razão, definida como a razão entre a imagem original e a imagem filtrada. Um filtro ideal deve resultar em uma imagem puramente constituída por *speckle*, enquanto uma remoção ineficaz de *speckle* resultará em feições estruturais como bordas e sombras (ARGENTI et al., 2013). A média e a variância de uma imagem razão devem ser próximos à média e variância do *speckle* puro sendo que, de acordo com o modelo multiplicativo, a média do *speckle* é 1.

Em resumo, um filtro ideal apresenta um alto valor de ENL, mantém a média, reduz a variância em relação à imagem original e não apresenta feições como bordas e sombreamentos na imagem razão. Porém, deve-se considerar que a inspeção visual da imagem é um processo subjetivo. Para suprir tal subjetividade, Gomez et al. (2016) apresentaram metodologia denominada *$\alpha\beta$ -ratio estimator for ratio images*, a qual avalia a permanência de feições estruturais nas imagens razão após a aplicação de filtros para remoção de *speckle*, o ENL medido em uma área homogênea na imagem razão e o valor médio do *speckle*, com base na imagem original (com *speckle*), na imagem razão e no produto da detecção de bordas da imagem razão. Um filtro ideal deve apresentar valor de $\alpha\beta = 0$. O estimador $\alpha\beta$ considera como variáveis o ENL e média da imagem razão, e sendo assim, fortemente favorece os filtros que preservam as bordas (GOMEZ et al., 2016).

2.7 Aplicação de SAR para estudos florestais

O retroespalhamento proveniente de uma floresta densa é dominado volumétrico, uma vez que é composto pelo sinal originado dos diversos elementos que a compõem, como folhas, galhos, ramos e troncos e ainda do solo sob a floresta, direta ou indiretamente e a depender do comprimento de onda da energia incidente (Tabela 3). A quantidade de energia retroespalhada dependerá dos parâmetros da onda e das propriedades do objeto observado. Em relação aos parâmetros da onda, estes incluem: frequência, polarização da onda emitida e recebida, e geometria de visada do sensor. Já as propriedades da floresta que influenciam o


retroespalhamento são: densidade do dossel, forma, orientação e distribuição dos componentes da vegetação e constante dielétrica (VAN DER SANDEN, 1997).

Tabela 3. Resumo da relação geral entre os componentes de dispersão da floresta e o comprimento de onda. '++': fonte principal de retroespalhamento, '+' fonte secundária de retroespalhamento, '-' fonte atenuante.

Comprimento de onda	Componentes da floresta					
	Folhas	Galhos	Ramos secundários	Ramos primários	Troncos	Solo
X-band	++	++	++			
C-band	++	+	++			
L-band	-	-	++	++	++	+
P-band	-	-	-	++	++	++

Em geral, o comportamento do retroespalhamento florestal pode ser decomposto em uma série de modelos que representam seus processos de interação com a energia (Figura 9). O cômputo do retroespalhamento total compreende a soma das contribuições de cada processo representado (VAN DER SANDEN, 1997).

Figura 9. Fontes dominantes de retroespalhamento florestal. (1) retroespalhamento volumétrico das copas; (2) retroespalhamento direto dos troncos; (3) retroespalhamento direto da superfície do solo; (4a) retroespalhamento tronco-solo; (4b) retroespalhamento solo-tronco; (5a) retroespalhamento copa-solo; E (5b) retroespalhamento solo-copa.

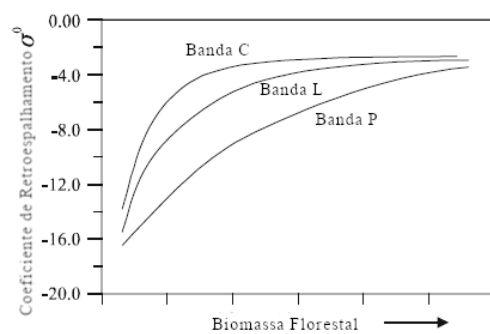


Fonte: Van der Sanden, (1997).

O processo 1 irá dominar o retroespalhamento do dossel observado por um sensor em banda X ou banda C, enquanto o processo 4 irá dominar o retroespalhamento em uma observação florestal em banda P. Em dados radar, observa-se uma correlação positiva entre densidade de

biomassa e retroespalhamento, até que se atinja um nível de saturação, onde a sensibilidade à biomassa é perdida (Figura 10). A explicação usual para esse padrão observado é que, em alta biomassa, a floresta acaba se tornando virtualmente opaca, de modo que o sinal retroespalhado retorne somente das camadas superiores do dossel da floresta após a saturação (WOODHOUSE, 2006b), comportando-se de maneira semelhante ao retroespalhamento das ondas de menor comprimento, como a banda X.


Figura 10. Esquema ilustrativo mostrando a tendência de incremento do coeficiente de retroespalhamento em relação ao aumento de biomassa.



Fonte: Woodhouse (2006b).


Dada sua baixa penetrabilidade no dossel, os dados em banda X são menos frequentemente aplicados a estudos florestais. Porém, alterações na estrutura do dossel ocasionadas por remoção vegetal podem ser perceptíveis pelos sensores que operam em bandas de altas frequências, por conterem mais informação textural (VAN DER SANDEN, 1997), a depender de fatores como biomassa, estrutura da floresta e condições do terreno, já que reduzem a intensidade da energia retroespalhada, conforme evidenciado por Bouvet et al. (2018). Os autores descreveram a metodologia de detecção em tempo real de feições de desmatamento a partir do efeito de sombreamento SAR em imagens Sentinel-1, em banda C. O efeito de sombreamento nas imagens SAR ocorre em função da geometria de visada lateral deste tipo de sensor. As áreas sombreadas são aquelas em que o pulso de radar não incide em função de um obstáculo mais alto que intercepta a energia emitida, criando uma zona escura em que nenhuma energia é retroespalhada. Tal fenômeno é comumente observado em regiões montanhosas, mas também pode ser observado nas bordas entre floresta e não-floresta em imagens de alta resolução espacial, a depender do ângulo de visada do sensor (Figura 11 e Figura 12). Quando as árvores de uma floresta são cortadas, sombras aparecem ou desaparecem, em suas bordas, dependendo da direção de órbita, da posição do fragmento em relação ao satélite e da cobertura do solo ao redor do fragmento (BOUVET et al., 2018).

Figura 11. Efeitos de sombreamento em imagens SAR.



Fonte: nrcan.gc.ca

Figura 12. Ilustração do efeito de sombreamento de uma imagem SAR em área de borda entre floresta e não-floresta em uma órbita satelital descendente e ascendente.



Fonte: adaptado de Bouvet et al. (2018).

O aparecimento do efeito de sombreamento é caracterizado pela queda repentina do retroespalhamento em uma série multitemporal de imagens adquiridas segundo mesmos parâmetros (ângulo de visada, altura do sensor, órbita, modo de aquisição). Um fenômeno oposto também pode ser observado na posição oposta da área desmatada: o aparecimento de um aumento do retroespalhamento, que ocorre em função do efeito de reflectância dupla exercido pelos troncos das árvores remanescentes que estão posicionadas da direção de propagação do sinal radar (VILLARD & BORDERIES, 2007).

Tanase et al. (2019) evidenciaram, a partir de estudos realizados em uma floresta temperada, que o coeficiente de retroespalhamento da banda C é sensível ao volume foliar, já que é atenuado por este, indicando potencial para monitoramento de alterações em nível de dossel. Em suas simulações, os autores observaram que alterações sutis, como a extração seletiva de madeira, não são facilmente detectadas usando dados em bandas C ou L a partir de aquisições esparsas, o que pode indicar a necessidade de alta frequência temporal para detecção desse tipo de distúrbio. O estudo também aponta que alterações significativas como corte raso podem ser mascaradas por efeitos como inversão, devido a uma resolução espacial insuficiente em relação à altura da vegetação, que governa os efeitos combinados de sombreamento e iluminação nas bordas frontais das clareiras, apontando ainda a importância da estrutura e altura da floresta no entorno da área perturbada, que têm impacto importante na capacidade de detecção em banda C.

Delgado-Aguilar et al. (2017), em estudo sobre o potencial de dados em banda X para mapeamento de desmatamento e degradação na floresta tropical do Equador, observaram uma superestimação das florestas degradadas em função da presença de ruído, do ângulo de incidência e do retroespalhamento semelhante ao das áreas de não-floresta nas imagens SAR. Os autores sugeriram, como possíveis melhorias, a incorporação de informação de coerência interferométrica, técnicas polarimétricas ou aumento da resolução temporal dos dados SAR.

Aplicando a técnica de interferometria, Deutscher et al. (2013) descreveram um método de identificação de degradação florestal a partir de modelos digitais de superfície obtidos de imagens COSMO-SkyMed, em banda X, adquiridas em modo *Spotlight* InSAR e da *Shuttle Radar Topography Mission* (SRTM) de 90 m, obtendo acurácia entre 76% e 82%, com subestimação da floresta degradada. Os autores apontaram a baixa coerência entre as cenas COSMO-SkyMed como uma limitação para aplicação da técnica proposta, já que impossibilita a geração do modelo digital de superfície a partir desses dados. De fato, a aplicação desse tipo de técnica exige, além de duas aquisições sobre uma mesma área, nem sempre disponíveis, que os dois sinais de onda retroespalhados pelo alvo sejam coerentes.

2.8 Detecção de mudanças em imagens SAR

A detecção de mudanças através de imagens SAR consiste na determinação das mudanças que podem ter ocorrido a partir de imagens adquiridas sobre uma mesma área em diferentes momentos. É uma abordagem comumente utilizada para monitoramento de ambientes urbanos, marítimos e naturais, como florestas e geleiras (CHEN et al., 2019; GENG et al., 2019; LI et

al., 2019). O uso de imagens SAR para tal finalidade faz-se indispensável nos casos em que as interferências atmosféricas, como a presença de nuvens, limitam a observação da Terra e, por consequência, o monitoramento das mudanças. Porém, as imagens SAR sofrem o efeito *speckle*, que torna a detecção de mudanças imprecisa. Esse efeito pode ser minimizado através do processo de *multilooking* ou através de métodos de filtragem, conforme apresentado na Seção 2.6. São duas principais abordagens de detecção de mudanças em imagens SAR: a primeira, baseada nas informações de fase contidas nas imagens SAR por meio do estudo do mapa de coerência, e a segunda, que pode ser qualificada de detecção de mudanças incoerentes, compara apenas as amplitudes das imagens SAR.

O processo de detecção de mudanças em imagens SAR em amplitude geralmente possui duas etapas: a detecção das mudanças entre duas (ou mais) imagens usando diferentes tipos de operadores e a classificação dessas mudanças através de classificadores supervisionados e não supervisionados (GHARBIA et al., 2020). A detecção das mudanças é usualmente baseada em uma operação de razão, que é sensível a erros de calibração e radiométricos, além do *speckle*. Embora diversos autores tenham sugerido a adoção do operador de razão logarítmica (DAS et al., 2016) para minimização do efeito de *speckle* na detecção de mudanças, Zhuang et al. (2019) apontaram que não há ganho em relação à utilização da imagem razão simples. O coeficiente de variação (CV) multitemporal é uma abordagem apresentada como sendo vantajosa para a detecção de mudanças em função de sua formulação simples e propriedades estatísticas notáveis (KOENIGUER & NICOLAS, 2020). O coeficiente de variação, também chamado de desvio-padrão relativo, é matematicamente definido, em estatística, como a razão do desvio-padrão do sinal pela média. Portanto, é considerada uma medida normalizada da dispersão de uma distribuição de probabilidade. Koeniguer et al. (2019) apresentaram os primeiros estudos teóricos demonstrando que o CV é relevante para detecção de mudanças mesmo em áreas com *speckle*, e que possui diferentes propriedades estatísticas para pelo menos três categorias de perfis temporais: a de um dispersor permanente; a de uma área natural de *speckle* estável, não necessariamente correlacionada no tempo, mas que é estacionária; e de uma área não estacionária que geralmente interpretamos como uma mudança. Nos dois primeiros casos, que representam situações de não-mudança, Koeniguer & Nicolas (2020) apresentaram ser possível derivar propriedades matemáticas úteis sobre o CV. Os autores concluíram que um contraste maior que 8 dB entre o alvo (mudança) e a não-mudança provê um excelente desempenho (superior a 90%) no uso do CV. A detecção de mudanças pode ser apresentada como um problema clássico de detecção, usando um teste de hipótese, sendo H_0 = “não-mudança” e H_1

= “mudança”. A formulação matemática do teste é dependente do limiar definido como critério para H_0 e H_1 . Um grande desafio desse método consiste na definição desse limiar, para qual alguns métodos automáticos são propostos na literatura (QUIN et al., 2014), baseados geralmente na distribuição estatística das mudanças e não-mudanças. Um questionamento possível a respeito de tais métodos é se variações de retroespalhamento ocasionadas por interferências atmosféricas influenciaram negativamente na definição desses valores.

A classificação das mudanças consiste na separação das detecções em classes (duas ou mais), e pode ser realizada de maneira supervisionada (onde o classificador recebe dados de entrada para treinamento) ou não-supervisionada (sem o aporte externo de dados de treinamento). Diversas são as técnicas de classificação propostas na literatura, que podem ser divididas em tradicionais e baseadas em Inteligência Artificial (IA). Nos últimos anos, a tecnologia de IA tornou-se foco de pesquisa no desenvolvimento de novos métodos de detecção e classificação de mudanças (SHI et al., 2020b). IA pode ser definida como a capacidade de um sistema de interpretar corretamente dados externos, de aprender com esses dados e de usar esses aprendizados para atingir objetivos e tarefas específicas por meio de adaptação flexível. A IA usa informações externas obtidas por meio de diferentes fontes de dados como uma entrada para identificar regras e padrões subjacentes, contando com abordagens de Aprendizado de Máquina, que, de modo geral, descreve métodos que ajudam os computadores a aprender sem serem programados explicitamente (KAPLAN & HAENLEIN, 2019). Assim, o Aprendizado de Máquina é parte essencial da IA, já que seus algoritmos são capazes de modelar assinaturas de classe complexas, podem aceitar uma variedade de dados preditores de entrada e podem ser não-paramétricos ou semiparamétricos. Uma ampla gama de estudos demonstra que esses métodos tendem a produzir maior precisão em comparação com classificadores paramétricos tradicionais, especialmente para dados complexos com um espaço de recursos de alta dimensão, ou seja, muitas variáveis preditoras (MAXWELL et al., 2018).

2.9 O uso do Aprendizado de Máquina para detecção de mudanças em imagens SAR

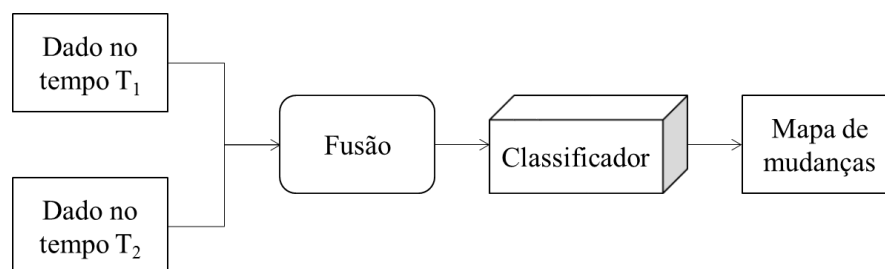
Métodos de detecção de mudanças baseadas em Aprendizado de Máquina para supressão de *speckle* e extração de feições em imagens SAR são o estado da arte, especialmente os denominados *Autoencoders* (AE) (DE et al., 2017) e redes neurais convolucionais (*Convolutional Neural Network* – CNN) (CUI et al., 2019; JATURAPITPORNCHAI et al., 2019; LI et al., 2019).

2.9.1 Estruturas dos modelos de Aprendizado de Máquina para detecção de mudanças

As estruturas dos modelos de detecção e classificação de mudanças baseados em Aprendizado de Máquina (*Machine Learning* - ML) podem ser resumidas em três tipos: de fluxo único, fluxo duplo e integração de vários modelos, conforme descritas abaixo (SHI et al., 2020b). As estruturas de fluxo único podem ser classificadas em estruturas de classificação direta e mapeamento baseado em transformação.

1. Estruturas de classificação direta (Figura 13): são usados vários métodos de processamento para a fusão entre as imagens multitemporais, gerando uma imagem intermediária sobre a qual o modelo de Aprendizado de Máquina irá treinar para classificar a imagem fusionada. Os métodos de fusão foram abordados no início da Seção 2.8. Através dessa estrutura, a tarefa de detecção de mudança é convertida em uma tarefa de classificação, que pode ser binária (mudança e não-mudança) ou multiclasse (deferentes tipos de mudanças). A chave para um resultado de classificação satisfatório está na seleção das amostras de treinamento. DONG et al. (2019) adotaram essa abordagem em sua proposta de modelo de detecção de mudanças baseado em Aprendizado de Máquina.

Figura 13. Diagrama esquemático da estrutura de classificação direta.




Fonte: adaptado de Shi et al. (2020b).

2. Mapeamento baseado em transformação (Figura 14): é um método usual para detecção de mudanças em dados heterogêneos, como por exemplo imagens provenientes de diferentes sensores ou de diferentes resoluções. Consiste no uso do método de Aprendizado de Máquina para aprender as transformações das feições de mapeamento, e usar o aprendizado para realizar a transformação em um tipo de dado. As feições transformadas correspondem às feições do outro tipo de dado. O mapa de mudança pode

ser obtido por meio da análise de decisão sobre as feições correspondentes dos dois tipos de dados. Zhang et al. (2016) adotaram essa abordagem para a detecção de mudanças entre uma imagem SAR e uma imagem óptica de diferentes resoluções espaciais.

Figura 14. Diagrama esquemático de estrutura baseada em transformação de atributos de mapeamento.




Fonte: adaptado de Shi et al. (2020b).

As estruturas de fluxo duplo podem ser classificadas em estrutura siamesa, estrutura baseada em transferência de aprendizado e estrutura de pós classificação.

3. Estrutura Siamesa (Figura 15): consiste em duas sub-redes com a mesma estrutura, ou seja, extratores de atributos, que convertem os dados de entrada de dois períodos em mapas de atributos (ZHAN et al., 2017). Finalmente, o mapa de mudança é obtido usando a análise de mudança, ou seja, um tomador de decisão. A principal vantagem dessa estrutura é que suas duas sub-redes são treinadas diretamente ao mesmo tempo para aprender as características profundas dos dados de entrada de dois períodos.

Figura 15. Diagrama esquemático da estrutura Siamesa.

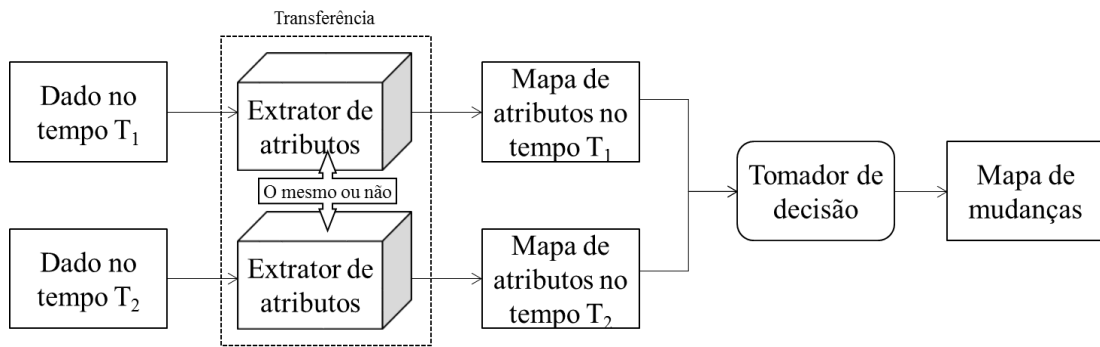


Fonte: adaptado de Shi et al. (2020b).

4. Estrutura baseada em transferência de aprendizado (Figura 16): consiste em uma proposta para atenuar a falta de amostras de treinamento. Essa estrutura utiliza o treinamento realizado em uma imagem para a classificação de outra imagem, ou seja, os atributos aprendidos na imagem original podem ser transferidos como atributos úteis na nova imagem (BALL et al., 2017). O modelo de Aprendizado de Máquina pré-treinado, como um extrator de atributos, é usado para gerar mapas de atributos para dois

períodos, e os extratores de atributos dos dois períodos podem ser os mesmos. Com base na ideia de transferência de aprendizagem, o modelo de Aprendizado de Máquina pré-treinado também pode ser usado para gerar amostras de treinamento ou máscaras para se proceder aos métodos não supervisionados.

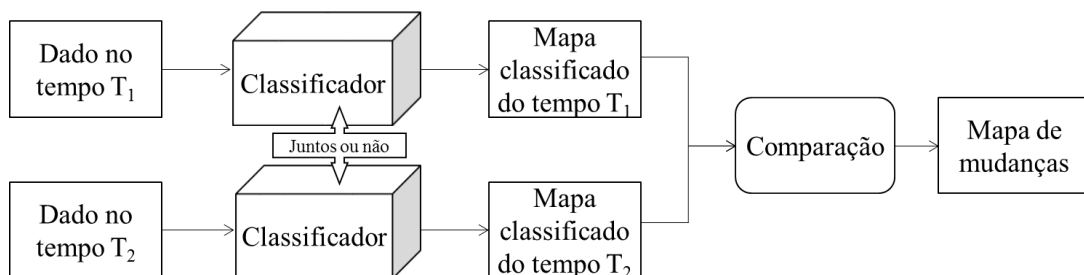
Figura 16. Diagrama esquemático de estrutura baseada em transferência de aprendizado.



Fonte: adaptado de Shi et al. (2020b).

5. Estrutura de pós classificação (Figura 17): consiste em dois classificadores que geralmente podem ser convertidos em tarefas de classificação e treinados de forma conjunta ou independente. Esta estrutura fornece um mapa de classificação para cada período de dados e o mapa de mudança pode ser obtido comparando mapas de classificação. No entanto, a precisão dos resultados da detecção de alterações desse método depende do desempenho dos classificadores. Essa estrutura vem sendo utilizada em diversos trabalhos de classificação de uso da terra, demonstrando bons resultados em posterior análise de detecção de mudanças (WU et al., 2017).

Figura 17. Diagrama esquemático da estrutura de pós classificação.



Fonte: adaptado de Shi et al. (2020b).

Diversos trabalhos têm explorado estruturas que integram vários modelos para melhorar o desempenho dos métodos de detecção de mudanças, sendo estas estruturas híbridas similares às de fluxo duplo, que podem contemplar mais tipos de modelos de Aprendizado de Máquina e serem treinadas em múltiplas etapas. Conforme mencionado em Shi et al. (2020a), a detecção

de mudanças é uma análise espaço-temporal, que pode ser realizada através de um modelo de Aprendizado de Máquina para extração das características espectro-espaciais e posteriormente, através de outro modelo de Aprendizado de Máquina, realizar a análise da dependência temporal. Essas estruturas híbridas são habilmente usadas para detecção de mudança não supervisionada (GONG et al., 2017) e detecção de mudança no nível do objeto (HAN et al., 2019), e tornam o processo de detecção de alterações mais complexo, enquanto melhoram seu desempenho.

2.9.2 Principais métodos de Aprendizado de Máquina

Os métodos de Aprendizado de Máquina têm apresentado resultados relevantes nas mais variadas aplicações (ZHANG & MA, 2012). Eles variam em estratégias de funcionamento e implementação, cujas características são indicadas para diferentes classes de problemas.

Conforme apresentado na Subseção 2.9.1, as estruturas dos modelos de Aprendizado de Máquina para detecção de mudanças contemplam, em geral, uma fase de extração de atributos e uma de classificação, podendo ser uma ou ambas baseadas em Aprendizado de Máquina, e podendo ainda ocorrer de maneira supervisionada ou não supervisionada, conforme explanado no início da Seção 2.8. Os principais métodos de Aprendizado de Máquina empregados nesta tese são descritos a seguir. Estas técnicas foram selecionadas por apresentarem resultados promissores em aplicações de sensoriamento remoto (BELGIU & DRĂGU, 2016).

Entre as técnicas, destacam-se os *ensemble classifiers* (ou, em tradução livre para o português, conjunto de classificadores). Esses classificadores podem ser baseados em um classificador supervisionado individual ou em uma série de diferentes classificadores supervisionados que são treinados usando as abordagens de *bagging* ou *boosting*, ou variações dessas abordagens. Na abordagem de *bagging*, também conhecida como abordagem de agregação de *bootstrap*, cada classificador do conjunto é treinado em um subconjunto aleatório de um conjunto de amostras de treinamento. Já na abordagem de *boosting*, os classificadores do conjunto são treinados iterativamente usando todas as amostras de treinamento, aumentando as ponderações para as amostras classificadas incorretamente durante o procedimento de treinamento. Trabalhos anteriores mostraram que os métodos de *boosting* e *bagging ensemble* alcançaram maior precisão do que o uso de classificadores únicos como os classificadores de árvore de decisão, além de serem mais estáveis ao ruído nos dados de treinamento (NOWAKOWSKI, 2015; BELGIU & DRĂGU, 2016; CHENG et al., 2020).

2.9.2.1 Random Forest

O classificador Random Forest se tornou popular na comunidade de sensoriamento remoto devido à alta precisão de suas classificações. De acordo com Belgiu & Drăgu (2016), trata-se de um classificador ensemble que utiliza várias árvores de classificação e regressão para realizar uma previsão (Figura 18). As árvores são criadas desenhando um subconjunto de amostras de treinamento por meio da substituição (abordagem *bagging*). Isso significa que uma amostra pode ser selecionada várias vezes, enquanto outra pode não ser selecionada nenhuma vez. Cerca de 2/3 das amostras selecionadas, referidas como amostras dentro do *bag*, são utilizadas para o treinamento das árvores, e o terço restante, referidas como amostras fora do *bag*, para o processo interno de validação cruzada para estimar o desempenho do modelo. Essa estimativa de erro é conhecida como erro *out-of-bag* (OOB).

Cada árvore de decisão é produzida de forma independente sem qualquer poda¹ e cada nó é dividido usando um número de atributos definido pelo usuário (*Mtry*), selecionado aleatoriamente. Ao crescer a floresta até um número de árvores definido pelo usuário (*Ntree*), o algoritmo cria árvores com alta variância e baixo viés. A decisão final pode ser obtida por diferentes estratégias, entre elas, a média aritmética das probabilidades de atribuição de classe calculadas por todas as árvores produzidas. Uma nova entrada de dados não rotulada é avaliada em relação a todas as árvores de decisão criadas no conjunto e cada árvore vota por uma associação de classe. A classe de adesão com o máximo de votos será a selecionada.

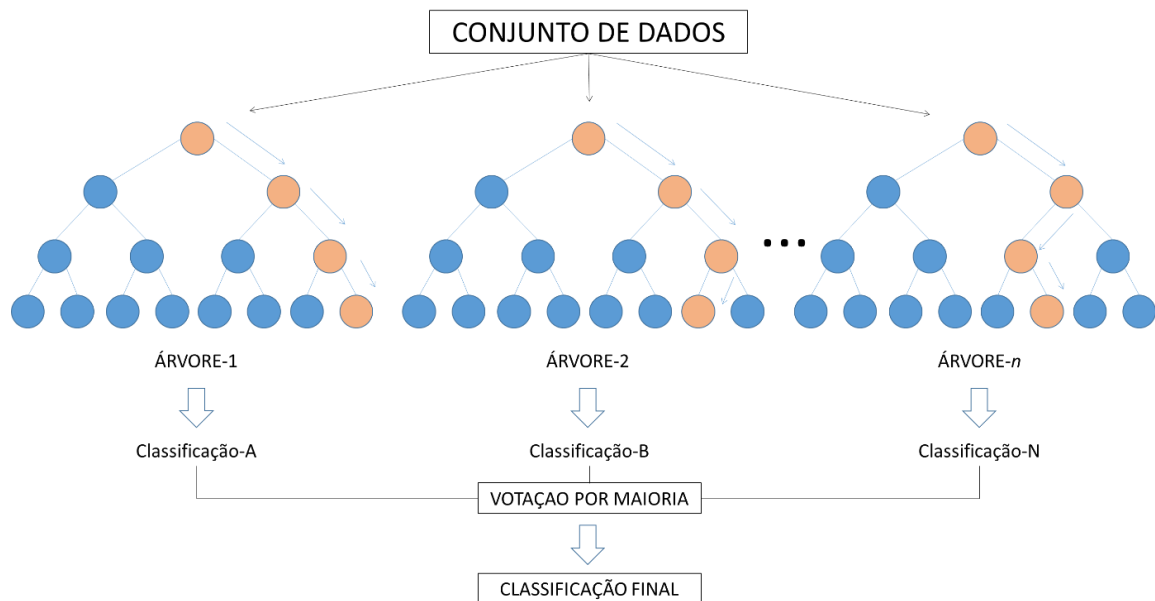
Conforme mencionado anteriormente, dois parâmetros precisam ser definidos a fim de produzir as árvores da floresta: o número de árvores de decisão a serem geradas (*Ntree*) e o número de atributos a serem selecionados e testados para a melhor divisão durante o crescimento das árvores (*Mtry*). Pesquisas teóricas e empíricas destacaram que a precisão da classificação é menos sensível ao *Ntree* do que ao parâmetro *Mtry* (GHOSH et al., 2014). Uma vez que o classificador de RF é computacionalmente eficiente, podem-se adotar valores altos para o *Ntree*. A maioria dos estudos citados por Belgiu & Drăgu (2016) definiu o valor de *Ntree* como 500, porque os erros se estabilizam antes que esse número de árvores de classificação fosse alcançado. Estudos dedicados à aplicação de Random Forest para classificação de imagens SAR apontaram *Ntree* = 70 como sendo o valor a partir do qual não há ganho de qualidade nos

¹ Dada uma árvore T e um nó interno $t \in T$, a poda do ramo T_t de T consiste em remover todos os descendentes de t , declarando-o como nó terminal.

resultados da classificação (DU et al., 2015; TOPOUZELIS & PSYLLOS, 2012). O parâmetro $Mtry$ padrão é definido como a raiz quadrada do número de atributos de entrada.

Um problema frequentemente observado na classificação de imagens de sensoriamento remoto são a ausência ou de amostras que diferenciem fortemente as classes ou indiquem sua tendência. Segundo Lawrence et al. (2006), o Random Forest é capaz de trabalhar bem com essas variáveis fracas.

Figura 18. Diagrama conceitual do classificador Random Forest.



Fonte: adaptado de <https://community.tibco.com/wiki/random-forest-template-tibco-spotfire>.

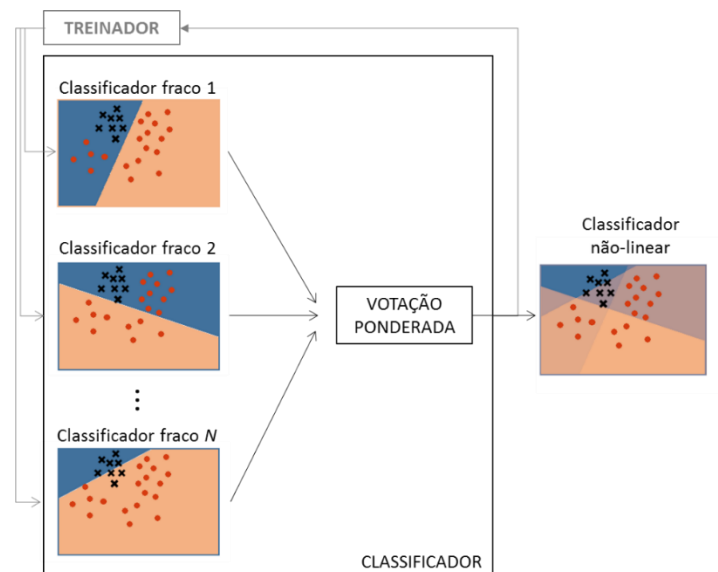
2.9.2.2 Adaboost

A ideia de criar um classificador forte a partir de muitos classificadores fracos vem sendo investigada desde meados da década de 1980 (VALIANT, 1984). O primeiro algoritmo de classificação do tipo *boosting* que se tornou popular por causa de sua confiabilidade, foi desenvolvido por Y. Freund e R. Schapire em 1995 e denominado AdaBoost (FREUND & SCHAPIRE, 1996). Desde então, algumas variantes desse método foram introduzidas, bem como muitos outros algoritmos de *boosting* foram propostos.

As árvores de decisão denominadas *Boosted DTs* (ou árvores de decisão aumentadas) (Figura 19) também são métodos *ensemble* que utilizam árvores de decisão. Porém, neste caso, à medida em que os modelos são construídos, eles são adaptados na tentativa de minimizar os erros das árvores anteriores (MAXWELL et al., 2018). Um tipo de *Boosted DT* é denominado

Adaptive Boosting, ou Adaboost. O método Adaboost compreende três componentes: *weak learners*, em tradução livre, aprendizes fracos, que são as árvores individuais (*stumps*), preditoras individualmente ruins; uma função de perda que aplica uma penalidade para classificações incorretas; e um modelo aditivo que permite que os *weak learners* individuais sejam combinados de modo que a função de perda seja minimizada. O conjunto incorpora todas as árvores, uma vez que o modelo aditivo é projetado de forma que a combinação de todas as árvores e não apenas uma ou mais árvores finais, forneça uma solução ótima.

Figura 19. Diagrama conceitual do classificador Adaboost.

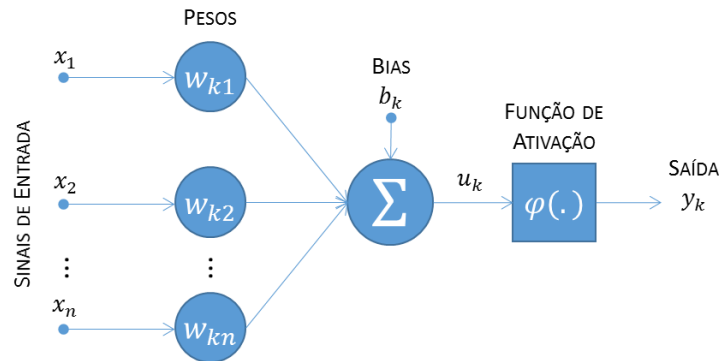


Fonte: adaptado de Wang et al. (2015).

2.9.2.3 Redes Neurais Artificiais

O conceito de Redes Neurais Artificiais (*Artificial Neural Network - ANN*) faz uma analogia matemática aos axônios do cérebro de um animal e suas muitas interconexões por meio de sinapses (ATKINSON & TATNALL, 1997). Elas têm sido utilizadas nas mais variadas aplicações (ABIODUN et al., 2018), entre elas, sensoriamento remoto (CHENG et al., 2020). Os elementos básicos de uma ANN são os neurônios, equivalentes aos axônios biológicos, que são organizados em camadas (Figura 20).


Figura 20. Diagrama esquemático de um neurônio artificial.



Uma ANN tem camadas mínimas de entrada e saída, com um neurônio para cada variável de entrada e um neurônio para cada classe de saída. Além disso, as ANNs normalmente têm nós ocultos (opcionais) organizados em uma ou mais camadas adicionais. Alguns modelos de ANN possuem, como característica, que todos os neurônios em uma camada estão conectados a todos os neurônios em todas as camadas adjacentes. Essas conexões têm pesos que são denominadas totalmente conectadas. Os pesos nas conexões, em combinação com a função de ativação, tipicamente não linear, modificam ainda mais os valores em cada neurônio e determinam como os valores de entrada são mapeados para valores nos nós de saída. Claramente, aumentar o número de neurônios na camada oculta e, especialmente, adicionar ainda mais camadas ocultas, aumenta rapidamente o potencial para descrever limites de decisão muito complexos. As redes neurais são normalmente treinadas por valores iniciais aleatórios para os pesos e, em seguida, ajustados iterativamente esses pesos e observados o efeito nos nós de saída. Os desafios no uso das ANNs são: a etapa de treinamento pode ser lenta e trabalhosa; pode ocorrer a super adaptação, ou sobreajuste ou ainda *overfitting* da rede; e existem muitos parâmetros a serem especificados pelo usuário (MAXWELL et al., 2018).

A principal diferença entre as abordagens estatísticas e neurais para classificação é que as abordagens estatísticas dependem de um modelo assumido, enquanto as abordagens neurais dependem dos dados (ATKINSON & TATNALL, 1997). Existem diversos tipos de redes neurais. Neste trabalho, será explorada a rede denominada redes de múltiplas camadas, sendo uma das mais famosas, a *Multi-Layer Perceptron* (MLP), perceptron multicamadas, em tradução livre) (Figura 21), composta por neurônios artificiais.

Figura 21. Diagrama esquemático do algoritmo MLP.



Fonte: adaptado de Atkinson & Tatnall (1997).

Na rede apresentada na Figura 21, a primeira camada possui duas entradas, três neurônios na primeira camada escondida, dois neurônios na segunda camada escondida e uma saída. As múltiplas setas que saem de cada neurônio são uma representação gráfica para indicar que uma saída única é utilizada como entrada para os n neurônios da camada seguinte. Uma MLP segue o modelo “*feed-forward*”, o que significa que as entradas são enviadas para o neurônio, processadas, resultando em uma saída. Isso significa que a rede (um neurônio) lê da esquerda para a direita.

O processo de treinamento de uma MLP consiste em fazer com que o modelo aprenda os valores ideais de pesos e bias. Apresentamos, ao modelo, os dados de entrada e as possíveis saídas, treinamos o modelo e os pesos e bias são aprendidos. Com o modelo treinado, pode-se apresentar novos dados de entrada e o modelo será capaz de prever a saída.

2.9.2.3.1 Arquiteturas das ANNs


Quando nos referimos à arquitetura de uma ANN, estamos falando a respeito da disposição dos neurônios, um em relação ao outro. Existem diferentes tipos de arquiteturas, mas antes de descrevê-las, é necessário apresentar algumas terminologias usuais, importantes para o entendimento dessas arquiteturas. Conforme apresentado na Figura 20, que exemplifica uma ANN, a camada mais à esquerda é denominada camada de entrada, que é responsável pelo recebimento dos dados a serem analisados, assim como a correspondente associação com os pesos de entrada. A camada mais à direita é denominada camada de saída, que contém o(s) neurônio(s) de saída. A camada de saída agrega os dados das camadas anteriores e ativa uma resposta adequada. As camadas do meio são as chamadas camadas escondidas (ou ocultas).

Elas têm por finalidade extrair as informações associadas ao sistema inferido, sendo também responsável pela maior parte do processamento destes dados (SILVA et al., 2010).

Em geral, as arquiteturas das ANNs podem ser agrupadas em três categorias, descritas a seguir:

1. Redes Neurais *Feed-Forward* (Figura 20): são os tipos de arquiteturas de ANN mais comumente aplicadas, o fluxo é sempre na direção da camada de saída. Quando há mais de uma camada escondida, essas redes são chamadas de Redes Neurais Profundas (ou *Deep Learning*). As tarefas dos neurônios de uma camada são função não-linear das tarefas da camada anterior. Podem ser classificadas em *Feed-Forward* de camada simples (uma camada de entrada diretamente associada a um ou mais neurônios que vão gerar a resposta de saída) e *Feed-Forward* de camadas múltiplas (constituídas por uma ou mais camadas escondidas de neurônios). As primeiras são usualmente empregadas em problemas de classificação de padrões e filtragem, e são exemplos os tipos Perceptron e Adaline (WIDROW & LEHR, 1990). As segundas são empregadas em problemas de aproximação de funções, classificação de padrões, identificação de sistemas e otimização, e são exemplos os tipos Perceptron Multicamadas e Redes de Base Radial. São ainda exemplos de ANNs do tipo *Feed-Forward*, os Auto-Encoders (GOODFELLOW et al., 2016).
2. Redes Neurais Recorrentes (Figura 22): diferentemente do que ocorre com as redes *Feed-Forward*, as redes recorrentes tomam como entrada não apenas o que lhe foi apresentado, mas também o que perceberam anteriormente no tempo, ou seja, a decisão alcançada na etapa de tempo $t-1$ influencia na decisão que tomará no tempo t . Portanto, as redes recorrentes têm duas fontes de entrada: o presente e o passado recente, o que atribui a esse tipo de rede a capacidade de memória. Essa informação sequencial é preservada no estado oculto da rede recorrente, que consegue passar por muitas etapas de tempo à medida que ela avança em cascata para afetar o processamento de cada novo exemplo. Tais correlações entre eventos são separadas por muitos momentos, e essas correlações são chamadas de “dependências de longo prazo”, pois um evento no tempo depende e é uma função de um ou mais eventos que o precederam. São exemplos, as redes Hopfield (SIMPSON, 1990) e *Perceptron* Multicamadas com Realimentação (SILVA et al., 2010).

Figura 22. Diagrama esquemático de uma arquitetura de rede recorrente.



Fonte: adaptado de Eliasy & Przychodzen (2020).

3. Redes conectadas simetricamente: são redes semelhantes às recorrentes, diferindo no fato de as conexões entre as unidades serem simétricas (têm o mesmo peso em ambas as direções). As redes conectadas simetricamente sem unidades ocultas são denominadas Redes Hopfield, e as conectadas simetricamente com unidades ocultas são chamadas de Máquinas de Boltzmann.

2.9.2.3.2 Aprendizagem das Redes Neurais Artificiais

O processo de aprendizagem de uma ANN consiste, basicamente, na adaptação de seus pesos a partir dos estímulos fornecidos por um conjunto de dados, visando à convergência. Esse processo pode ser, conforme já mencionado, supervisionado ou não supervisionado (GHARBIA et al., 2020). A aprendizagem supervisionada se caracteriza pela presença de um especialista que indica, a partir dos pares de dados de entrada e de saída desejada, os erros da rede. Esse conjunto de dados de entrada e saída constituem o conjunto de treinamento, o qual representa o conhecimento do especialista a respeito do problema abordado. Assim, é possível utilizar o erro calculado e o vetor de entrada para obtenção do vetor de pesos (REZENDE, 2005).

Na aprendizagem não supervisionada, não há o fornecimento desses exemplos de pares de dados de entrada e saída desejada. Assim, o ajuste dos pesos ocorre baseado nas regularidades estatísticas dos dados fornecidos à rede. Esta forma de treinamento permite que a rede neural categorize os dados (REZENDE, 2005).

A aprendizagem de uma ANN do tipo Multi Layer Perceptron (MLP) busca minimizar uma função de erro e maximizar a capacidade de generalização da rede. A capacidade de generalização refere-se à capacidade de a rede de classificar corretamente (ou próximo do correto) um dado de um conjunto de dados não utilizado para treinamento da rede (HAYKIN, 2008).

Os passos para aprendizagem de uma MLP são, de maneira resumida, os que seguem:

- a) Apresentação dos dados de entrada;
- b) Modelagem da rede: definição do número de camadas, da quantidade de neurônios em cada camada, e da função de ativação;
- c) Configuração de parâmetros: a depender do algoritmo de aprendizagem selecionado, haverá diversos parâmetros a serem definidos, que podem ser modificados durante o processo de aprendizagem. Alguns algoritmos de aprendizagem serão detalhados na Seção 2.9.2.3.2.2;
- d) Definição do critério de parada (Seção 2.9.2.3.2.3);
- e) Execução do algoritmo de aprendizagem; e
- f) Avaliação da capacidade de generalização da rede: para isso, pode-se utilizar a técnica de validação cruzada, para a qual divide-se os dados de entrada em subconjuntos, que serão utilizados para estimação, avaliação e teste do modelo.

2.9.2.3.2.1 Funções de ativação

A função de ativação (Equação 22) permite que pequenas alterações nos pesos e bias resultem em uma pequena alteração na saída, permitindo que uma rede de neurônios artificiais aprenda. A função de ativação é um elemento fundamental de uma rede neural artificial, pois é a partir dela que se decide se um neurônio deve ser ativado ou não, ou seja, se a informação que o neurônio está recebendo é importante ou deve ser ignorada.

$$Saída = Ativação(\sum(pesos * entrada) + bias) \quad \text{Equação 22}$$

A função de ativação é uma transformação não linear que fazemos no sinal de entrada. Essa saída transformada é então enviada para a próxima camada de neurônios como uma entrada. Quando não temos uma função de ativação, os pesos e o bias simplesmente fazem uma transformação linear, a qual é simples de resolver, mas limitada em sua capacidade de solucionar problemas complexos. Uma rede neural sem função de ativação é, em essência, apenas um modelo de regressão linear. Assim, a função de ativação faz uma transformação não linear dos dados de entrada, tornando o neurônio capaz de aprender e realizar tarefas mais complexas (NIELSEN, 2015). As funções de ativação tornam possível a propagação posterior, desde que os gradientes (NIELSEN, 2015) sejam fornecidos juntamente com o erro para atualizar os pesos e bias, em um processo conhecido como *backpropagation*.

Existem vários tipos de função de ativação, e essa é uma área de pesquisa em constante evolução. Algumas dessas funções serão detalhadas a seguir (SILVA et al., 2010):

1. Função linear (Equação 23): é uma função cuja derivada é constante, ou seja, não depende do valor de entrada x . Isso significa que toda vez que ocorrer o *backpropagation*, o gradiente será o mesmo, e por isso não haverá melhora do erro, independentemente do número de camadas.

$$f(x) = ax \quad (\text{Equação 23})$$

2. Função sigmoide (Equação 24): é uma função amplamente utilizada. Apresenta o formato de S, variando de 0 a 1, tendendo a empurrar os valores de y para os extremos, que é uma característica desejável quando o objetivo é classificar um valor em uma classe específica. Vários neurônios com função sigmoide de ativação resultam em uma saída também não linear.

$$f(x) = 1/(1 + e^{-x}) \quad (\text{Equação 24})$$

Um problema relacionado a esse tipo de função são os baixos valores de gradiente, pois quanto mais esse se aproxima de zero, menos a rede está realmente aprendendo. Outro problema é o fato de a faixa de valores estar compreendida entre 0 e 1, o que faz com que os valores recebidos pelo próximo neurônio sejam todos positivos, o que nem sempre é desejável. Esse é o problema solucionado pela próxima função a ser apresentada, a tangente hiperbólica.

3. Função tangente hiperbólica – Tanh (Equação 25): é o escalonamento da função sigmoide, tornando-a simétrica em relação à origem, variando de -1 a 1.

$$\tanh(x) = 2/(1 + e^{-2x}) - 1 \quad (\text{Equação 25})$$

A função tanh é contínua e diferenciável em todos os pontos, e por não ser linear, possibilita o *backpropagation* nos erros.

4. Função ReLU (Rectified Linear Unit) (Equação 26): é a função de ativação não-linear mais comumente utilizada em ANNs. Ela produz resultados no intervalo $[0, \infty]$. Sua principal vantagem em relação às demais funções é não ativar todos os neurônios ao mesmo tempo, já que se entrada for negativa, ela será convertida em zero, e a função não será ativada. Isso torna a rede esparsa e, portanto, eficiente computacionalmente.

$$f(x) = \max(0, x) \quad (\text{Equação 26})$$

Porém, caso recebam somente valores negativos, esses neurônios podem “morrer” e não aprender nada, sendo essa uma desvantagem da função ReLU. Além disso, pode produzir ativações explodidas por não possuir um limite positivo.

5. Função PReLU (*Parametric ReLU*) (HE et al., 2015): é uma adaptação da função ReLU, que ao invés de definir a função ReLU como 0 para $x < 0$, define-se conforme segue (Equação 27):

$$f(x) = \begin{cases} ax, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (\text{Equação 27})$$

Aqui, x é a entrada da ativação não linear f , e a é um coeficiente que controla a inclinação da parte negativa. Quando $a = 0$, a função torna-se ReLU; quando a é um parâmetro que pode ser aprendido, nos referimos à Equação 33 como função ReLU Paramétrica (PReLU). Se a for pequeno e fixo, a função PReLU torna-se uma função Leaky ReLU (LReLU) (p.ex. $a = 0,01$). O objetivo da função LReLU é evitar gradientes zero.

6. Função Softmax (Equação 28): é também um tipo de função sigmoide, útil para lidar com problemas de classificação, quando este envolve várias classes. A função softmax transforma as saídas para cada classe em valores entre 0 e 1, dividindo ainda pela soma das saídas, o que dá a probabilidade de a entrada estar em uma determinada classe.

$$\phi_i = \frac{e^{z_i}}{\sum_{j \in \text{grupo}} e^{z_j}} \quad (\text{Equação 28})$$

Sendo: i o índice do neurônio de saída (o) sendo calculado;
 j os índices de todos os neurônios de um nível; e
 z designa o vetor de neurônios de saída.

A função de ativação softmax é calculada de forma diferente das demais apresentadas, já que nesta a saída de um neurônio depende dos outros neurônios de saída.

Atualmente, a função de ativação mais utilizada nas camadas escondidas das ANNs é a ReLU e suas adaptações. Para as camadas de saída, a escolha deve considerar o problema abordado. Para uma classificação binária, pode-se recorrer à função sigmoide ou ainda à tangente hiperbólica. Para classificações não-binárias, pode-se adotar a função softmax. E para problemas de regressão, usa-se a função de ativação linear.

2.9.2.3.2 Algoritmos de aprendizagem

São denominados algoritmos de aprendizagem um conjunto de regras bem definidas para solução de um problema de aprendizagem. Esses algoritmos operam construindo um modelo a partir de inputs amostrais para realizar previsões ou decisões guiadas pelos dados ao invés de simplesmente seguindo instruções programadas. São algoritmos de aprendizagem usuais:

1. *Backpropagation*: é um algoritmo de aprendizagem supervisionada baseado na regra delta (ou regra de Widrow-Hoff). Seu objetivo é a minimização da função do erro médio quadrático (Equação 29):

$$E(n) = \frac{\sum_{j=1}^k (d_j(n) - y_j(n))^2}{2} \quad (\text{Equação 29})$$

Sendo: n = época de treinamento (cada vez que se apresenta uma amostra para ajuste dos pesos sinápticos e limiares da rede);

k = número de neurônios da camada de saída;

d_j = valor desejado do neurônio j ; e

y_j = saída fornecida pelo neurônio.

De acordo com Haykin (2008), o processo de treinamento possui duas fases: *forward* (ocorre a propagação do sinal de entrada ao longo da rede); e *backward* (um sinal de erro é produzido através da comparação da saída obtida com a saída desejada. Este sinal é propagado para trás ao longo da rede. Nessa fase, ocorre a correção dos pesos). O algoritmo compreende os passos seguintes:

- a. Inicialização com atribuição de pesos aleatórios de distribuição uniforme aos dados.
- b. Para cada entrada, realiza-se a propagação do sinal por meio da Equação 34:

$$y_k = \varphi\left(\sum_{j=0}^n w_{kj} x_j\right) \quad (\text{Equação 30})$$

Sendo: w_{kj} = peso correspondente à entrada j ; e

x_j = entrada j do neurônio.

- c. O erro de cada unidade de saída é calculado segundo a equação:

$$e_j(n) = d_j(n) - y_j(n) \quad (\text{Equação 31})$$

- d. São então calculados os gradientes locais da rede, sendo que para a última camada, utiliza-se a equação:

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)) \quad (\text{Equação 32})$$

em que $v_j(n)$ é dado pela equação:

$$v_j(n) = \sum_{j=1}^m w_{kj}(n) x_j(n) \quad (\text{Equação 33})$$

O gradiente para as camadas escondidas é dado por (Equação 38):

$$\delta_j^{(l)}(n) = \varphi'_j(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{l+1}(n) \quad (\text{Equação 34})$$

Sendo: l = camada; e

K = número de neurônios da camada seguinte.

Os pesos são ajustados de acordo com a regra delta generalizada (Equação 35):

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha w_{ji}^{(l)}(n-1) + \eta \delta_j^{(l)}(n) y_j^{(l-1)}(n) \quad (\text{Equação 35})$$

em que η é a taxa de aprendizado e α é a constante momento que é aplicada sobre a variação anterior obtida a fim de acelerar a convergência da rede, além de provocar um efeito estabilizante no treinamento.

- e. Enquanto o critério de parada adotado não for atendido, o processo é repetido a partir do passo b, apresentando uma nova época de exemplos de treinamento.
2. Adam (*Adaptive Moment Estimation*) (KINGMA & BA, 2015): é uma variação propondo otimização do *backpropagation*, que calcula as taxas individuais de aprendizagem adaptativa para diferentes pesos da ANN a partir das estimativas de primeiro e segundo momentos dos gradientes consecutivos. Algumas das vantagens da Adam são que as magnitudes das atualizações de parâmetros são invariantes ao reescalonamento do gradiente, seus tamanhos de passos são aproximadamente limitados pelo hiperparâmetro de tamanho de passos, não requer um objetivo estacionário, trabalha com gradientes esparsos e executa uma forma de anelamento do tamanho do passo. As equações do método Adam estão descritas em Kingma & Ba (2015).
3. SGD (*Stochastic Gradient Descent*) (BOTTOU, 2010): o método descida de gradiente, quando aplicado a algoritmos de Aprendizado de Máquina, é utilizado para encontrar o mínimo de uma função de erro (*loss function*). Um algoritmo de Aprendizado de Máquina normalmente se inicia em um ponto, e a partir desse ponto, é calculado o seu gradiente, de modo que seja possível minimizar o erro da *loss function*. A função é basicamente calculada pela derivada da função em determinado ponto, essa derivada aponta para onde a função está crescendo. A principal diferença entre o SGD e o algoritmo de descida de gradiente padrão é que, ao invés de realizar somente uma atualização dos parâmetros para uma descida de gradiente calculada a partir de todo o conjunto de dados, é realizado uma atualização para cada instância de treinamento. O

SGD é considerado um método eficiente computacionalmente quando se trabalha com um grande conjunto de dados.

4. L-BFGS-B (Limited-memory Broyden-Fletcher-Goldfarb-Shanno Bound-constrained) (BYRD et al., 1995): o algoritmo é uma extensão do L-BFGS, que tem origem no algoritmo BFGS (FLETCHER, 2000), considerado um método iterativo quasi-Newton de busca local. É um algoritmo que trata de problemas de otimização não linear com restrição simples ($a \leq x \leq b$), mas que também pode ser usado em problemas irrestritos. O método assume que o cálculo da matriz Hessiana é impraticável ou muito custoso e utiliza uma aproximação através da memória limitada BFGS (*Broyden-Fletcher-Goldfarb-Shanno*) que atualiza a matriz aproximada, a cada iteração, utilizando uma determinada quantidade de informação de $m_{l-b f gs-b}$ iterações passadas. Valores usualmente empregados para o hiperparâmetro $m_{l-b f gs-b}$ estão entre 3 e 20. A matriz de memória aproximada é usada na definição de um modelo quadrático da função objetivo para que uma busca em direção seja realizada. Primeiramente, o método de gradiente projetado identifica o conjunto com os limites (das variáveis de entrada) que estão ativos, e então o modelo quadrático é aproximadamente minimizado em relação às variáveis livres. Então, o próximo ponto de avaliação é calculado através da busca em linha, utilizando um determinado tamanho de passo $\alpha_{l-b f gs-b}$ (hiperparâmetro) (ALVARENGA Jr., 2018). Uma característica importante do algoritmo L-BFGS-B é o fato de o mesmo evitar o armazenamento das aproximações sequenciais da matriz Hessiana, o que permite que ele generalize bem as altas dimensionalidades. O algoritmo armazena informações sobre a curvatura da função objetivo nas últimas k iterações e utiliza esta mesma informação para encontrar uma nova direção de busca (FONSECA, 2017).

2.9.2.3.2.3 Critérios de parada

A modificação dos pesos no processo de aprendizagem ocorre até que o critério de parada seja atendido. O critério de parada mais empregado é o número máximo de épocas de treinamento, em que uma época é dada pela apresentação de todas as amostras do conjunto de treinamento à rede neural. Em geral, devem ser consideradas a taxa de erro médio por ciclo e sua capacidade de generalização. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de *overtraining*, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização. O treinamento deve ser interrompido quando a rede apresentar boa capacidade de generalização e a taxa de erro for

menor que o erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima (HAYKIN, 2008). Alguns dos critérios de parada mais utilizados são:

1. Número de ciclos: define-se o número de vezes em que o conjunto de treinamento é apresentado à rede. Um número alto de ciclos pode levar à perda de capacidade de generalização da rede (*overfitting*), ou seja, à sua especialização, enquanto com um número baixo a rede pode não chegar ao seu melhor desempenho (*underfitting*).
2. Erro: define-se um valor de erro médio quadrático α , e o treinamento é encerrado no momento em que se atinge um valor de erro abaixo do definido. Um valor pequeno de erro médio quadrático não significa necessariamente uma boa generalização. Esse valor é dependente do problema abordado. Sugere-se ir ajustando o α em função do resultado.
3. Combinação dos métodos anteriores: uma alternativa é combinar os dois métodos apresentados anteriormente. O treinamento será encerrado quando qualquer um dos critérios for obtido.
4. Validação: neste método, o treinamento é interrompido a cada x ciclos e é realizada uma estimação de erro da rede sobre o conjunto de dados de teste. A partir do momento em que o erro medido no conjunto de teste apresentar crescimento, o treinamento é encerrado. O que se deseja com esta técnica é descobrir o momento exato em que a rede começa a perder sua capacidade de generalização.

2.9.2.3.3 Conjunto de dados de entrada para Aprendizado de Máquina

Com o discorrer dos conceitos anteriormente expostos, fica evidente que, além dos parâmetros a serem definidos para configuração do método de Aprendizado de Máquina selecionado, o elemento mais importante para que as inferências sejam corretamente realizadas é o dado (ou conjunto de dados) de entrada. Esses dados de entrada já foram mencionados anteriormente como atributos de entrada.

Em aplicações de Aprendizado de Máquina na área de sensoriamento remoto, esses atributos, em geral, referem-se às características das imagens que representam determinado alvo de interesse, podendo ser atributos espectrais, espaciais ou texturais, extraídos da cena, de uma região, ou ainda de dados multitemporais. A seguir, serão descritos alguns dos referidos atributos.

1. Atributos espectrais: as equações estatísticas estão descritas em Everitt & Skrondal (2010).

- a. Contagem: número de pixels contidos em determinado polígono;
 - b. Somatório: soma dos valores dos pixels contidos em um polígono;
 - c. Média: valor médio dos pixels contidos em um polígono;
 - d. Mediana: valor central do conjunto de valores dos pixels contidos em um polígono;
 - e. Desvio-padrão: medida de dispersão em relação à média dos valores dos pixels contidos em um polígono;
 - f. Mínimo: menor valor que ocorre no conjunto de valores dos pixels contidos em um polígono;
 - g. Máximo: maior valor que ocorre no conjunto de valores dos pixels contidos em um polígono;
 - h. Range: Diferença entre o valor máximo e o valor mínimo que ocorrem no conjunto de valores dos pixels contidos em um polígono;
 - i. Minoria: valor que menos ocorre no conjunto de valores dos pixels contidos em um polígono;
 - j. Maioria: valor que mais ocorre no conjunto de valores dos pixels contidos em um polígono; e
 - k. Variância: número de valores únicos que ocorrem no conjunto de valores dos pixels contidos em um polígono.
2. Atributos texturais: as métricas de segunda ordem, também chamadas de co-ocorrência, analisam a relação entre os pares de pixels. Eles usam uma matriz de co-ocorrência para calcular os valores da textura. Essa matriz é uma função da relação angular e da distância entre dois pixels vizinhos. Mostra o número de ocorrências da relação entre um pixel e seu vizinho especificado. Haralick et al. (1973) referiram-se a isso como uma matriz de dependência espacial em tons de cinza. Sua implementação considera quatro direções (0° , 45° , 90° e 135°) entre células vizinhas que são separadas por uma distância d . As equações dos atributos texturais listados abaixo podem ser obtidas em Haralick et al. (1973).
- a. Média: calcula a média local dos valores dos pixels contidos na janela.
 - b. Variância: é uma medida da dispersão dos valores em torno da média local dos valores dos pixels contidos na janela;
 - c. Homogeneidade: medida de homogeneidade usando a equação do "momento inverso da diferença". Os valores variam de 0 a 1.
 - d. Contraste: medida de contraste da matriz de co-ocorrência.

- e. Dissimilaridade: medida de dissimilaridade usando os valores absolutos das diferenças da escala de cinza;
 - f. Entropia: é calculada com base na distribuição dos valores dos pixels na janela, medindo a desordem dos valores. Os valores variam de 0 ao \log do tamanho do kernel.
 - g. Segundo momento: é calculado com base na equação do segundo momento angular. Os valores variam de 0 a 1.
 - h. Correlação: medida de correlação, com valores variando entre -1 e 1.
3. Atributos espaciais:
- a. Área: área total de um polígono, subtraídos os buracos.
 - b. Perímetro: perímetro total de um polígono.
 - c. Compacidade: é uma medida de forma que indica a compacidade do polígono. Um círculo é a forma mais compacta com um valor de $1/\pi$. O valor de compactação de um quadrado é $1/2(\sqrt{\pi})$.
 - d. Convexidade: polígonos são convexos ou côncavos. Este atributo mede a convexidade do polígono através da equação 'Convexidade = comprimento do casco convexo/comprimento'. O valor de convexidade para um polígono convexo sem buracos é 1, enquanto o valor para um polígono côncavo é menor que 1.
 - e. Solidez: é uma medida de forma que compara a área do polígono com a área de uma casca convexa em torno do polígono, segundo a equação 'Solidez = Área / área do casco convexo'. O valor de solidez para um polígono convexo sem orifícios é 1, e o valor para um polígono côncavo é inferior a 1.
 - f. Circularidade: uma medida de forma que compara a área do polígono ao quadrado do diâmetro máximo do polígono. O "diâmetro máximo" é o comprimento do eixo principal de uma caixa delimitadora orientada que envolve o polígono. O índice de circularidade de um círculo é 1 e de um quadrado é $4/\pi$.
 - g. Fator de forma: uma medida de forma que compara a área do polígono ao quadrado do perímetro total. O valor do fator de forma de um círculo é 1 e o valor de um quadrado é $\pi/4$.
 - h. Alongamento: uma medida de forma que indica a proporção do eixo maior do polígono em relação ao eixo menor do polígono. Os eixos principais e secundários são derivados de uma caixa delimitadora orientada que contém o polígono. O valor de alongamento de um quadrado é 1 e o valor de um retângulo é maior que 1.

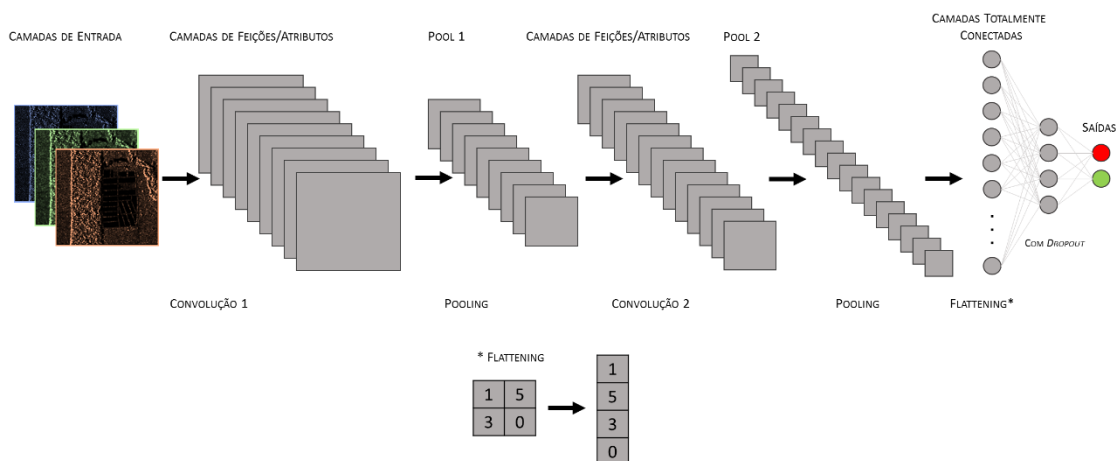
- i. Ajuste retangular: uma medida de forma que indica quão bem a forma é descrita por um retângulo. Este atributo compara a área do polígono com a área da caixa delimitadora orientada que envolve o polígono. O valor de ajuste retangular para um retângulo é 1 e o valor para uma forma não retangular é menor que 1.
- j. Número de buracos: contabilização do número de buracos contidos em um polígono. É um número inteiro.
- k. Área dos buracos/Área sólida: proporção da área total do polígono com a área do contorno externo do polígono. O valor da proporção para um polígono sem furos é 1. É calculado como segue: $\text{Área dos buracos/Área sólida} = \text{Área} / \text{área de contorno externo}$.

Em Wang et al. (2018), os autores extraíram atributos espectrais, espaciais e texturais dos segmentos gerados a partir de imagens ópticas de alta resolução espacial para treinamento de diferentes classificadores, dentre os quais o Random Forest. Lang e Wu (2017) utilizaram atributos espaciais para classificar navios em imagens SAR, utilizando a abordagem *Multiple Kernel Learning* (MKL). Já Chen et al. (2020) utilizaram atributos de textura para discriminar navios em imagens SAR através da mesma abordagem MKL.

2.9.2.4 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs) são um tipo de rede profunda multicamadas com capacidade de aprendizagem, compostas por camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas (Figura 23).

Figura 23. Diagrama esquemático de uma Rede Neural Convolucional.



A entrada das camadas convolucionais $\mathbf{X} \in \mathbb{R}^{n \times w \times h}$ consiste em n mapas de feições/atributos 2D de tamanho $w \times h$. A saída $\mathbf{H} \in \mathbb{R}^{m \times w' \times h'}$ das camadas convolucionais são m mapas de feições/atributos 2D de tamanho $w' \times h'$ via matriz de convolução \mathbf{W} . $\mathbf{W} \in \mathbb{R}^{m \times l \times l \times n}$ são os m filtros treináveis de tamanho $l \times l \times n$ (sendo geralmente $l = 1, 3$ ou 5). O processo de convolução é descrito como $\mathbf{H} = f(\mathbf{W} * \mathbf{X} + b)$, onde $*$ denota operação de convolução 2D e b o *bias*. Em geral, uma função de ativação não linear f é realizada após a operação de convolução. Conforme a estrutura convolucional se aprofunda, as camadas convolucionais podem capturar diferentes feições/atributos (por exemplo, bordas, linhas, cantos, estruturas e formas) dos mapas de feições/atributos de entrada (CHENG et al., 2020). As camadas de *pooling* executam uma operação de máxima ou média sobre uma pequena área de cada mapa de feições de entrada. Podem ser definidas como $\mathbf{H}_l = pool(\mathbf{H}_{l-1})$, em que *pool* representa a função de *pooling* (resume a informação daquela área de *pooling* em um único valor de *pooling* médio, máximo ou estocástico), e \mathbf{H}_{l-1} e \mathbf{H}_l a entrada e saída da camada de *pooling*, respectivamente.

Normalmente, as camadas de *pooling* são aplicadas entre duas camadas convolucionais sucessivas. A operação de *pooling* pode criar invariância, como pequenos deslocamentos e distorções. Para a detecção de objeto e classificação de imagens, a característica de invariância fornecida por camadas de *pool* é muito importante (CHENG et al., 2020). As camadas totalmente conectadas geralmente aparecem na camada superior das CNNs, que podem resumir as feições/atributos extraídos das camadas inferiores. Camadas totalmente conectadas processam sua entrada $\tilde{\mathbf{X}}$ com transformação linear por peso $\tilde{\mathbf{W}}$ e bias $\tilde{\mathbf{b}}$, mapeando a saída da transformação linear por uma função de ativação não linear f , segundo a equação $y = f(\tilde{\mathbf{W}} \cdot \tilde{\mathbf{X}} + \tilde{\mathbf{b}})$. Na tarefa de classificação, para gerar a probabilidade de cada classe, um classificador *softmax* é geralmente conectado à última camada totalmente conectada. O classificador *softmax* é usado para normalizar a saída da camada totalmente conectada $y \in \mathbb{R}^c$ (em que c é o número de classes) entre 0 e 1, que pode ser descrito como $P(y_i) = e^{y_i} / \sum_{i=1}^c e^{y_i}$, em que e é a função exponencial.

A saída do classificador *softmax* denota a probabilidade de que uma determinada imagem de entrada pertença a cada classe. O método *dropout*² opera nas camadas totalmente conectadas

² Neste método, dado um valor $p \in (0, 1)$, em cada época de treinamento cada neurônio das camadas ocultas tem uma probabilidade p de ser "esquecido", deixando de contribuir com a rede e de ser treinado, voltando ao normal na época seguinte.

para evitar *overfitting*³, dado que uma camada totalmente conectada geralmente contém um grande número de parâmetros (CHENG et al., 2020). Os métodos baseados em CNNs aplicados ao sensoriamento remoto podem ser divididos em três grupos: o que utiliza CNNs pré-treinadas como extratoras de atributos; ajuste fino de CNNs pré-treinadas no conjunto de dados; e CNNs de treinamento a partir do zero. A extração de atributos das imagens ocorre através dos denominados *embedders*, os quais leem as imagens e utilizam modelos de aprendizado profundo para calcular um vetor de atributos para cada imagem. Ele retorna uma tabela de dados com colunas adicionais contendo os descritores da imagem. Exemplos de *embedders* são:

- a. InceptionV3 (SZEGEDY et al.,): é a rede neural profunda do Google para reconhecimento de imagem, que consiste em 48 camadas. Ela é treinada no conjunto de dados ImageNet⁴, tendo demonstrado atingir uma precisão superior a 78% neste conjunto. O modelo é composto de componentes simétricos e assimétricos, incluindo convoluções, agrupamentos médios, agrupamentos máximos, concatenações, desistências e camadas totalmente conectadas. A normalização em lote é usada extensivamente em todo o modelo e aplicada às entradas de ativação. A perda é calculada por meio da função *softmax*.
- b. VGG16 (SIMONYAN & ZISSERMAN, 2015): é um modelo de rede neural convolucional que consiste em 16 camadas contendo seus respectivos pesos, treinada no conjunto de dados ImageNet, tendo atingido 93% de precisão em sua classificação. Em vez de ter um grande número de hiperparâmetros, a rede possui camadas de convolução de filtro 3×3 com uma passada 1, sempre utilizando o mesmo *padding*, e a camada *maxpool* de filtro 2×2 de passada 2. Segue-se este arranjo de convolução e camadas *maxpool* de forma consistente em toda a arquitetura. No final, têm-se duas camadas totalmente conectadas, seguidas por um *softmax* para a saída.
- c. VGG19: é uma variante do modelo VGG que contém 19 camadas profundas, que atingiu 93% de precisão na classificação do conjunto ImageNet.

³ Um modelo que aprende muito bem o conjunto de dados de treinamento, com bom desempenho no conjunto de dados de treinamento, mas não apresenta bom desempenho em uma nova amostra.

⁴ ImageNet é um conjunto de dados de mais de 15 milhões de imagens rotuladas de alta resolução pertencentes a cerca de 22.000 categorias. As imagens foram coletadas da web e rotuladas por rotuladores humanos usando a ferramenta de crowdsourcing Mechanical Turk da Amazon.

- d. SqueezeNet (IANDOLA et al., 2016): é uma rede neural convolucional profunda de 26 camadas, que atinge precisão de nível AlexNet⁵ no ImageNet com 50 vezes menos parâmetros. A SqueezeNet emprega estratégias de arquitetura que reduzem o número de parâmetros, notadamente com o uso de módulos de disparo que "comprimem" os parâmetros usando convoluções 1×1 .
- e. Painters: é um modelo treinado no conjunto de dados da competição *Painter by Numbers on Kaggle*⁶, composto por 79.433 imagens de pinturas de 1.584 diferentes pintores, cujo objetivo foi examinar pares de pinturas e determinar se são do mesmo artista. A rede é composta, no total, por 24 camadas.
- f. DeepLoc (ARMENTEROS et al., 2017): é uma rede convolucional treinada em 21.882 imagens de células individuais que foram atribuídas manualmente a um dos 15 compartimentos de localização. É um algoritmo de predição que usa redes neurais profundas para prever a localização subcelular de proteínas baseando-se apenas nas informações de sequência. Em seu núcleo, o modelo de predição usa uma rede neural recorrente que processa toda a sequência da proteína e um mecanismo de atenção que identifica as regiões da proteína importantes para a localização subcelular. A rede é composta por 11 camadas.

2.9.3 Meta-heurística para otimização do conjunto de dados: os algoritmos genéticos

Uma meta-heurística é um conjunto de conceitos que podem ser usados para definir métodos heurísticos que podem ser aplicados a um amplo conjunto de diferentes problemas. Em outras palavras, uma meta-heurística pode ser vista como uma estrutura algorítmica geral que pode ser aplicada a diferentes problemas de otimização (busca da melhor solução para um dado problema dentro de um conjunto finito ou infinito de possíveis soluções) com relativamente poucas modificações para torná-los adaptados a um problema específico. Exemplos de meta-heurísticas incluem anelamento simulado (SA) (VAN LAARHOVEN & AARTS, 1987), busca tabu (TS) (GLOVER & LAGUNA, 1997), algoritmos genéticos (ILS) (GOLDBERG, 1989),

⁵ AlexNet é uma rede neural profunda com 240 MB de parâmetros, e o SqueezeNet tem apenas 5 MB de parâmetros. Porém, é importante notar que o SqueezeNet não é uma "versão comprimida do AlexNet". Em vez disso, o SqueezeNet é uma arquitetura de rede neural profunda totalmente diferente do AlexNet.

⁶ <https://github.com/inejc/painters>.

algoritmos evolutivos (EC) (BÄCK et al., 1991) e otimização de colônia de formigas (ACO) (DORIGO et al., 2006)⁷.


É um algoritmo mais geral do que os de otimização numérica e, por isso, evita-se o uso de técnicas para resolução de problemas específicos que façam o uso de conhecimento prévio do problema (heurísticas). As meta-heurísticas são aplicadas quando não há um método exato ou heurístico satisfatório ou quando o custo computacional for excessivamente grande. Porém, não garantem que um ótimo global seja encontrado. Em geral, as meta-heurísticas são aplicadas a problemas de otimização combinatória ou problemas contínuos com função objetivo multimodal, nos quais existe uma grande quantidade de soluções de alta qualidade em relação a uma vizinhança e poucos, ou apenas um ótimo global. O uso de meta-heurísticas tem produzido soluções que superam aquelas produzidas pelo ser humano especialista, especialmente no domínio de problemas de otimização combinatória (MELO, 2009).

Algoritmos genéticos são algoritmos de busca baseados nos mecanismos de seleção natural e genética. Nos algoritmos genéticos, ocorre um processo no qual indivíduos concorrem uns com os outros pela sobrevivência e direito de se reproduzirem. Os indivíduos melhores ou mais aptos propagam suas características, enquanto os menos promissores tendem a ser eliminados. O resultado desse processo é a evolução de uma população de soluções em direção a melhores regiões no espaço de busca do ambiente.

No início do processo, uma população de soluções candidatas é selecionada aleatoriamente dentro do domínio do problema, evoluindo na direção das melhores regiões do espaço de busca através de operações como seleção, recombinação (*crossover*) e mutação. Uma informação de avaliação (*fitness*) quantifica o quão adequado é um indivíduo em relação à superfície de resposta da função objetivo (função sobre a qual o indivíduo evolui). O processo de seleção favorece os indivíduos com melhor avaliação, e o processo de recombinação mistura dois indivíduos para a geração de novos dois (duas novas soluções candidatas). O operador de mutação insere modificações nas características dos indivíduos com o intuito de manter a diversidade da população. Como esse operador permite ao algoritmo saltar para uma nova solução em outro contexto, através de um grande número de mutações é possível atingir um valor de ótimo global (MELO, 2009). A Figura 24 esquematiza as funções de recombinação e mutação.

⁷ <http://www.metaheuristics.org/index.php%3Fmain=1.html>

Figura 24. Esquemas dos operadores de *crossover* e *mutação*.



A avaliação das soluções (ou subconjuntos de atributos) pode ser realizada através de diferentes metodologias, baseadas em correlação (HALL, 1999) que avaliam o valor de um subconjunto de atributos considerando a capacidade preditiva individual de cada atributo juntamente com o grau de redundância entre eles, onde são preferidos subconjuntos de atributos que são altamente correlacionados com a classe, embora tenham baixa intercorrelação, baseadas na avaliação dos resultados de classificadores, como os convencionais ou baseados em Aprendizado de Máquina.

3. MATERIAIS E MÉTODOS

3.1 Área de estudo

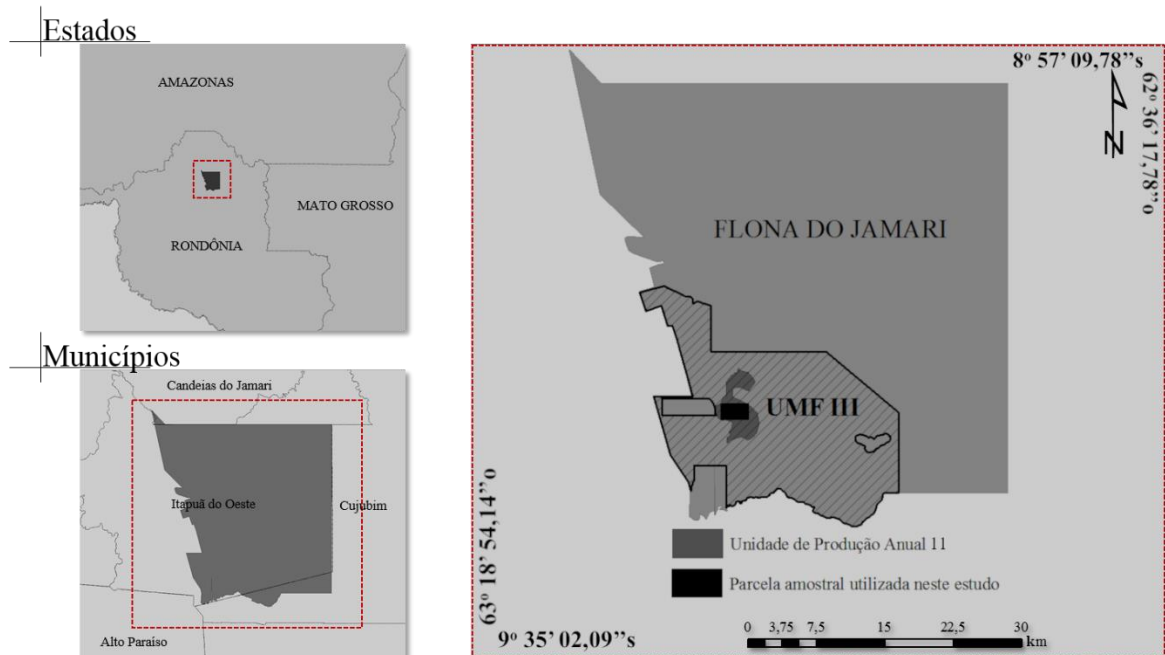
A área de estudo está localizada na Floresta Nacional do Jamari (FLONA⁸ do Jamari), estado de Rondônia, nos municípios de Cujubim, Candeias do Jamari e Itapoã do Oeste (Figura 25). Prevalece na Flona a floresta ombrófila densa com porções de floresta ombrófila aberta, que podem apresentar predominância de palmeiras ou cipós (IBGE, 2012). Segundo a atualização da classificação de Köppen (PEEL et al., 2007), esta área possui um clima tipo Aw - clima tropical chuvoso, com período seco bem definido durante a estação de inverno, precipitação média anual em torno de 2.400 mm e temperatura média anual de 25°C.

A FLONA do Jamari foi criada em 1984 e possui aproximadamente 220 mil hectares, dos quais 96 mil foram destinados à concessão florestal em 2008 (SFB, 2020a). Três empresas possuem autorização do Serviço Florestal Brasileiro para exploração das três unidades de manejo florestal existentes na Flona (UMF I, II e III) e podem explorar madeira e outros produtos florestais como látex, frutos e folhas. A UMF III, alvo deste estudo, é explorada pela empresa Amata S/A, seguindo os critérios de manejo estabelecidos pela legislação brasileira, considerada, portanto, uma exploração de impacto reduzido. Porém, as empresas autorizadas a explorar a área vêm sofrendo pressão por parte da exploração ilegal de madeira que ocorre na porção sudeste da Flona, da forma convencional, causando maior impacto.

O edital para concorrência de autorização para exploração das UMFs inclui o inventário florestal, do qual faz parte a lista de espécies que ocorrem na área. O inventário florestal da FLONA do Jamari foi realizado pelo Instituto Brasileiro de Desenvolvimento Florestal (IBDF), no ano de 1983, tendo como principal finalidade subsidiar o processo de criação da Flona. O objetivo principal do inventário florestal foi avaliar o potencial produtivo da floresta, por meio de estimativas para o volume e o número de árvores de espécies comerciais (SFB, 2020b). A lista de espécies comerciais que ocorrem na Flona consta no Anexo 7.1.

⁸ A Floresta Nacional (FLONA) é uma área com uma cobertura florestal de espécies nativas com proteção especial do Estado. Seu objetivo básico é o uso múltiplo sustentável dos recursos florestais e a pesquisa científica, com ênfase em métodos para exploração sustentável de florestas nativas. Fonte: <https://uc.socioambiental.org/pt-br/noticia/152434>.

Figura 25 - Localização da FLONA do Jamari em relação aos estados e municípios brasileiros, e da Unidade de Manejo Florestal III.



Além das informações contidas no inventário florestal, foram disponibilizadas para este estudo o censo realizado pela empresa Amata S/A, com dados georreferenciados dos indivíduos cortados, com informação de espécie, diâmetro na altura do peito (DAP), circunferência na altura do peito (CAP), volume estimado e levantamentos LiDAR realizados antes e após a exploração (em 2018 e 2019), adquiridos pelo Serviço Florestal Brasileiro. O imageamento LiDAR foi configurado para adquirir aproximadamente 21 pulsos por metro quadrado de superfície terrestre através do sensor aerotransportado LiDAR Optech ALTM Gemini.

3.2 Imagens SAR utilizadas

Um dos fatores que limitam trabalhos que envolvem sensoriamento remoto é a disponibilidade de dados de imageamento, especialmente cobrindo a Amazônia. À exceção de alguns programas espaciais que incluem as plataformas e sensores Landsat, MODIS e Sentinel, cujos produtos são distribuídos gratuitamente, vários dados, em especial os de radar, cuja aquisição ocorre sob demanda, são comercializados.

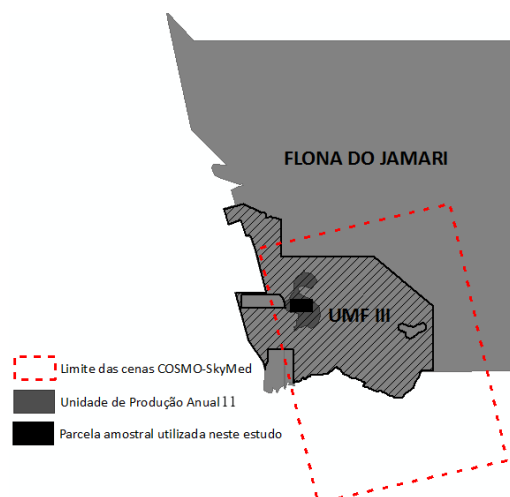
O governo brasileiro, através do Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), vem monitorando sistematicamente o desmatamento na Amazônia brasileira nos períodos chuvosos desde 2016. Para isso, conta com a aquisição frequente de imagens da constelação COSMO-SkyMed, com quatro satélites, cada um equipado com um radar de abertura sintética. O COSMO-SkyMed opera na banda X, e em função de suas ondas

curtas (aproximadamente 3 cm), sua interação com o dossel florestal é superficial. As imagens disponíveis para este estudo foram adquiridas no âmbito deste projeto de monitoramento, compreendendo duas cenas adquiridas sobre uma mesma área da UMF III, em momentos diferentes (antes da exploração e após a exploração). As datas de aquisição foram 08 de janeiro ($\alpha = 55^\circ$), 05 de junho ($\alpha = 55^\circ$) e 08 de outubro de 2018 ($\alpha = 55^\circ$). As imagens foram obtidas em formato complexo (amplitude e fase), em extensão H5, desenvolvida para organização e armazenamento de uma grande quantidade de dados numéricos para aplicações científicas. A Tabela 4 resume as principais características da aquisição dessas imagens, e a Figura 26 apresenta a localização das imagens em relação à área de estudo.

Tabela 4. Características das cenas COSMO-SkyMed utilizadas nesse estudo.

Plataforma	Parâmetro	Especificação
Dados do Sistema	Plataforma	COSMO-SkyMed
	Operação	Junho/2007 - atual
	Órbita	620 km
	Comprimento de onda	Banda X
	Polarização	HH
	Ciclo da órbita (1 satélite)	16 dias
	Número de satélites	4
	Ano de aquisição	2018
Dados das imagens	Modo	<i>Stripmap</i> HIMAGE
	Swath	40 km × 40 km
	Ângulo de incidência	~ 55°
	Resolução espacial	3 m x 3 m

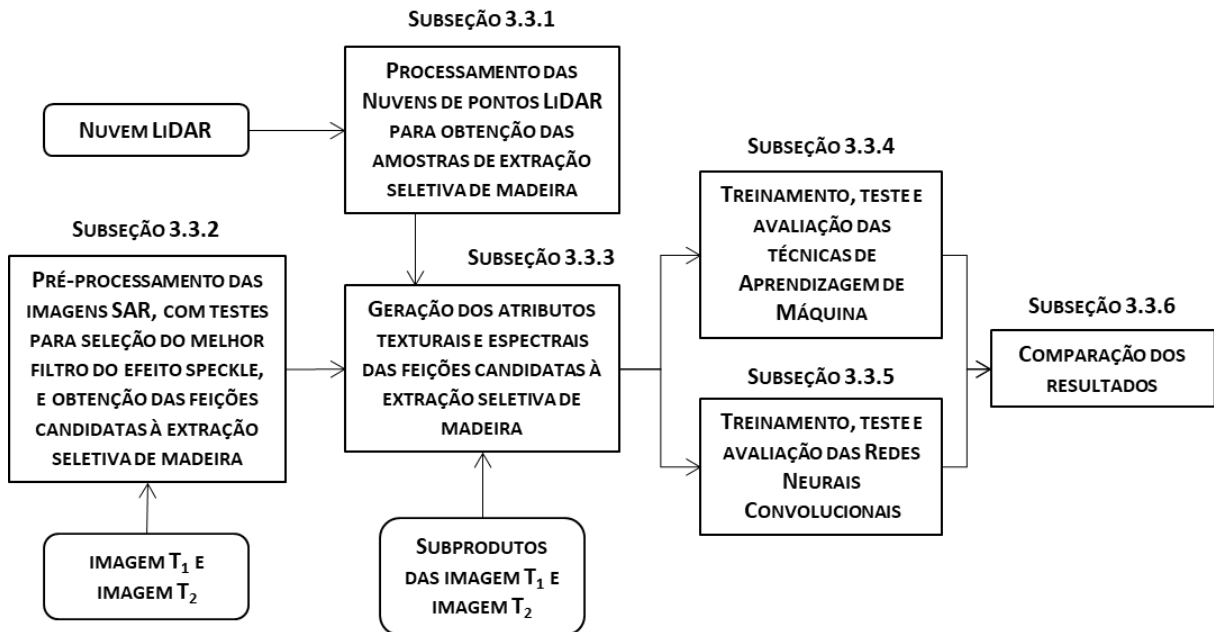
Figura 26. Localização das cenas COSMO-SkyMed em relação à área de estudo. UMF = Unidade de Manejo Florestal.



3.3 Metodologia

O fluxograma apresentado na Figura 27 resume as etapas metodológicas que serão apresentadas nas subseções detalhadas a seguir.

Figura 27. Fluxograma geral das etapas metodológicas.



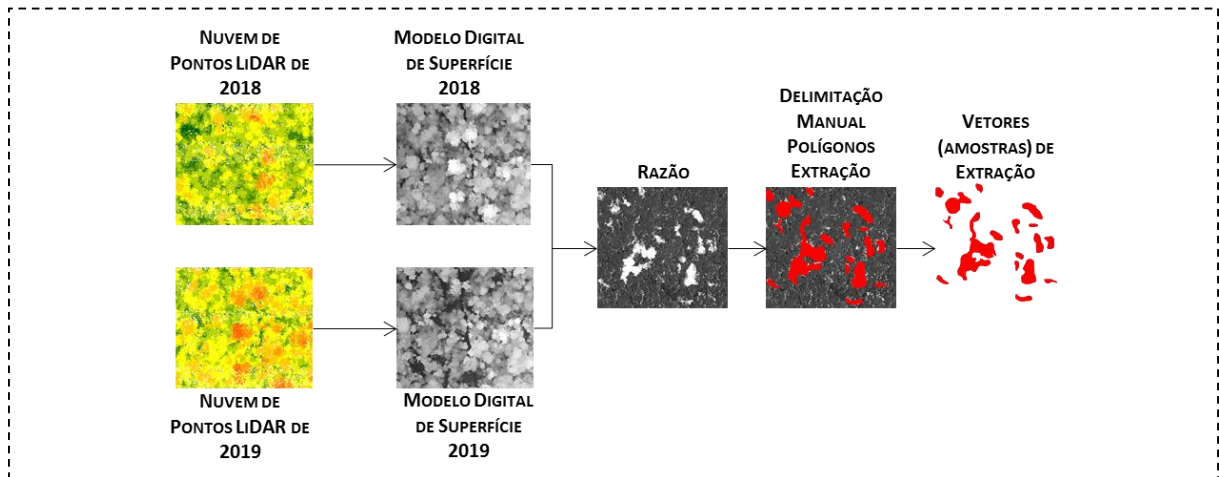
3.3.1 Processamento das nuvens de pontos LiDAR para obtenção das amostras de extração seletiva de madeira

O Serviço Florestal Brasileiro, para a finalidade de monitoramento das atividades de exploração na área concedida à empresa Amata, contratou varredura através de sensor *Light Detection And Ranging* (LiDAR) de áreas amostrais dentro da UMFIII, em datas prévia e posterior (2008 e 2009) à exploração. O LiDAR é uma tecnologia óptica de detecção remota que mede propriedades da luz refletida de modo a obter a distância e/ou outra informação a respeito de um determinado objeto por meio do laser pulsado. A distância a um objeto é determinada medindo a diferença de tempo entre a emissão de um pulso laser e a detecção do sinal refletido. O resultado do escaneamento é uma nuvem de pontos que representam os pulsos refletidos.

Neste trabalho, as nuvens de pontos de 2008 e 2009 adquiridas sobre uma parcela da UMF III denominada JAM04 (Figura 26) foram processadas. A partir dessas nuvens, gerou-se um modelo digital de superfície (MDS) utilizando-se, para isso, as informações de primeiros retornos. Os primeiros retornos correspondem aos pulsos com menor tempo entre emissão e retorno, ou seja, aqueles que, em uma região de floresta, incidem sobre a superfície mais externa do dossel. Esse procedimento é realizado por meio da geração de uma matriz, onde cada célula,

de resolução definida pelo especialista, receberá o valor do primeiro pulso recebido dentro daquela célula. A varredura realizada na área de estudo foi configurada para a obtenção de aproximadamente 21 pulsos por metro quadrado de área do terreno. Definiu-se, para a matriz do MDS, uma célula (pixel) de tamanho 1×1 metro.

Figura 28. Metodologia de obtenção das amostras de extração seletiva de madeira através das imagens LiDAR.

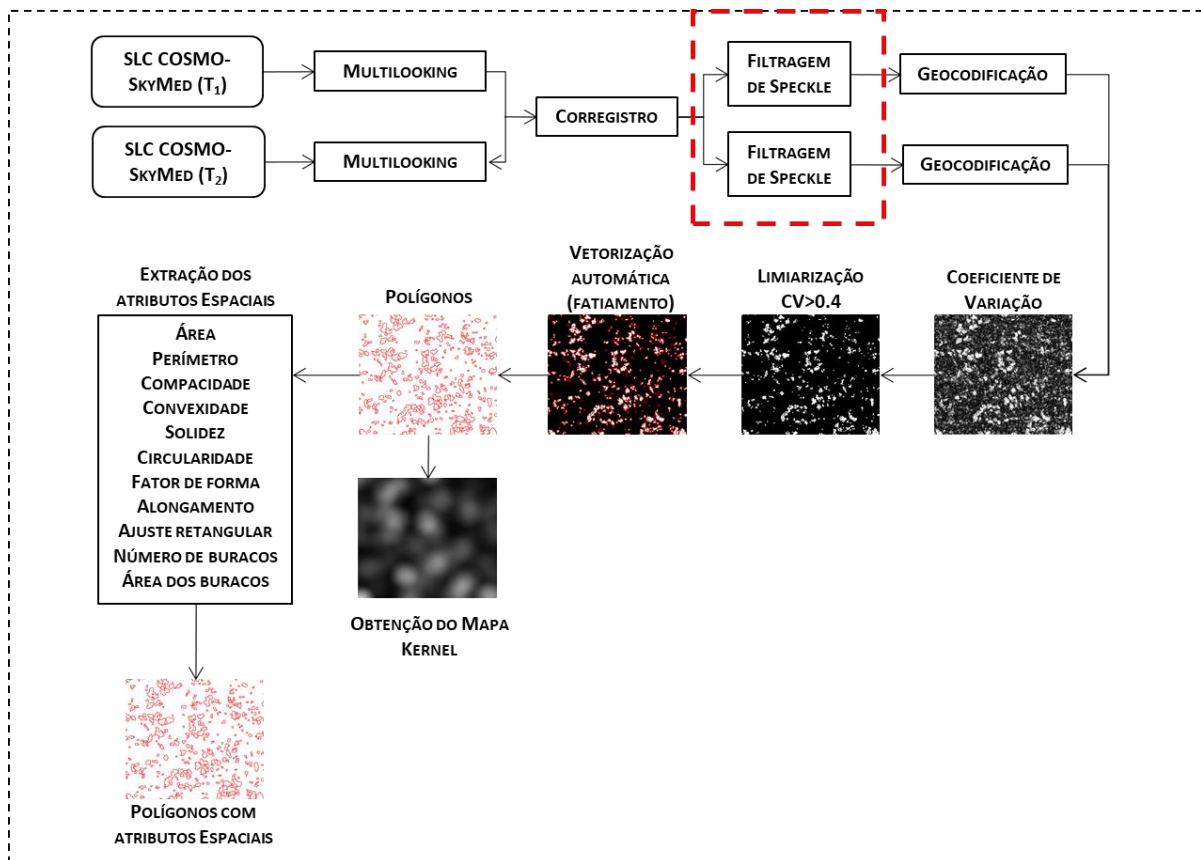


Após a produção das matrizes das varreduras de 2008 e 2009, procedeu-se à operação de razão das matrizes. O objetivo dessa operação foi destacar as áreas que sofreram modificações pela retirada de árvores, resultando em valores de pixel mais altos para as áreas de extração em relação às áreas que não sofreram modificações. Posteriormente, as áreas de extração foram delimitadas manualmente e convertidas em poligonais vetoriais. Essas poligonais representam as amostras de extração madeireira (Figura 28).

3.3.2 Pré-processamento das imagens SAR (testes de filtragem do efeito *speckle*) e obtenção das feições candidatas à extração seletiva de madeira

As etapas metodológicas apresentadas nessa Seção estão resumidas na Figura 29. As imagens SAR utilizadas foram recebidas no formato *single look complex* (SLC) e pré-processadas antes de se proceder com a análise exploratória. O pré-processamento consiste na conversão para imagem para imagem *ground range*, filtragem do efeito *speckle* e geração do coeficiente de retroespalhamento (σ^0) (VAN DER SANDEN, 1997).

Figura 29. Fluxo metodológico do processamento das imagens COSMO-SkyMed e obtenção dos polígonos candidatos à extração madeireira seletiva.



Através de funções implementadas no módulo SARscape, desenvolvido pela SARMAP[®], procedeu-se à importação do sinal complexo no formato nativo H5, que armazena os dados em *hierarchical data format* (HDF), contendo os metadados do conjunto de dados de varredura do sensor. Posteriormente, foi aplicado o *multilooking*, definindo-se 1 *look* em alcance e azimuth, o que resultou em um tamanho de grade de 3 m, que representa a melhor resolução espacial possível do modo de imageamento *STRIPMAP*, e conversão das distâncias em alcance inclinado para alcance no terreno. Procedeu-se então com o corregristo para correção do desvio translacional relativo, das diferenças rotacionais e de escala entre as imagens.

Para a redução do efeito *speckle*, inerente às imagens SAR em função de o princípio do imageamento radar ser baseado na superposição coerente dos ecos refletidos por uma grande quantidade de retroespalhamento distribuído aleatoriamente, foram testados os filtros De Grandi multitemporal (DE GRANDI et al., 1997), Frost (SHI & FUNG, 1994), Gamma (SHI & FUNG, 1994), Lee (LEE, 1980), Média (BOSE, 2003), Anisotropic Non-Linear Diffusion filter (ANLD) para imagem única e multitemporal (ASPERT et al., 2007). Embora muitos métodos de filtragem tenham sido propostos na literatura, sempre haverá perda de resolução

espacial ou de detalhes nas imagens após sua aplicação. Foram realizados, portanto, testes qualitativos e quantitativos de avaliação de desempenho dos filtros, baseados na metodologia proposta por Gomez et al. (2016) para identificação daquele que mantém a melhor relação sinal-ruído.

A etapa final do processamento das imagens consistiu na geocodificação utilizando-se o modelo digital de elevação (MDE) proveniente do sensor *Phased Array type L-band Synthetic Aperture Radar* (PALSAR), gerando o coeficiente de retroespalhamento (σ^0), em decibéis (dB), tornando os alvos SAR comparáveis temporalmente (WOODHOUSE, 2006a).

Posteriormente, a imagem de coeficiente de variação foi obtida entre as imagens geocodificadas de junho/2018 (T_1) e outubro/2018 (T_2). O valor do coeficiente de variação compreende o intervalo 0–1, sendo 0 a ausência de mudança. Foram realizados experimentos exaustivos para definição do valor limite entre extração e não extração, no intuito de se definir um valor que resultasse em erros de comissão para a classe extração e reduzisse a quase zero a ocorrência de erros de omissão, obtendo-se o valor de 0,4. Aplicou-se tal limiar sobre a imagem coeficiente de variação, obtendo-se assim uma imagem binária, onde 0 representa a não extração e 1 a extração. Os conjuntos de pixels de valor 1 foram então convertidos em vetores (polígonos). Para cada polígono, foram calculados os seguintes atributos espaciais (de forma): área, perímetro, compacidade, convexidade, solidez, circularidade, fator de forma, alongamento, ajuste retangular, número de buracos e área dos buracos/área sólida. Os polígonos foram também utilizados para a geração de um mapa Kernel (ROSENBLATT, 1956), que consiste em um método estatístico de estimação de curvas de densidades. Neste método, cada uma das observações é ponderada pela distância em relação a um valor central, o núcleo. No mapa é plotado, por meio métodos de interpolação, a intensidade pontual de determinado fenômeno em toda a região de estudo (QGIS PROJECT, 2016). Assim, temos uma visão geral da intensidade do processo em todas as regiões do mapa. Como peso para definição dos núcleos, foi utilizado, além do adensamento de polígonos, a área dos mesmos. Assim, uma grande densidade de polígonos que representam pixels isolados possui um peso pequeno em relação ao agrupamento de polígonos maiores que representam as extrações madeireiras.

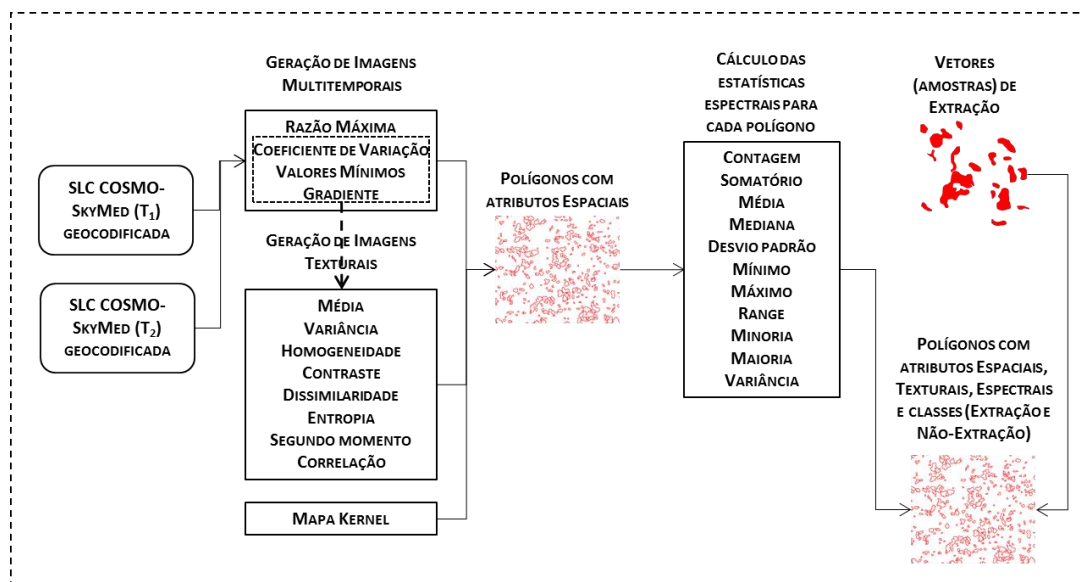
3.3.3 Geração dos atributos texturais e espectrais das feições candidatas à extração seletiva de madeira

As etapas metodológicas apresentadas nessa Seção estão resumidas na Figura 30. A partir das imagens COSMO-SkyMed geocodificadas dos T_1 (junho/2018) e T_2 (outubro/2018), foram

geradas as imagens de estatísticas multitemporais de valores mínimos (o pixel de saída representa o valor mínimo extraído de todos os dados de entrada), gradiente (o valor do pixel de saída representa a variação absoluta máxima entre as datas de aquisição consecutivas) e razão máxima (o pixel de saída representa o valor máximo (incremento máximo de retroespalhamento) entre todas as razões calculadas entre datas de aquisição consecutivas, além da imagem de coeficiente de variação já apresentada na seção anterior.

Posteriormente, as imagens texturais de média, variância, homogeneidade, contraste, dissimilaridade, entropia, segundo momento e correlação foram obtidas a partir da imagem RGB CovMinGrad (R = coeficiente de variação; G = valores mínimos; B = gradiente). O objetivo da geração de imagens texturais sobre as imagens de estatísticas multitemporais foi testar a contribuição desses atributos na diferenciação da extração em relação à floresta circundante, já que esta segunda apresenta grande variação de retroespalhamento em escala de vizinhança (espacial) e multitemporal, o que ocasiona maior rugosidade em relação às áreas que sofreram mudanças ao longo do tempo e que, em função de sua dimensão, apresentam textura lisa/homogênea.

Figura 30. Fluxo metodológico da geração dos atributos texturais e espectrais das feições candidatas à extração seletiva de madeira.



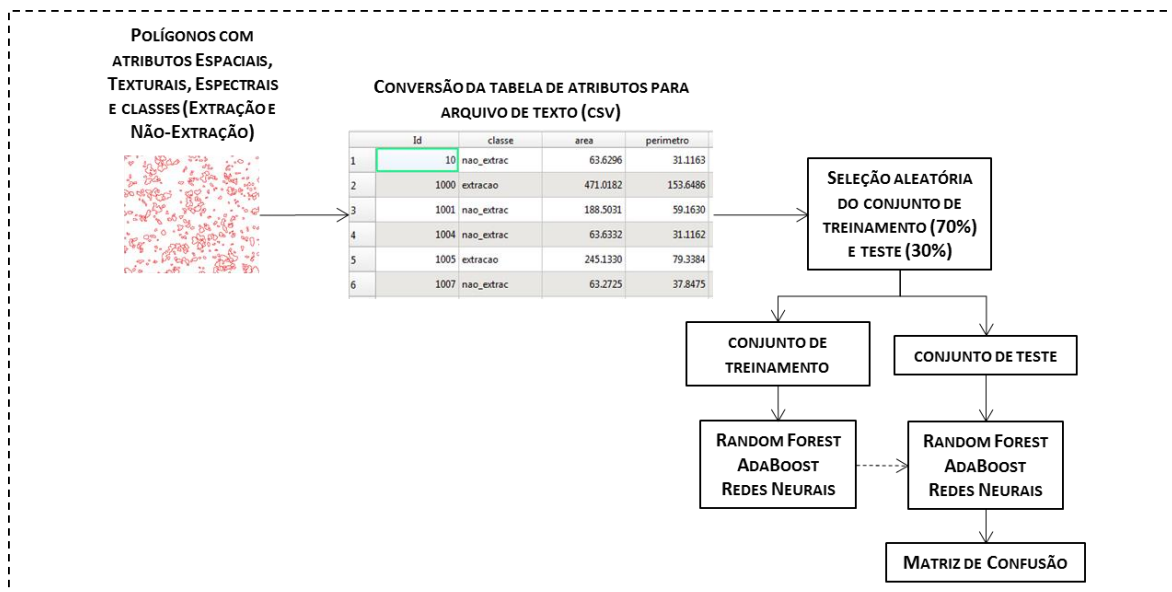
Em seguida, cada polígono, já contendo os atributos espaciais (produtos das etapas apresentadas na Seção 3.3.2) foi populado com as estatísticas espectrais zonais das imagens multitemporais, texturais e kernel, a saber: contagem, somatório, média, mediana, desvio-padrão, mínimo, máximo, range, minoria, maioria e variância. Em resumo, a estatística zonal é o cálculo de

parâmetros estatísticos dos pixels de um dado matricial (raster) contido em determinada zona (no caso deste trabalho, cada polígono é uma zona). O produto dessa etapa consistiu em polígonos cuja tabela de atributos contém os atributos espaciais, espectrais e texturais que serão utilizados nas etapas posteriores. Com o auxílio das amostras de extração madeireira seletiva obtidos através das etapas descritas na Seção 3.3.1, os polígonos receberam, por fim, o atributo ‘classe’, rótulo que descreve a classe à qual cada polígono pertence, a saber, extração ou não extração. Esse atributo é indispensável para o processo de Aprendizado de Máquina, já que é esse rótulo que os algoritmos utilizam para aprender quais características descrevem uma e outra classe e definir seus limites.

3.3.4 Testes de classificação por meio de técnicas de Aprendizado de Máquina

As etapas metodológicas apresentadas nessa Seção estão resumidas na Figura 31. Inicialmente, os polígonos gerados conforme metodologia apresentada na Seção 3.3.3, classificados em extração e não extração e populados com os respectivos atributos espaciais, texturais e espectrais, foram convertidos em uma tabela de atributos, onde cada linha representa um polígono e cada coluna, um atributo. As próximas etapas foram realizadas com o suporte da plataforma Orange Data Mining (DEMŠAR et al., 2013), que disponibiliza ferramentas de visualização de dados, Aprendizado de Máquina e mineração de dados em código aberto.

Figura 31. Fluxo metodológico dos testes de classificação por meio de técnicas de Aprendizado de Máquina.



Inicialmente, procedeu-se à seleção aleatória dos conjuntos de treinamento e de teste a partir do conjunto total de dados (tabela de atributos), sendo de 70% e 30%, respectivamente. O

conjunto amostral foi fixado no intuito de permitir que todos os testes posteriores utilizassem o mesmo conjunto, tornando os resultados comparáveis entre si, e estratificado, no intuito de imitar a composição do conjunto de dados de entrada. Posteriormente, o conjunto de treinamento foi utilizado como entrada dos algoritmos de aprendizagem supervisionada (com o aporte de amostras), primeiro para testes do classificador Random Forest, variando-se os parâmetros conforme se segue (Tabela 5).

Tabela 5. Parâmetros das topologias Random Forest testadas.

IDENTIFICADOR	<i>N</i> TREE (NÚMERO DE ÁRVORES)	<i>M</i> TRY (NÚMERO DE ATRIBUTOS CONSIDERADOS EM CADA DIVISÃO)
RF1	10	$\sqrt{160}$
RF2	15	$\sqrt{160}$
RF3	20	$\sqrt{160}$
RF4	30	$\sqrt{160}$
RF5	50	$\sqrt{160}$
RF6	50	5
RF7	100	$\sqrt{160}$
RF8	200	$\sqrt{160}$
RF9	200	5

Já os testes do classificador Adaboost foram realizados variando-se os parâmetros conforme apresentado na Tabela 6. Na plataforma Orange Data Mining, o classificador AdaBoost tem como padrão a utilização de árvores de decisão como *weak learners*

Tabela 6. Parâmetros das topologias AdaBoost testadas.

IDENTIFICADOR	NÚMERO DE ESTIMADORES	TAXA DE APRENDIZAGEM ⁹	ALGORITMO DE CLASSIFICAÇÃO ¹⁰
AB1	1	1.00	SAMME.R
AB2	15	1.00	SAMME.R
AB3	20	1.00	SAMME.R
AB4	30	1.00	SAMME.R

⁹ A taxa de aprendizagem determina em que medida as informações recém-adquiridas substituirão as informações antigas (0 = o agente não aprenderá nada; 1 = o agente considera apenas as informações mais recentes).

¹⁰ Algoritmo de classificação (se classificação na entrada): SAMME (atualiza os pesos do estimador de base com os resultados da classificação) ou SAMME.R (atualiza o peso do estimador de base com estimativas de probabilidade) (ZHU et al., 2006).

AB5	50	1.00	SAMME.R
AB6	100	1.00	SAMME.R

A arquitetura da Rede Neural Artificial testada foi a do tipo *Feed-Forward* de camadas múltiplas, denominada Perceptron Multicamadas (*multi-layer perceptron* - MLP) com *backpropagation*. Foram testadas diversas topologias de rede, apresentadas na Tabela 7. Os testes de NN61 ao NN70 foram realizados utilizando-se as cinco topologias testadas de NN1 a NN60 que apresentaram os melhores resultados, alterando-se a função de ativação para tangente hiperbólica e o número máximo de iterações para 2.000.

Tabela 7. Parâmetros das topologias das Redes Neurais Artificiais do tipo MLP testadas.

IDENTIFICADOR	Nº DE NEURÔNIOS EM CADA CAMADA ESCONDIDA	FUNÇÃO DE ATIVAÇÃO	OTIMIZADOR DOS PESOS	α (CRITÉRIO DE PARADA)	NÚMERO MÁXIMO DE ITERAÇÕES
NN1	10	ReLU	L-BFGS-B	0.00002	1.000
NN2	10, 10	ReLU	L-BFGS-B	0.00002	1.000
NN3	10, 10, 10	ReLU	L-BFGS-B	0.00002	1.000
NN4	10, 10, 10, 10	ReLU	L-BFGS-B	0.00002	1.000
NN5	10, 10, 10, 10, 10	ReLU	L-BFGS-B	0.00002	1.000
NN6	50	ReLU	L-BFGS-B	0.00002	1.000
NN7	50, 50	ReLU	L-BFGS-B	0.00002	1.000
NN8	50, 50, 50	ReLU	L-BFGS-B	0.00002	1.000
NN9	50, 50, 50, 50	ReLU	L-BFGS-B	0.00002	1.000
NN10	50, 50, 50, 50, 50	ReLU	L-BFGS-B	0.00002	1.000
NN11	100	ReLU	L-BFGS-B	0.00002	1.000
NN12	100, 100	ReLU	L-BFGS-B	0.00002	1.000
NN13	100, 100, 100	ReLU	L-BFGS-B	0.00002	1.000
NN14	100, 100, 100, 100	ReLU	L-BFGS-B	0.00002	1.000
NN15	100, 100, 100, 100, 100	ReLU	L-BFGS-B	0.00002	1.000
NN16	200	ReLU	L-BFGS-B	0.00002	1.000
NN17	200, 200	ReLU	L-BFGS-B	0.00002	1.000
NN18	200, 200, 200	ReLU	L-BFGS-B	0.00002	1.000
NN19	200, 200, 200, 200	ReLU	L-BFGS-B	0.00002	1.000
NN20	200, 200, 200, 200, 200	ReLU	L-BFGS-B	0.00002	1.000
NN21	10	ReLU	SGD	0.00002	1.000
NN22	10, 10	ReLU	SGD	0.00002	1.000
NN23	10, 10, 10	ReLU	SGD	0.00002	1.000
NN24	10, 10, 10, 10	ReLU	SGD	0.00002	1.000
NN25	10, 10, 10, 10, 10	ReLU	SGD	0.00002	1.000
NN26	50	ReLU	SGD	0.00002	1.000
NN27	50, 50	ReLU	SGD	0.00002	1.000
NN28	50, 50, 50	ReLU	SGD	0.00002	1.000
NN29	50, 50, 50, 50	ReLU	SGD	0.00002	1.000
NN30	50, 50, 50, 50, 50	ReLU	SGD	0.00002	1.000
NN31	100	ReLU	SGD	0.00002	1.000
NN32	100, 100	ReLU	SGD	0.00002	1.000
NN33	100, 100, 100	ReLU	SGD	0.00002	1.000
NN34	100, 100, 100, 100	ReLU	SGD	0.00002	1.000
NN35	100, 100, 100, 100, 100	ReLU	SGD	0.00002	1.000
NN36	200	ReLU	SGD	0.00002	1.000

NN37	200, 200	ReLU	SGD	0.00002	1.000
NN38	200, 200, 200	ReLU	SGD	0.00002	1.000
NN39	200, 200, 200, 200	ReLU	SGD	0.00002	1.000
NN40	200, 200, 200, 200, 200	ReLU	SGD	0.00002	1.000
NN41	10	ReLU	ADAM	0.00002	1.000
NN42	10, 10	ReLU	ADAM	0.00002	1.000
NN43	10, 10, 10	ReLU	ADAM	0.00002	1.000
NN44	10, 10, 10, 10	ReLU	ADAM	0.00002	1.000
NN45	10, 10, 10, 10, 10	ReLU	ADAM	0.00002	1.000
NN46	50	ReLU	ADAM	0.00002	1.000
NN47	50, 50	ReLU	ADAM	0.00002	1.000
NN48	50, 50, 50	ReLU	ADAM	0.00002	1.000
NN49	50, 50, 50, 50	ReLU	ADAM	0.00002	1.000
NN50	50, 50, 50, 50, 50	ReLU	ADAM	0.00002	1.000
NN51	100	ReLU	ADAM	0.00002	1.000
NN52	100, 100	ReLU	ADAM	0.00002	1.000
NN53	100, 100, 100	ReLU	ADAM	0.00002	1.000
NN54	100, 100, 100, 100	ReLU	ADAM	0.00002	1.000
NN55	100, 100, 100, 100, 100	ReLU	ADAM	0.00002	1.000
NN56	200	ReLU	ADAM	0.00002	1.000
NN57	200, 200	ReLU	ADAM	0.00002	1.000
NN58	200, 200, 200	ReLU	ADAM	0.00002	1.000
NN59	200, 200, 200, 200	ReLU	ADAM	0.00002	1.000
NN60	200, 200, 200, 200, 200	ReLU	ADAM	0.00002	1.000
NN61	1º MELHOR RESULTADO NN1-NN60	-	-	-	2.000
NN62	1º MELHOR RESULTADO NN1-NN60	TANH	-	-	2.000
NN63	2º MELHOR RESULTADO NN1-NN60	-	-	-	2.000
NN64	2º MELHOR RESULTADO NN1-NN60	TANH	-	-	2.000
NN65	3º MELHOR RESULTADO NN1-NN60	-	-	-	2.000
NN66	3º MELHOR RESULTADO NN1-NN60	TANH	-	-	2.000
NN67	4º MELHOR RESULTADO NN1-NN60	-	-	-	2.000
NN68	4º MELHOR RESULTADO NN1-NN60	TANH	-	-	2.000
NN69	5º MELHOR RESULTADO NN1-NN60	-	-	-	2.000
NN70	5º MELHOR RESULTADO NN1-NN60	TANH	-	-	2.000

Os resultados dos testes foram avaliados aplicando-se a rede treinada sobre o conjunto de teste e calculando-se os seguintes parâmetros:

1. *Area Under Receiver Operator Curve (AUC)*: uma AUC de 0,5 sugere nenhuma discriminação entre classes; 0,7 a 0,8 é considerado aceitável; 0,8 a 0,9 é considerado excelente; e mais de 0,9 é considerado excepcional.
2. *Acurácia*: proporção de amostras classificadas corretamente.
3. *F-1*: média harmônica ponderada da precisão e recall.
4. *Precisão*: proporção de verdadeiros positivos entre as ocorrências classificadas como positivas, por exemplo, a proporção de extração corretamente classificada como extração.
5. *Recall*: proporção de verdadeiros positivos entre todas as instâncias positivas nos dados.
6. *Tempo de treinamento (em segundos)*.
7. *Tempo de teste (em segundos)*.

Ainda para fins de avaliação dos resultados obtidos com cada classificador e tipologias, foram observadas e comparadas as matrizes de confusão dos melhores resultados obtidos, as quais apontam as proporções de erro em cada classe separadamente. Posteriormente, com o auxílio de um algoritmo genético básico, foi avaliada a contribuição de cada um dos atributos para a obtenção do melhor resultado encontrado no conjunto de testes. Os parâmetros necessários para configuração de um algoritmo genético foram atribuídos conforme descrito:

1. Probabilidade de recombinação (*crossover*): 0,6;
2. Número máximo de gerações: 50;
3. Probabilidade de ocorrer mutação: 5%;
4. Tamanho da população (número de indivíduos (atributos) da população): 20;
5. Semente aleatória: 1.

O subconjunto de atributos identificado pelo algoritmo genético como melhor descritor e diferenciador das classes extração de não extração, foi utilizado para testar as cinco tipologias que resultaram nas melhores classificações, esperando-se obter resultado similar às classificações utilizando todo o conjunto de atributos. Os resultados foram avaliados através da comparação dos valores de acurácia, precisão e tempo de treinamento e de teste das classificações utilizando o conjunto total e o subconjunto de atributos.

Para testar a capacidade de generalização dos treinamentos realizados, as cinco topologias que apresentaram os melhores resultados de classificação foram testadas para a cena COSMO-SkyMed completa (porção contida na FLONA Jamari), cujos limites estão apresentados na Figura 26, validando-se os resultados obtidos através de sua comparação com o registro das árvores extraídas fornecido pelo Serviço Florestal Brasileiro. Tal capacidade de generalização também foi testada aplicando-se a rede treinada nos dados gerados a partir das imagens COSMO-SkyMed de junho/2018 e outubro/2018, para a detecção das feições de interesse que ocorreram entre as aquisições COSMO-SkyMed de janeiro e junho de 2018. A validação foi realizada conforme já descrito neste parágrafo.

3.3.5 Testes de classificação por meio de Redes Neurais Convolucionais

A primeira etapa dos testes de classificação consistiu na seleção de todas as feições candidatas à mudança entre as imagens SAR de junho/2018 e outubro/2018. Para isso, gerou-se o coeficiente de variação (CV) entre as duas imagens, já que o CV tem sido apontado como uma alternativa vantajosa para detecção de mudanças em imagens SAR (KOENIGUER & NICOLAS, 2020). Conforme previamente descrito, o valor de 0,4 foi definido como limite entre não extração e extração (valores maiores que 0,4 foram incluídos como possíveis extrações).

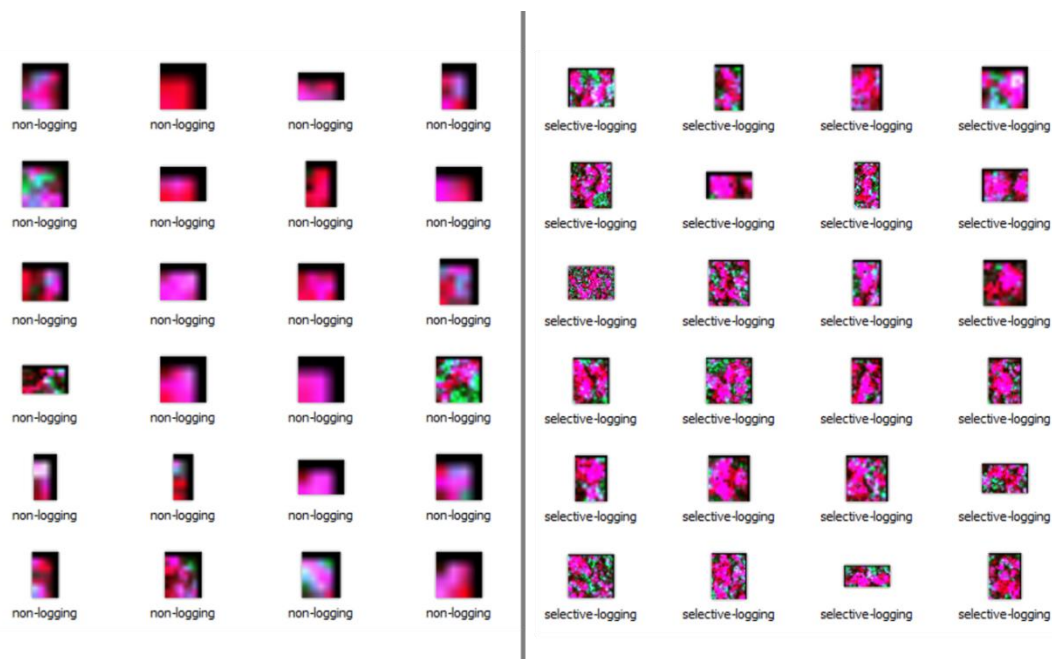
Posteriormente, tais conjuntos de pixels foram vetorizados, formando polígonos candidatos à classe extração.

Para seleção dos polígonos representantes da verdade de campo, os candidatos à classe extração foram cruzados com a verdade de campo proveniente dos dados LiDAR e do inventário florestal. Assim, dos 186.886 polígonos gerados pelo fatiamento do CV, 4.324 receberam o rótulo de classe, a saber, extração e não extração. Os polígonos foram então utilizados como máscara para recorte das imagens a seguir:

- RGB cujo canal R contém a imagem de coeficiente de variação, o canal G a imagem de valores mínimos e canal B o gradiente (covmingrad image) entre as imagens de junho e outubro;
- Banda única do coeficiente de variação (CV image);
- Banda única razão (CSKoutubro/CSKjunho – ratio image).

As imagens recortadas pelos polígonos rotulados e classificadas pela verdade de campo foram utilizadas como conjuntos de treinamento (70%) e teste (30%), e as não-rotuladas para análise da capacidade de generalização da CNN. A Figura 32 apresenta uma amostra das imagens covmingrad recortadas pelos referidos polígonos.

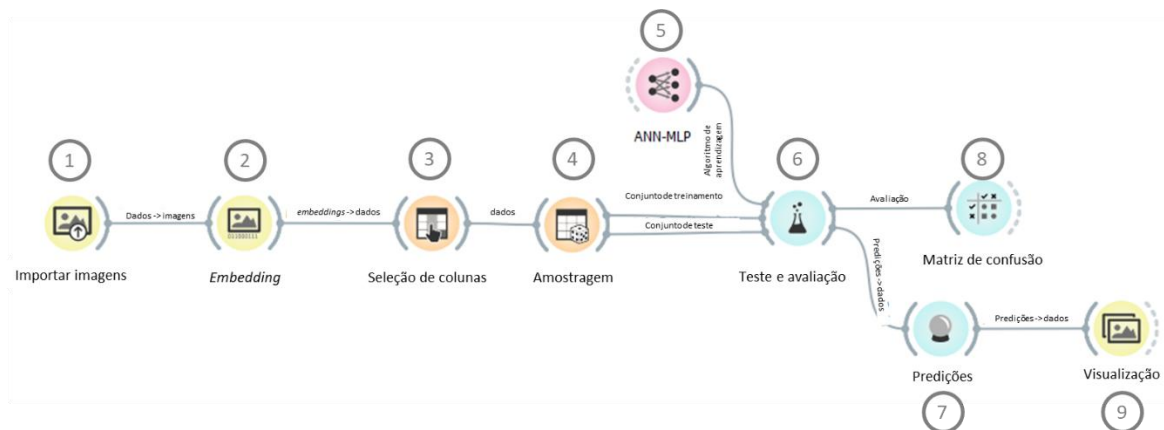
Figura 32. Sub-imagens covmingrad de extração e não extração usadas para treinamento da CNN.



Para execução dos testes, foi utilizado o *software* Orange data mining (DEMŠAR et al., 2013), que é uma plataforma para análise e visualização de dados baseada em programação visual que

apresenta a possibilidade de implementação usando a biblioteca Python 3. O fluxograma geral dos testes está apresentado na Figura 33.

Figura 33. Fluxograma apresentando as etapas do teste de classificação pelas CNNs. 1. Importação das subimagens rotuladas; 2. *Embedding*; 3. Seleção das colunas contendo os atributos extraídos pelos *embedders*; 4. Divisão do conjunto de dados em conjunto de treinamento e de teste; 5. Classificador ANN-MLP (última camada totalmente conectada); 6. execução dos testes sobre o conjunto separado para esta finalidade e apresentação dos resultados da avaliação quantitativa da classificação; 7. Predição para cada subimagem; 8. Geração e apresentação da matriz de confusão; 9. Visualização das imagens por classe.



Os *embedders* testados foram o InceptionV3, VGG16, VGG19, SqueezeNet, Painters e DeepLoc, descritos na Seção 2.9.2.3.1. A última camada totalmente conectada foi definida conforme testes apresentados na Seção 3.3.4, sendo escolhida a arquitetura ANN-MLP que apresentou melhor resultado para classificação de extração seletiva de madeira. A avaliação dos resultados da classificação do conjunto de testes foi realizada a partir do cálculo dos parâmetros a seguir:

- Área sob a curva do operador do receptor (AUC): uma AUC de 0,5 sugere que não há discriminação entre as classes; 0,7 a 0,8 é considerado aceitável; 0,8 a 0,9, excelente; e mais de 0,9, excepcional.
- Exatidão: proporção de amostras classificadas corretamente.
- Precisão: proporção de verdadeiros positivos entre as amostras corretamente classificadas como positivas, por exemplo, a proporção de extrato corretamente classificada como seletivamente registrada.
- Tempo de treinamento (em segundos).
- Tempo de teste (em segundos).

A estratégia de validação adotada foi a validação cruzada (STONE, 1974), com número de *folds* = 5. Já a avaliação dos resultados da capacidade de generalização foi realizada a partir da contabilização, dentro da área em que estão disponíveis dados do inventário florestal que

apontam as árvores cortadas, dos acertos, erros de comissão e omissão e cálculo do índice de exatidão global.

3.3.6 Estimativa da intensidade de exploração

Como etapa final, este trabalho propôs-se a estimar a intensidade de exploração (IEX) da área de estudo por meio da razão entre área de extração seletiva madeireira (que compreende a área de clareiras) e área total que delimita a região em exploração (polígono mínimo delimitador). Para delimitação do polígono mínimo delimitador, foi utilizado o método *Density Based Spatial Clustering of Application with Noise* (DBSCAN) (ESTER et al., 1996), o qual requer dois parâmetros: tamanho mínimo do grupo (número de clareiras) e máxima distância entre clareiras agrupadas, cuja definição foi baseada em análises da distribuição de distâncias e agrupamentos dos dados de extração disponíveis.

4. RESULTADOS E DISCUSSÃO

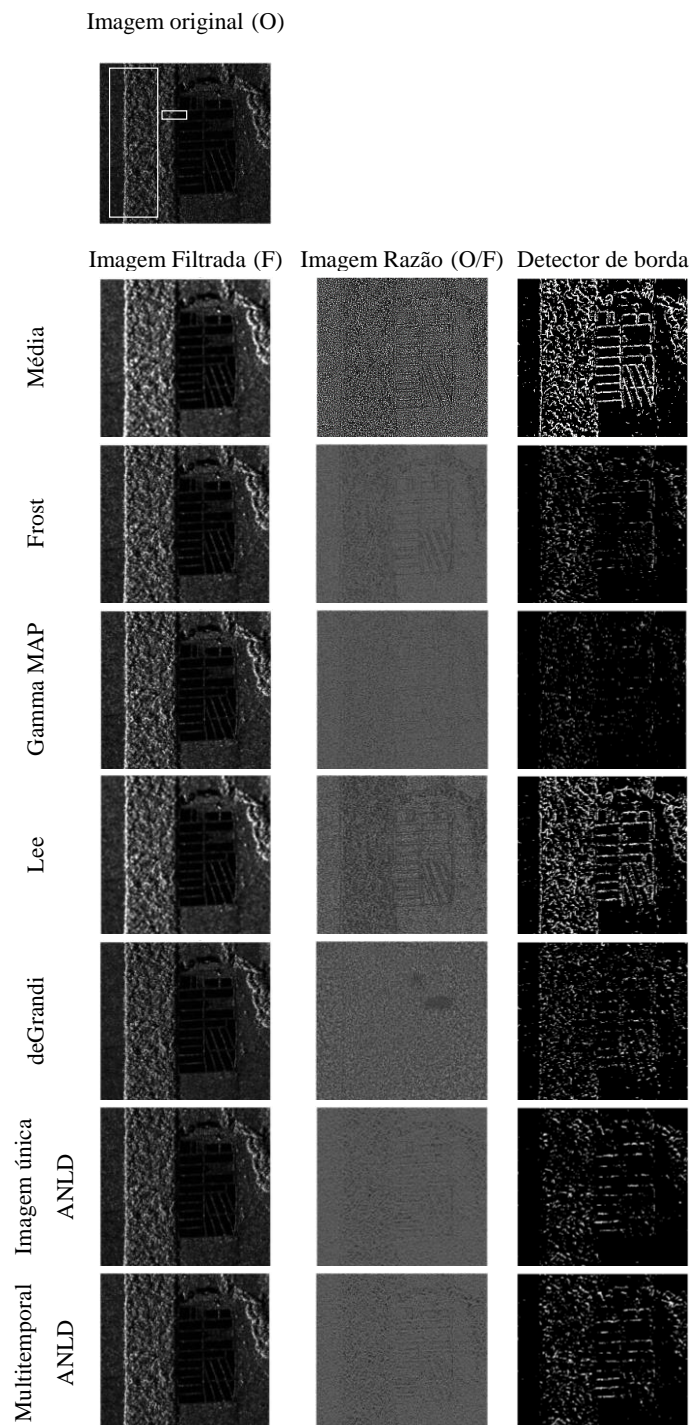
4.1 Desempenho de filtros de *speckle* para imagens COSMO-SkyMed da Amazônia brasileira

A Figura 34 apresenta parte da imagem original selecionada para avaliar os resultados dos diferentes filtros considerados neste estudo. Visualmente, não há diferença aparente entre as imagens originais e as filtradas. A Figura 34 também mostra que, nas imagens razão, é possível observar, por meio de inspeção visual e em menor ou maior grau, a presença de estruturas geométricas correlacionadas com a imagem original na maioria dos filtros aplicados (Média, Frost, Lee, imagem única e multitemporal de ANLD). Essas estruturas incluem a rugosidade da região florestal (destacada na maior caixa branca). Isso indica que possivelmente algumas informações relevantes, como bordas ou estruturas brilhantes (retroespalhamento alto), foram removidas ou modificadas. Embora também presentes, essas estruturas aparecem menos pronunciadas no filtro De Grandi, o que sugere melhor desempenho, uma vez que qualquer conteúdo na imagem de proporção diferente de *speckle* puro indica que alguma modificação ocorreu em relação a áreas não homogêneas, principalmente nas bordas (GOMEZ et al., 2016). A Figura 34 também apresenta os resultados do detector de bordas das imagens de razão, obtidos por meio da metodologia proposta por Touzi et al. (1988) para imagens razão para obtenção das bordas e posteriormente cálculo do estimador de borda β (GOMEZ et al., 2016). A inspeção visual desses resultados permite observar com mais clareza as arestas remanescentes na imagem razão, apontando para o filtro Gamma como aquele que resulta em um conjunto menor de feições estruturais nesta imagem.

A Tabela 8 mostra a análise quantitativa do desempenho dos filtros selecionados. Nesta tabela, apresentam-se os valores extraídos de uma amostra homogênea da imagem original (não filtrada), a imagem filtrada e a proporção da imagem Π (proporção entre a imagem original e filtrada). Os valores de média (μ) e variância (σ) obtidos nas imagens filtradas indicam que houve maior preservação de μ com a aplicação do filtro Frost e redução de σ na aplicação do filtro médio. Porém, a partir dos resultados do teste ANOVA, não é possível rejeitar a hipótese nula de que as variâncias são iguais para um nível de significância de 5%. O valor-p indica que não há evidência suficiente para rejeitar a hipótese nula de que as médias da população são todas iguais. Portanto, esses parâmetros não são suficientes para escolher os melhores filtros. O ENL mostrou que a maior suavização foi obtida pelo filtro de média, que apresentou um aumento de 898% em relação ao ENL da imagem original. A análise visual da imagem filtrada

pelo filtro de média confirma esse achado, uma vez que é possível observar um maior “borramento”, ou seja, menor nitidez das feições.

Figura 34. Sub-região da imagem COSMO-SkyMed selecionada para testar o desempenho do filtro. A caixa branca menor representa a amostra de uma área homogênea usada para análise quantitativa do desempenho dos filtros. A caixa branca maior destaca uma área coberta por floresta.



Analisando a imagem razão, o melhor resultado foi obtido pelo filtro De Grandi. De acordo com o modelo multiplicativo, que assume que o valor de cada pixel em uma dada intensidade

é a observação de um processo estocástico Z , que é o produto de dois processos estocásticos (a verdade de campo e o modelo do efeito *speckle*), a média do *speckle* é igual a 1. Um filtro ideal resultaria, para uma área homogênea, em uma imagem razão de puro *speckle* (sem feições estruturais), cuja média, portanto, deveria ser igual a 1. Assim, ao analisar uma área homogênea de uma imagem razão, espera-se que $\mu_{\text{razão}} = 1$. O filtro De Grandi apresentou $\mu_{\text{razão}}$ mais próximo de 1, indicando menos subtração de informações estruturais durante o processo de filtragem.

Um dos pioneiros no estudo das propriedades estatísticas do efeito *speckle*, (GOODMAN, 1975) definiu sua distribuição como gama de parâmetros de forma e escala iguais a L , sendo L o número de visadas na imagem SAR. Assim, supondo que a imagem correta de um filtro ideal contenha apenas *speckle*, espera-se que seus valores apresentem distribuição gama. Por meio do teste de Kolmogorov-Smirnov de qualidade de ajuste de uma distribuição, ao nível de significância de 5%, foi aceita a hipótese nula de que a distribuição dos dados da imagem razão do filtro De Grandi segue uma distribuição gama, a qual foi rejeitada para os outros filtros.

De acordo com ACHIM et al. (2006), para uma imagem original com $\text{ENL} = \text{ENL}_{\text{ruidosa}}$ (medido em uma região homogênea da imagem) com *speckle* médio = 1, o melhor filtro é aquele em que o ENL da imagem razão se aproxima do $\text{ENL}_{\text{ruidosa}}$ (1,1699) e a razão média da imagem se aproxima de 1. Essa aproximação foi obtida em maior grau pelo filtro De Grandi (0,2632).

Tabela 8. Valores calculados para uma área homogênea na imagem COSMO-SkyMed. Os valores em negrito representam os melhores resultados. μ = média; σ = variância; ENL = número equivalente de looks; $\mu_{\text{razão}}$ = média da imagem da razão; O estimador $\alpha\beta$ e a $\beta_{\text{razão}}$ são descritos em GOMEZ et al. (2016).

	μ	σ	ENL	μ_{ratio}	ENL ratio	$\alpha\beta$	β_{ratio}
Média	0,0085	0,0025	11,6771	3,2709	0,1170	0,7551	0,7021
Frost	0,0083	0,0033	6,1795	2,5948	0,1420	1,1830	0,2020
Gamma	0,0083	0,0032	6,4880	2,9089	0,1099	0,5236	0,1013
Lee	0,0084	0,0027	9,6184	3,4094	0,1230	0,8383	0,5431
De Grandi	0,0069	0,0036	3,6605	1,7952	0,2632	0,9547	0,2337
ANLD img única	0,0086	0,0048	3,2166	2,5378	0,1194	1,5631	0,1755
ANLD multitemp	0,0086	0,0045	3,6358	2,5817	0,1319	1,4423	0,2225
original	0,0082	0,0076	1,1699				

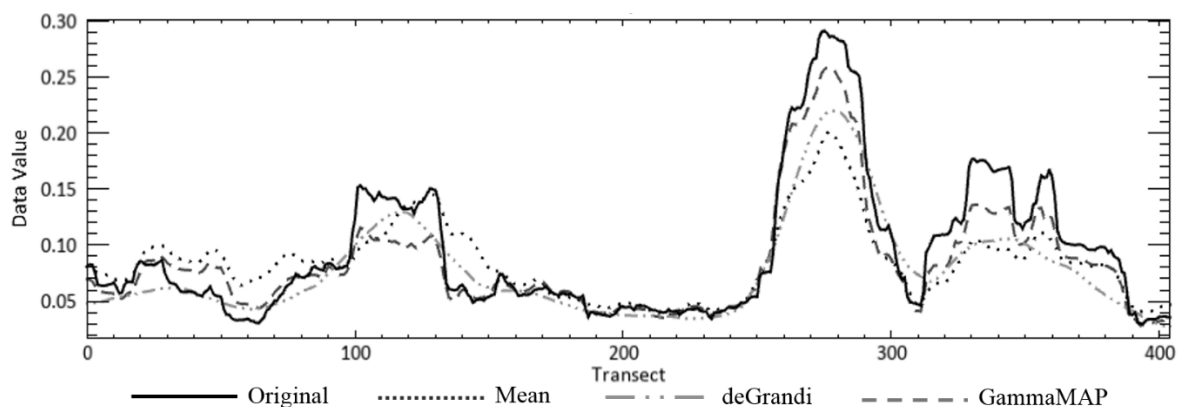
A Tabela 8 mostra os valores do estimador $\alpha\beta$ (GOMEZ et al., 2016), que considera o valor médio do *speckle* ($\mu_{\text{razão}}$) e do ENL ($\text{ENL}_{\text{razão}}$) medido em uma área homogênea da imagem

razão e o conteúdo geométrico remanescente na imagem razão. O restante do conteúdo geométrico é medido pela $\beta_{\text{razão}}$, que considera a imagem original, a imagem razão e o detector de bordas da imagem razão (GOMEZ et al., 2016). Um filtro ótimo deve apresentar $\alpha\beta = 0$. Desta forma, o filtro Gamma, que apresentou $\alpha\beta = 0,5236$, pode ser considerado como aquele que melhor preservou as bordas da imagem original. Este filtro também apresentou valor de $\beta_{\text{razão}}$ próximo a 0. Essa razão mede o conteúdo geométrico remanescente na imagem filtrada. A Figura 34 confirma a manutenção das bordas na imagem razão.

Portanto, a análise visual e numérica conjunta mostrou que os filtros Gamma e De Grandi apresentaram os melhores desempenhos, pois apresentaram a menor quantidade de características estruturais na imagem de razão e valores mais próximos do ideal na avaliação quantitativa da imagem de razão e dos índices descritos por Gomez et al. (2016).

Por fim, a Figura 35 mostra os valores de um perfil arbitrário traçado em uma área de floresta nas imagens que apresentaram os melhores resultados, juntamente com a imagem original e o filtro de média (melhor valor ENL). A Figura 35 confirma que o filtro Media resulta em maior suavização, visto que é possível notar uma redução da amplitude e remoção de picos e vales que representam bordas na imagem. O filtro GammaMAP apresentou a maior similaridade com a imagem original, seguido pelo filtro De Grandi, que apresentou maior suavidade em relação ao GammaMAP, visível na Figura 35 através da atenuação de pequenas amplitudes para este filtro.

Figura 35. Perfil arbitrário em uma área de floresta para a imagem original e os filtros Mean, De Grandi e GammaMAP.



4.2 Preparação dos dados e análise exploratória

A limiarização da imagem de coeficiente de variação, gerado entre as imagens COSMO-SkyMed de junho e outubro de 2018, a um valor de 0,4, incluiu todas as amostras selecionadas

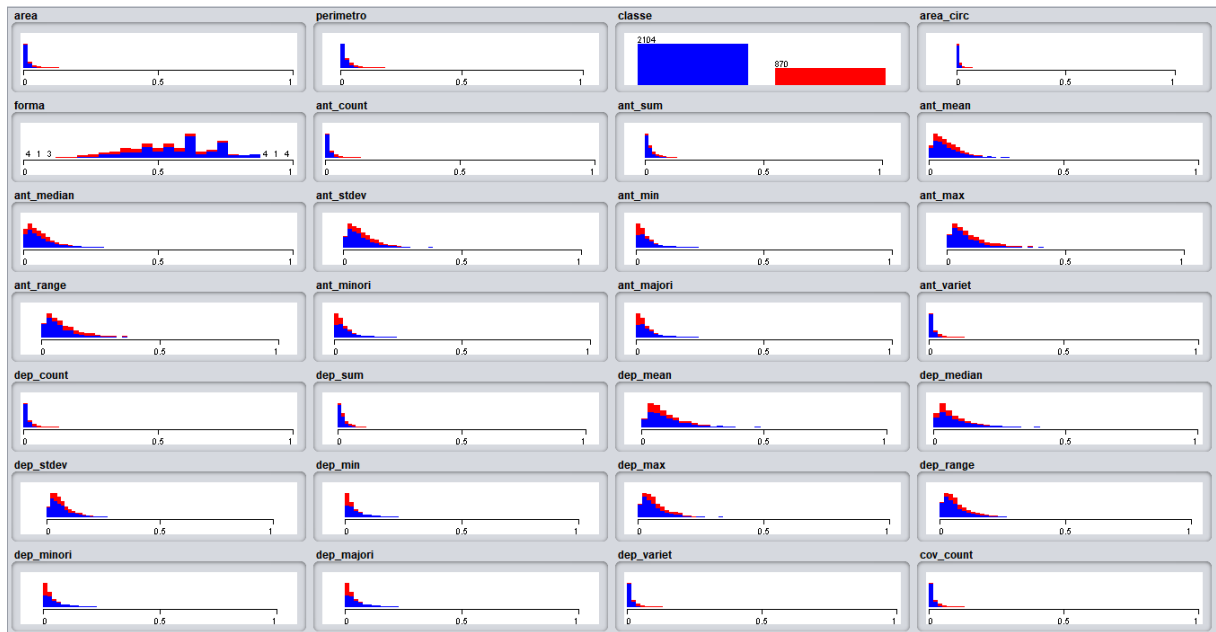
como extração nas imagens LiDAR somadas a 70% de erros de comissão. Assim, dos 2.974 polígonos gerados, 870 pertencem à classe extração e 2.104 à não extração (Figura 36). Os atributos extraídos para cada polígono totalizaram 160. A sobreposição das amostras selecionadas como extração nas imagens LiDAR, os pontos georreferenciados de árvores extraídas fornecidos pelo SFB e os polígonos gerados pela limiarização do coeficiente de variação mostrou que, das 849 árvores cortadas na parcela amostral utilizada neste estudo, 96% são passíveis de identificação nas imagens SAR, sendo os 4% restantes composto por extrações que não alteraram a estrutura do dossel e, portanto, não detectáveis em dados SAR de banda X.

Figura 36. Limiarização do produto coeficiente de variação classificado como extração (em vermelho) e não extração (em amarelo).




A análise exploratória dos atributos, através da visualização dos gráficos de distribuição, mostrou haver redundância e sobreposição em diversos atributos. A Figura 37 apresenta parte dos gráficos visualizados, exemplificando que os dados não são linearmente separáveis. Uma análise das combinações apropriadas de variáveis para a finalidade de separação das classes extração e não extração, a qual esse trabalho se propõe, será apresentada em seção posterior, que abordará a aplicação da técnica de algoritmos genéticos.

Figura 37. Exemplos de distribuição de alguns atributos gerados sobre as imagens SAR. Em vermelho, a classe extração e em azul, não extração.



Os *boxplots* apresentados na Figura 38 exemplificam atributos extremos em termos de potencial para diferenciação das classes extração e não extração. É possível observar, no gráfico da esquerda, que apresenta os dados do atributo `maxR_media`, que as distribuições estão praticamente sobrepostas, e os valores das medianas, bem próximos. Já no gráfico da direita, que apresenta os dados do atributo `cov_mean`, mostra diferença nos valores das medianas e nas distribuições, o que indica potencial desse dado para diferenciação das classes.

Figura 38. *Boxplots* de um atributo com parâmetros estatísticos semelhantes entre as classes extração e não extração (à esquerda) e um com parâmetros estatísticos divergentes para as mesmas classes (à direita).



Porém, dado o grande número de atributos, não é possível proceder-se a uma análise meramente visual que resulte na correta seleção das variáveis e suas combinações que melhor descrevem e diferenciam as classes. Assim, o conjunto completo de atributos foi utilizado, em um primeiro momento, como entrada dos algoritmos baseados em Aprendizado de Máquina.

4.3 Testes de classificação por meio de técnicas de Aprendizado de Máquina

A limiarização da imagem de coeficiente de variação, gerado entre as imagens COSMO-SkyMed de junho e outubro de 2018, a um valor de 0,4, incluiu todas as amostras selecionadas como extração nas imagens LiDAR somadas a 70% de erros de comissão. Dos 2.974 polígonos gerados, 870 pertencem à classe extração e 2.104 à não extração. A sobreposição das amostras selecionadas como extração nas imagens LiDAR, os pontos georreferenciados de árvores extraídas fornecidos pelo SFB e os polígonos gerados pela limiarização do coeficiente de variação mostrou que, das 849 árvores cortadas na parcela amostral utilizada neste estudo (UPA 11), 96% são passíveis de identificação nas imagens SAR, sendo os 4% restantes composto por extrações que não alteraram a estrutura do dossel e, portanto, não detectáveis em dados SAR de banda X.

O conjunto de treinamento, composto por 70% dos dados de entrada, resultou em um conjunto de 2.082 amostras estratificadas por extração e não extração. O conjunto, embora selecionado aleatoriamente, foi definido como replicável, ou seja, todos os testes utilizaram o mesmo conjunto, para evitar diferenças nos resultados oriundos de seleções amostrais diferentes.

4.3.1 Testes com o classificador Random Forest

Os resultados obtidos a partir da variação dos parâmetros e topologia do algoritmo Random Forest estão apresentados na Tabela 9. Em uma primeira visualização dos resultados, é possível observar que todas as topologias baseadas em Random Forest apresentaram bons resultados, já que a acurácia e a precisão obtidas foram próximas à 95% e a AUC superior, em todos os casos, a 0,95.


Tabela 9. Resultados do classificador Random Forest. Em negrito, os melhores resultados obtidos.

Id	Tempo de treinamento [s]	Tempo de teste [s]	AUC	Acurácia	F1	Precisão	Recall
RF1	0,349	0,1720	0,9661	0,9456	0,9461	0,9468	0,9456
RF2	0,418	0,0500	0,9721	0,9440	0,9441	0,9442	0,9440
RF3	0,550	0,0550	0,9742	0,9504	0,9506	0,9509	0,9504
RF4	0,991	0,0590	0,9737	0,9464	0,9467	0,9472	0,9464
RF5	1,423	0,0740	0,9740	0,9440	0,9443	0,9447	0,9440
RF6	0,898	0,0900	0,9740	0,9424	0,9423	0,9422	0,9424
RF7	4,962	0,2980	0,9772	0,9440	0,9442	0,9444	0,9440
RF8	5,369	0,4600	0,9792	0,9416	0,9417	0,9419	0,9416
RF9	1,769	0,1410	0,9759	0,9440	0,9440	0,9440	0,9440

Um problema comum em Aprendizado de Máquina é a comparação dos resultados de classificadores (ou topologias) aplicados a um conjunto de dados. Corani & Benavoli (2015) apresentam uma abordagem bayesiana para inferência estatística comparativa de dois algoritmos concorrentes avaliados por meio de validação cruzada. Tal abordagem é composta por duas partes: a primeira, constituída por uma nova proposta de teste-*t* Bayesiano correlacionado para a análise dos resultados da validação cruzada de um conjunto único de dados responsável pela correlação devido aos conjuntos de treinamento sobrepostos; e a segunda, mescla as probabilidades posteriores calculadas pelo teste-*t* Bayesiano correlacionado nos diferentes conjuntos de dados para fazer inferência em vários conjuntos (ou subconjuntos) de dados, adotando um modelo binomial de Poisson. As inferências em vários conjuntos de dados são responsáveis pelas diferentes incertezas dos resultados da validação cruzada nos diferentes conjuntos de dados. A realização do referido teste na validação cruzada *k-fold* com $k = 10$ mostrou que todas as topologias *Random Forest* são equivalentes, com uma probabilidade de 0,03.

As matrizes de confusão mostrando os acertos, erros de comissão e omissão em porcentagem estão apresentadas na Figura 39. O RF3 apresentou melhores precisão e acurácia, e ao analisar-se a matriz de confusão, é possível observar que também apresentou maior taxa de acerto para a classe extração (87%) e não extração (97,2%). Os menores tempos de treinamento e teste foram obtidos com o RF1 e RF2, porém, bem próximos aos tempos apresentados pelo RF3.

Figura 39. Matrizes de confusão dos resultados das classificações pelas topologias *Random Forest*.



4.3.2 Testes com o classificador AdaBoost


Os resultados obtidos a partir da variação dos parâmetros e da topologia do classificador AdaBoost são apresentados na Tabela 10. Nesta, é possível observar que a variação da topologia em número de estimadores não resultou em alterações significativas em nenhuma das medidas de qualidade dos classificadores, sendo todos considerados equivalentes.

Tabela 10. Resultados do classificador AdaBoost.

Id	Tempo de treinamento	Tempo de teste	AUC	Acurácia	F1	Precisão	Recall
	[s]	[s]					
AB1	0,901	0,064	0,903	0,919	0,919	0,919	0,919
AB2	0,625	0,067	0,899	0,914	0,914	0,914	0,914
AB3	0,749	0,049	0,899	0,914	0,914	0,914	0,914
AB4	0,514	0,036	0,899	0,914	0,914	0,914	0,914
AB5	0,664	0,034	0,909	0,924	0,924	0,924	0,924
AB6	0,547	0,036	0,909	0,924	0,924	0,924	0,924

As matrizes de confusão, apresentadas na Figura 40, mostram que a classe extração teve acerto de classificação próxima a 80% em todas as topologias, enquanto a não extração variou em torno de 94%, sem ganhos significativos com o aumento do número de estimadores. As topologias AB2, AB3 e AB4 apresentaram maior taxa de acerto para a classe extração, embora ligeiramente maiores valores de acurácia e precisão tenham sido obtidos pelas AB5 e AB6.

Figura 40. Matrizes de confusão dos resultados das classificações pelas topologias AdaBoost.



4.3.3 Testes com Redes Neurais Artificiais do tipo MLP


As tipologias utilizadas nos testes NN61 ao NN70, que replicaram as tipologias dos cinco melhores resultados obtidos nos testes de NN1 a NN60, foram NN23, NN26, NN31, NN22 e NN21, respectivamente. Os dez melhores resultados obtidos a partir da variação dos parâmetros e da topologia das NNs, em relação à acurácia e precisão, constam na Tabela 11.

Tabela 11. Resultados do classificador NN-MLP. Em negrito, os melhores resultados obtidos.

Id	Tempo de treinamento [s]	Tempo de teste [s]	AUC	Acurácia	F1	Precisão	Recall
NN22	3,723	0,208	0,987	0,959	0,958	0,958	0,959
NN26	9,456	0,161	0,988	0,961	0,961	0,961	0,961
NN29	102,091	0,222	0,983	0,957	0,957	0,957	0,957
NN31	12,075	0,224	0,986	0,956	0,956	0,956	0,956
NN32	117,475	0,236	0,986	0,954	0,954	0,954	0,954
NN36	28,229	0,195	0,988	0,960	0,960	0,960	0,960
NN37	209,572	0,259	0,986	0,954	0,954	0,954	0,954
NN64	8,518	0,210	0,986	0,956	0,956	0,956	0,956
NN66	4,238	0,173	0,983	0,955	0,955	0,955	0,955
NN70	3,672	0,174	0,986	0,960	0,959	0,959	0,960

As matrizes de confusão mostrando os acertos, erros de comissão e omissão em porcentagem dos melhores resultados obtidos através das ANNs estão apresentadas na Figura 41. As acurácia e precisão mais altas foram obtidas com a topologia NN26, com função de ativação ReLu e otimizador dos pesos SGD, não tendo apresentado diferença com o aumento do número de iterações. A referida topologia resultou em 89% e 96,4% de acerto para as classes extração e não extração, respectivamente. O tempo de teste também foi o menor (0,161 segundo), e o tempo de treinamento (9,456 segundos) significativamente inferior em relação aos apresentados pelas topologias NN29, NN32 e NN37.


Figura 41. Matrizes de confusão dos resultados das classificações pelas topologias NN-MLP.



4.3.4 Teste de generalização

A capacidade de generalização refere-se à capacidade de a rede classificar corretamente (ou próximo do correto) um dado de um conjunto de dados não utilizado para treinamento da rede (HAYKIN, 2008). Neste trabalho, realizou-se o teste de capacidade de generalização da NN26, cuja primeira etapa consistiu na limiarização da imagem de coeficiente de variação gerada entre as imagens COSMO-SkyMed de junho-outubro e janeiro-junho de 2018, a um valor de 0.4. Para tal teste, foram utilizadas as porções das cenas contidas na FLONA Jamari, conforme já mencionado. Esse procedimento resultou em 186.886 polígonos para as imagens de junho-outubro e 224.250 para janeiro-junho (Figura 42).

Figura 42. Polígonos gerados pela limiarização do coeficiente de variação (em amarelo) antes e depois da classificação, para os pares de imagens janeiro-junho e junho-outubro.




A Figura 42 apresenta também o resultado da classificação por meio da NN26 para a classe extração. Os dados foram validados, selecionando-se todos os polígonos contidos na área em que o inventário florestal fornecido pelo SFB está disponível (o qual inclui a posição geográfica das árvores cortadas), comparando o resultado da classificação com os dados do inventário. Para o resultado obtido entre as imagens COSMO-SkyMed de 05/06/2018 e 08/10/2018, sobre

as quais as tipologias foram treinadas, as extrações e não extrações corretamente classificadas representaram 88,8% e 95%, respectivamente. O índice de exatidão global foi de 91%.


Uma análise sobre os dados do inventário florestal apontou que 11% das árvores informadas como cortadas não foram identificadas, não tendo nem participado do processo de classificação por não terem sido delimitadas na primeira etapa (limiarização do coeficiente de variação). A avaliação dos 11% de árvores cortadas e não detectadas constatou que 36% representam cortes que não resultaram em clareiras e, portanto, não é possível identificá-los por meio de imageamento por sensores que interagem com o topo do dossel (Figura 43). Essas feições também não foram identificadas no produto Modelo Digital de Superfície Gerado a partir do último retorno do levantamento LiDAR. Os demais 64% tratam-se de árvores com copas pequenas ou sombreadas por copas vizinhas localizadas em sua frente em relação à direção de imageamento do sensor.

Figura 43. Imagens COSMO-SkyMed mostrando uma extração não identificada.




Para as imagens COSMO-SkyMed de janeiro-junho, as extrações e não-extrações corretamente classificadas representaram 88% e 92%, respectivamente. O índice de exatidão global foi de 89%. É possível observar que a imagem de janeiro apresenta ruídos em forma de faixas (Figura 44) que alteram os valores do coeficiente de retroespalhamento, e por consequência, geram altos valores de coeficiente de variação entre as imagens, ocasionando uma alta incidência de falsos positivos para a classe extração. Por isso, faz-se necessário observar os ocasionais ruídos, que podem ser resultantes de efeitos atmosféricos (frequentemente presentes em dados de banda X) ou problemas no sensor, e que podem interferir na qualidade dos resultados.

Figura 44. Polígonos gerados cortando o coeficiente de variação (em amarelo) das imagens de janeiro a junho mostrando listras indicando problemas de sensor/aquisição.



Embora os algoritmos de Aprendizado de Máquina tenham sido treinados a partir dos dados coletados nas áreas de exploração florestal legal, o teste de generalização apontou extrações ocorrendo em áreas externas às concessões do ano de 2018. A sobreposição das extrações detectadas no período entre junho e outubro com os polígonos apontados pelo sistema Detex (sistema de Detecção da Exploração Seletiva) (SFB, 2021) como áreas de explorações ilegais ocorridas entre junho e outubro, da parceria entre Serviço Florestal Brasileiro e Instituto Nacional de Pesquisas Espaciais, demonstrou que a metodologia apresentada pode ser útil na detecção da extração madeireira ilegal, dado que as detecções coincidiram, conforme pode ser observado na Figura 45.

Figura 45. Polígonos (em amarelo) classificados como extração (corte) e polígonos (em magenta) fornecidos pelo SFB delimitando a área de corte ilegal, mostrando áreas coincidentes.



4.3.5 Avaliação comparativa entre as técnicas de Aprendizado de Máquina

Dentre as diferentes arquiteturas testadas no conjunto de atributos gerado sobre as imagens de antes e depois da exploração, o melhor resultado foi obtido pela ANN de topologia NN26, a qual apresentou precisão e acurácia de 0,961, tendo acertado 89% das amostras de teste da classe extração e 96,4% da classe não extração. Apesar de exaustivos testes variando-se os parâmetros das topologias RF e NN, os resultados não apresentaram melhoria em relação aos apresentados. Esse fato apontou a necessidade de uma análise sobre o erro, com o objetivo de se entender os motivos que os ocasionaram. Foram analisados os erros das topologias NN26. Analisando-se os boxplots conjuntamente das feições corretamente classificadas como extração com aquelas que foram erroneamente classificadas como não extração, vê-se que o centro, a amplitude e a simetria dessas feições diferem-se, conforme pode ser observado na Figura 46, que exemplifica alguns atributos aleatoriamente selecionados e apresenta o *teste-t*, que rejeita a hipótese nula, demonstrando que as médias são estatisticamente diferentes. Da mesma forma, comparando-se as feições corretamente classificadas como não extração com aquelas que foram erroneamente classificadas como extração, temos dados assimétricos (Figura 46). Em resumo, as feições erroneamente classificadas tratam-se de outliers, tendo valores de atributos que as diferem do restante do conjunto amostral.

Analisando-se o dado LiDAR disponível para a área de estudo, é possível observar, a partir do modelo de superfície gerado antes e após a exploração, que as árvores retiradas (informadas pela concessionária que explora a área) que não foram delimitadas na etapa de limiarização do

coeficiente de variação, e portanto não foram incluídas no processo de classificação em extração ou não extração (11% das árvores cortadas), tratam-se de estruturas de copas pequenas (entre 6 e 10 m de diâmetro) e de arquitetura corimbiforme, e não emergentes em relação às copas vizinhas (Figura 47).

De acordo com Locks (2017), que realizou um estudo de identificação de dano ao dossel pela extração seletiva madeireira a partir de dados LiDAR, cerca de 93,3% das árvores abatidas resultam em dano no dossel, ou seja, é esperado que, por não resultarem em tal dano, aproximadamente 7% das extrações não sejam identificadas através de sensores imageadores que interagem em nível superficial com as copas das árvores, como é o caso da banda X.

Figura 46. Boxplots de feições classificadas incorretamente, exemplificando suas diferenças em um atributo selecionado aleatoriamente.





Figura 47. Modelos digitais de superfície gerados a partir de dados LiDAR de antes e depois da exploração mostrando uma árvore não detectada pelo método proposto.



Até esse momento, este estudo é o primeiro a investigar o potencial das imagens SAR de banda X adquiridas no modo StripMap, para o monitoramento da extração seletiva de madeira em florestas tropicais. Os resultados indicam boa possibilidade de utilização deste conjunto de dados, pois a atividade madeireira provoca alterações nos processos de retroespalhamento devido às mudanças na estrutura do dossel da floresta. No entanto, cerca de 7% das árvores extraídas não puderam ser identificadas devido à resolução espacial insuficiente do SAR e devido aos arranjos das copas das árvores extraídas em relação às suas vizinhas, conforme observado por Locks (2017).

A grande quantidade de dados disponíveis na Floresta Nacional do Jamari (imagens LiDAR e inventário florestal) permitiu a identificação de cicatrizes florestais causadas pela extração seletiva madeireira, essenciais para o treinamento dos algoritmos de Aprendizado de Máquina testados neste estudo. Mudanças multitemporais no sombreamento e iluminação nas imagens SAR da banda X, cujos sinais transmitidos interagem principalmente no topo das copas, puderam ser detectadas e delimitadas definindo um limiar em termos do coeficiente de variação. Essas mudanças no sombreamento e na iluminação também foram relatadas por Bouvet et al., (2018) como características potenciais para detecção e mapeamento de desmatamento. O limite baseado no coeficiente de variação, conforme relatado por Koeniguer e Nicolas (2020), é adequado para detectar mudanças devido à sua formulação simples e propriedades estatísticas notáveis.

Koeniguer e Nicolas (2020) apresentaram o primeiro estudo teórico demonstrando que o coeficiente de variação é relevante para detectar mudanças mesmo em áreas com manchas, e que possui propriedades estatísticas diferentes para pelo menos três categorias de perfis temporais: dispersor permanente, manchas naturais estáveis área e uma área não estacionária que geralmente é interpretada como uma mudança. Neste estudo, as áreas florestais que não sofreram interferência antrópica foram consideradas naturais com manchas estáveis, e os desmatamentos seletivos corresponderam a mudanças. Um limite de 0,4 habilitou a delimitação de características alteradas (registro seletivo) junto com algumas outras alterações relacionadas a manchas e interferência atmosférica (falsos positivos).

As técnicas de Aprendizado de Máquina consideradas neste estudo mostraram bons resultados em comparação com estudos anteriores sobre a detecção automática de extração seletiva baseados em imagens ópticas ou SAR de alta resolução, métodos semiautomáticos e de baixa frequência temporal (DEUTSCHER et al., 2013; COSTA et al., 2019; BULLOCK et al., 2020). As vantagens em relação aos estudos anteriores são as seguintes: (1) após o treinamento dos

algoritmos, o método é totalmente automático, reduzindo os erros associados à interpretação humana; (2) a possibilidade de monitoramento constante, mesmo sob condições climáticas adversas; (3) alta capacidade de revisita dos satélites de constelação COSMO-SkyMed da banda X; (4) alta capacidade de generalização das redes pré-treinadas, permitindo o uso do mesmo conjunto de treinamento se as imagens SAR forem adquiridas sob os mesmos parâmetros.

Os testes de capacidade de generalização apresentaram resultados próximos aos obtidos pelos algoritmos que contam com processos de treinamento, demonstrando alta generalização das redes treinadas. Um problema frequente relatado em estudos baseados em classificadores de Aprendizado de Máquina é a especialização da rede treinada (ou *overfitting*) e o problema de mínimos locais, limitando a capacidade de generalização e exigindo novas amostras de treinamento para cada cena a ser classificada (ZHU et al., 2017). Uma hipótese sugerida para os bons resultados obtidos neste trabalho é a estabilidade do sinal SAR nas imagens utilizadas e o uso de atributos texturais e espaciais, influenciados por mudanças espectrais em escala menor que os atributos espectrais. Além dos efeitos ionosféricos, o clima e as condições sazonais da superfície podem afetar consideravelmente as medições de SAR, modificando as características da série temporal e limitando as aplicações em grande escala (DOBLAS et al., 2020). No caso de imagens SAR de banda X, a interceptação de chuva, por exemplo, pode adicionar até 3 dB ao sinal retroespalhado. Vários autores estudaram esses fenômenos e apontaram soluções para estabilizar o sinal de dados SAR multitemporal (DOBLAS et al., 2020).

A imagem adquirida em janeiro de 2018 utilizada neste estudo mostrou problemas radiométricos relacionados ao sensor, como pode ser visto na Figura 44, o que não afetou negativamente a capacidade de generalização da rede pré-treinada. Porém, o método ainda precisa ser testado quanto à generalização da predição de acordo com fatores que podem afetar a detecção pelo modelo, como cenas cobrindo florestas distintas e obtidas em condições climáticas adversas. Também são sugeridos testes de redes neurais convolucionais (CNN), que têm grande potencial de generalização em áreas não vistas antes, pois usam informações contextuais e não são fortemente afetadas por valores absolutos de pixels (KATTENBORN et al., 2021). Outras abordagens sugeridas para reduzir o problema de *overfitting* são o aprendizado sem fim (MITCHELL et al., 2018) e o aprendizado autodidata (FENG et al., 2020), que podem ser testados no futuro.

Embora vários testes tenham sido realizados usando redes neurais profundas, o melhor resultado foi obtido usando uma rede neural de camada única. Independentemente da

profundidade da rede, uma vantagem do uso de redes neurais artificiais reside no fato de que a aprendizagem é baseada nas características dos dados apresentados e não no conhecimento a priori do intérprete (ZHU et al., 2017). Assim, um passo importante para a obtenção de bons resultados é a disponibilização de dados confiáveis para algoritmos de treinamento. A adoção de redes neurais para problemas de sensoriamento remoto apresenta vantagens em problemas cujos modelos físicos são complexos (não lineares, por exemplo), ainda não bem compreendidos, ou mesmo difíceis de serem generalizados (ZHU et al., 2017). A desvantagem desse tipo de abordagem é encontrar os hiperparâmetros adequados para o conjunto de dados e o problema considerado, bem como o longo tempo de treinamento (que aumenta com o número de camadas ocultas).

Abordagens baseadas em Aprendizado de Máquina, especialmente CNN, são frequentemente tratadas como caixas pretas devido à dificuldade de compreensão dos parâmetros que levaram a rede a uma determinada decisão. Kattenborn et al. (2021) justificaram este tratamento devido ao desconhecimento dos usuários com essas técnicas e a profundidade incomparável e número de parâmetros desses modelos. No entanto, a maioria dos modelos de Aprendizado de Máquina tem uma estrutura clara e linear e operações básicas, como funções de *pooling* e ativação. Em relação aos atributos utilizados neste estudo, é possível, por meio de várias abordagens, como os algoritmos genéticos (GOLDBERG, 1989), conhecer a contribuição individual para a obtenção dos resultados, buscando a otimização combinatória.

4.4 Testes de classificação por meio de Redes Neurais Convolucionais

Os testes das CNNs foram realizados com a NN26 como última camada totalmente conectada, já que essa apresentou o melhor resultado nos testes das ANN-MLPs. Sua arquitetura é composta por 1 camada escondida de 50 neurônios, com função de ativação ReLu e ativador de pesos SGD, $\alpha = 0,00002$ e 1.000 iterações.

O procedimento de recorte das imagens gerou 4.324 subimagens rotuladas para cada uma das três imagens, das quais 3.026 foram utilizadas para treinamento e 1.298 para teste. Os testes de classificação pelas CNNs pré-treinadas sobre a imagem *covmingrad* estão apresentados na Tabela 12A, sobre a imagem cov na Tabela 12B, e sobre a imagem razão na Tabela 12C, sendo todas as imagens provenientes do par de imagens CSK filtradas.

Tabela 12. Os resultados dos testes de classificação por CNNs pré-treinadas na imagem *covmingrad* são mostrados em A, na imagem *cov* em B, e na imagem *razão* em C.

A					
Embedder	Tempo de treinamento (s)	Tempo de teste (s)	AUC	Acurácia	Precisão
InceptionV3	82,971	1,103	0,953	0,912	0,912
VGG16	207,532	2,345	0,945	0,901	0,899
VGG19	385,772	2,547	0,937	0,907	0,905
SqueezeNet	132,128	0,511	0,954	0,918	0,918
Painters	124,047	1,064	0,951	0,920	0,915
DeepLoc	62,666	0,245	0,955	0,910	0,909
B					
Embedder	Tempo de treinamento (s)	Tempo de teste (s)	AUC	Acurácia	Precisão
InceptionV3	107,208	1,025	0,948	0,907	0,905
VGG16	333,649	3,194	0,954	0,906	0,904
VGG19	239,280	2,851	0,951	0,899	0,896
SqueezeNet	123,924	0,469	0,943	0,906	0,904
Painters	105,149	0,807	0,957	0,911	0,910
DeepLoc	64,436	0,187	0,957	0,910	0,909
C					
Embedder	Tempo de treinamento (s)	Tempo de teste (s)	AUC	Acurácia	Precisão
InceptionV3	145,101	1,475	0,838	0,858	0,851
VGG16	281,361	3,830	0,845	0,863	0,857
VGG19	285,898	2,321	0,845	0,860	0,854
SqueezeNet	61,798	0,476	0,850	0,850	0,843
Painters	125,313	1,031	0,849	0,858	0,851
DeepLoc	60,500	0,190	0,854	0,860	0,853

Os dados apresentados nas Tabela 12A, B e C mostram valores de acurácias e precisões obtidas acima de 85% para todas as imagens apresentadas, que são considerados ótimos resultados. Embora as diferenças entre os *embedders* testados tenham sido da ordem de menos de 5%, os testes sobre a composição RGB *covmingrad* apresentaram os melhores resultados, em particular utilizando o *embedder* Painters (acurácia = 92% e precisão ~ 92%). Os melhores tempos de treinamento e teste foram obtidos com o *embedder* DeepLoc para todos os testes realizados. As

matrizes de confusão para os melhores resultados obtidos para cada tipo de imagem de entrada estão apresentadas na Tabela 13.

Tabela 13. Matrizes de confusão dos melhores resultados obtidos através das CNNs testadas para cada tipo de imagem de entrada.


		predicted	
		timber extraction	no-timber extraction
covmingrad (Painters)			
ground truth	timber extraction	85,4%	7,0%
	no-timber extraction	14,6%	93,0%
cov (Painters)			
		predicted	
		timber extraction	no-timber extraction
ground truth	timber extraction	83,0%	6,6%
	no-timber extraction	17,0%	93,4%
ratio (VGG16)			
		predicted	
		timber extraction	no-timber extraction
ground truth	timber extraction	84,4%	11,2%
	no-timber extraction	15,6%	88,8%

Na Tabela 13, observa-se que a maior taxa de acerto para a classe extração de madeira foi obtida com o *embedder* Painters sobre a imagem covmingrad, e por isso, testou-se sua capacidade de generalização aplicando-a às imagens não-rotuladas (186.886 imagens). A matriz de confusão contendo os resultados (percentual em relação à predição) do teste de generalização está apresentada na Tabela 14. O Índice de Exatidão Global obtido foi de 87%. A Figura 48 apresenta os retângulos envolventes das subimagens não rotuladas antes e após a classificação.

Tabela 14. Matriz de confusão contendo os resultados (porcentagem em relação à previsão) do teste de generalização.

		predicted	
		timber extraction	no-timber extraction
covmingrad (Painters) – generalization test			
ground truth	timber extraction	87,5%	12,7%
	no-timber extraction	12,5%	87,3%

Figura 48. Candidatos à extração seletiva antes e após a classificação.



A Tabela 15 apresenta os resultados dos testes de classificação pelas CNNs pré-treinadas sobre a imagem *covmingrad* proveniente do par não filtrado de imagens CSK, com a finalidade de se avaliar a eficácia da classificação na presença de efeito *speckle*. A Tabela 16 apresenta a matriz de confusão da classificação pelo *embedder* Painters, cujas acurácias e precisão obtidas foram maiores que os demais.

Tabela 15. Resultados dos testes de classificação por CNNs pré-treinadas na imagem *covmingrad* do par não filtrado de imagens CSK.

Embedder	Tempo de treinamento (s)	Tempo de teste (s)	AUC	Acurácia	Precisão
InceptionV3	149,655	1,220	0,931	0,894	0,890
VGG16	412,935	14,689	0,923	0,890	0,888
VGG19	496,055	4,399	0,910	0,871	0,869
SqueezeNet	175,185	0,500	0,923	0,891	0,889
Painters	169,676	1,239	0,944	0,899	0,898
DeepLoc	127,549	0,263	0,932	0,887	0,887

Tabela 16. Matriz de confusão contendo os resultados (porcentagem em relação à predição) do teste com o Painters na imagem *covmingrad* do par não filtrado de imagens CSK.

covmingrad (Painters)		predicted	
		timber extraction	no-timber extraction
ground truth	timber extraction	81,2%	8,6%
	no-timber extraction	18,8%	91,4%

Dada sua baixa penetrabilidade no dossel, os dados em banda X são menos frequentemente aplicados a estudos florestais. Porém, alterações na estrutura do dossel ocasionadas por remoção vegetal podem ser perceptíveis pelos sensores que operam em bandas de altas frequências, por conterem mais informação textural (VAN DER SANDEN, 1997), a depender de fatores como biomassa, estrutura da floresta e condições do terreno, já que reduzem a intensidade da energia retroespalhada, conforme evidenciado por Bouvet et al. (2018). Quando as árvores de uma floresta são cortadas, sombras aparecem ou desaparecem, em suas bordas, dependendo da direção de órbita, da posição do fragmento em relação ao satélite e da cobertura do solo ao redor do fragmento (BOUVET et al., 2018).

O aparecimento do efeito de sombreamento é caracterizado pela queda repentina do retroespalhamento em uma série multitemporal de imagens adquiridas segundo os mesmos parâmetros (ângulo de visada, altura do sensor, órbita, modo de aquisição). Um fenômeno oposto também pode ser observado na posição oposta da área desmatada: o aparecimento de um aumento do retroespalhamento, que ocorre em função do efeito de retroespalhamento duplo exercido pelos troncos das árvores remanescentes que estão posicionadas na direção de propagação do sinal radar (VILLARD; BORDERIES, 2007).

Esse efeito possibilitou, conforme evidenciado neste estudo, a detecção de extrações seletivas ocorridas em uma área de floresta tropical na Amazônia brasileira, cuja extração seletiva é autorizada pelo governo. Os testes aplicando CNNs pré-treinadas sobre produtos do par bitemporal de imagens CSK apresentaram a banda X como apta à realização desse tipo de detecção, atingindo acurácia superior a 90% com o uso do *embedder* Painters sobre a imagens *covmingrad*. Ele foi capaz de classificar corretamente 85,4% das subimagens da classe extração seletiva e 93% da classe não extração. Apesar de seu desempenho não ser tão bom, os resultados da classificação das imagens *cov* e *ratio* apresentaram acurácias superiores a 85%, tendo classificado corretamente as extrações seletivas em 83% e 84,4%, respectivamente.

O teste de capacidade de generalização do *embedder* Painters sobre a imagem *covmingrad* apresentou, igualmente, bons resultados, com índice de exatidão global de 87%. Esses resultados são similares aos obtidos nos testes utilizando ANN-MLP sobre atributos extraídos manualmente dos produtos das mesmas imagens CSK bitemporais. A vantagem da utilização das CNNs reside na eliminação da etapa de geração dos atributos, reduzindo o tempo de processamento. Porém, em geral, o tempo de treinamento das CNNs foi superior ao das ANN-MLPs, dado que as CNNs são treinadas remotamente sobre um grande conjunto de dados (ImageNet, p. ex.).

O *embedder* Painters foi desenvolvido no âmbito da competição Painter by Numbers no Kaggle (NICHOL, 2016), cujo objetivo foi examinar pares de pinturas para determinar se eram pintadas pelo mesmo artista. O conjunto de treinamento consistiu em obras de arte e seus rótulos de classe correspondentes (pintores). Sua capacidade de identificar os estilos únicos dos pintores, em obras que não apresentam feições padrão, e sim abstratas (embora estilos e traços característicos, no caso de obras de um mesmo pintor), pode ter representado uma característica importante para a classificação das extrações e não extrações, que da mesma forma, não apresentam um padrão de forma (ao contrário da identificação de um rosto, por exemplo, onde existe um padrão característico). As outras redes utilizadas neste estudo foram treinadas com o conjunto de dados da ImageNet, que é composto de imagens de objetos concretos, a exemplo de carros, gatos, cachorros, aviões, etc.


O teste de classificação da imagem *covmingrad* proveniente das imagens CSK bitemporais não filtradas resultou em acurácia e precisão de 90% pelo *embedder* Painters, tendo sido capaz de classificar corretamente 81,2% das subimagens de extração seletiva. Esse resultado aponta que as CNNs são capazes de classificar corretamente esses alvos mesmo sob o efeito *speckle*, que, em geral, dificulta ou até impossibilita a identificação de alvos em imagens SAR, sendo sua supressão ou minimização foco de diversos estudos na área de sensoriamento remoto de micro-ondas (KUCK et al., 2021).

Até a submissão deste trabalho, nenhum estudo havia apresentado alternativa para monitoramento operacional de extração seletiva de madeira baseado em dados SAR em banda X, o que permite o monitoramento mesmo nos períodos de alta cobertura de nuvens na Amazônia, que compreende os meses entre outubro e abril. Este trabalho demonstra ser possível tal monitoramento em grande escala, já que uma rede bem treinada pode apresentar alta capacidade de generalização. Os dados SAR multitemporais, se adquiridos sob os mesmos parâmetros geométricos e radiométricos, apresentam mudanças relacionadas às alterações de cobertura da terra ou à presença de formações meteorológicas densas e alterações no teor de umidade dos alvos. Essas diferenças afetam o retroespalhamento e podem produzir falsas detecções (DOBLAS et al., 2020). Mais estudos devem ser realizados para se quantificar o efeito desses artefatos nas detecções através de CNNs, embora os testes com ANN-MLPs tenham demonstrado serem capazes de separar esses artefatos das extrações seletivas de madeira.

4.5 Estimativa da intensidade de exploração

O governo brasileiro, através do Serviço Florestal Brasileiro, desenvolveu um Sistema, denominado DETEX (SFB, 2021b), de mapeamento da extração seletiva de madeira. A Figura 49 apresenta os polígonos das áreas afetadas por extrações ilegais no ano 2018. Na mesma figura, é possível observar que as detecções através da CNNs (em magenta) apresentam como vantagem a delimitação da cicatriz no dossel de cada árvore ou conjunto de árvores retiradas, enquanto o DETEX (em amarelo) apresenta somente um polígono delimitador da área afetada.


Figura 49. Comparação entre a extração seletiva detectada pelo CNN (magenta) e pelo DETEX (amarelo).



Essa delimitação precisa da cicatriz permite, dada a correlação entre a área de clareiras decorrentes da exploração florestal e a IEX (Intensidade de Exploração – m^3/ha) apresentada por Locks (2017), estimar a IEX.


Em geral, as áreas de exploração legal, ou seja, aquelas sob concessão, possuem limites bem definidos, facilitando a tarefa de estimação da IEX. Para as áreas de exploração ilegal, uma alternativa que se propõe é o agrupamento dos polígonos classificados como extração pelo método DBSCAN (*Density Based Spatial Clustering of Application with Noise*) (ESTER et al., 1996), cujos parâmetros requeridos e adotados foram o tamanho mínimo do grupo (5 clareiras) e máxima distância entre clareiras agrupadas, definida como 60 m a partir de análise das distâncias entre clareiras apresentada na Figura 50.

Figura 50. Distribuição das distâncias entre clareiras na extração seletiva legal e ilegal.



A Figura 51 apresenta os polígonos de clareiras agrupados. As clareiras apresentadas na Figura 51 em branco são aquelas geograficamente isoladas. Para detecção de áreas de exploração ilegal, por exemplo, ou mesmo para monitoramento das concessões florestais, essas clareiras poderiam ser desconsideradas, por representarem, em muitos casos, quedas arbóreas naturais ou perda foliar intensa, já que pelo fato de a extração madeireira requerer infraestrutura de transporte, apresenta padrão concentrado de cicatrizes, e não disperso. Essa abordagem pode ser útil especialmente para os esforços de fiscalização in loco, direcionando operações para áreas em estágio inicial de exploração, reduzindo a ocorrência de falsos positivos.

Figura 51. Polígonos classificados como extração (agrupados - cada cor representa um grupo).
Em vermelho, limite da Floresta Nacional do Jamari.



5. CONCLUSÕES

As imagens utilizadas neste estudo, cujas datas de aquisição coincidiram com o período anterior e posterior à extração seletiva madeireira na FLONA do Jamari, permitiram identificar as feições decorrentes desse tipo de atividade, uma vez que todas as imagens foram adquiridas segundo os mesmos parâmetros (direção da órbita, ângulo de incidência, banda e polarização); portanto, as mudanças temporais referem-se a mudanças na cobertura da terra em vez de diferenças nos parâmetros de aquisição. Outros fatores que podem causar alterações multitemporais em imagens SAR de banda X são eventos atmosféricos graves e falhas no processo de aquisição de imagens.

Considerando a pesquisa bibliográfica realizada até a entrega desta tese, nenhuma pesquisa foi publicada abordando o uso de dados SAR de banda X adquiridos no modo StripMap para o monitoramento sistemático da extração seletiva de madeira em uma floresta tropical. Com o aumento da disponibilidade desses dados, por meio do lançamento de novas constelações de SAR em banda X, novas metodologias de extração de informações são necessárias para aplicações que demandam grandes revisitas.

As técnicas de Aprendizado de Máquina testadas mostraram bons resultados a partir dos atributos gerados com imagens adquiridas antes e depois da exploração da área, mostrando o potencial de detecção de extração seletiva em florestas tropicais por meio de dados SAR de banda-X. As taxas de acurácia obtidas para a classe de floresta explorada seletivamente foram de aproximadamente 88% usando uma ANN com 50 neurônios em uma camada oculta, com função de ativação ReLu e um otimizador de peso SGD com 1.000 iterações, mesmo no teste de validação aplicado a um conjunto de dados diferente daquele usado para treinamento. Ainda que a inflexão da curva de erro do conjunto de teste não tenha sido avaliada, a alta capacidade de generalização dos algoritmos testados demonstrou um baixo risco de ter havido *overfitting*. Foram realizados ainda testes com Redes Neurais Convolucionais pré-treinadas. Os testes demonstraram que as CNNs foram capazes de apresentar bons resultados para o caso estudado, mesmo quando aplicadas sobre os produtos bitemporais provenientes das imagens não filtradas. Muitos estudos têm apresentado alternativas de redução do efeito *speckle* sobre imagens SAR dado que tal efeito reduz a capacidade de detecção de alvos e classificação dessas imagens. Sugere-se que estudos futuros sejam realizados para mensurar a contribuição desse efeito na redução do desempenho das técnicas baseadas em Aprendizado de Máquina para classificação de imagens SAR.

O fato de a ANN-MLP ter superado o desempenho da CNN pode se dever a um número insuficiente de amostras, refinamento não totalmente explorado na parametrização da rede ou à arquitetura da rede utilizada não ter sido a ideal para o problema proposto.

O método DBSCAN de agrupamento foi apresentado como uma alternativa para identificação de áreas em estágio inicial de exploração seletiva ilegal, bem como para mensuração da intensidade de exploração em áreas legais e ilegais. Apesar de já iniciados, mais estudos devem ser realizados para se estabelecer a correlação entre área de clareiras e intensidade de exploração.

Como a banda X interage principalmente no topo do dossel da floresta, apenas extrações seletivas que causam danos ao dossel podem ser detectadas. Como resultado, 11% das árvores identificadas como exploradas na UPA 11 não puderam ser identificadas na primeira etapa do método proposto, e essas florestas exploradas não puderam ser detectadas usando o produto do modelo digital de superfície derivado do primeiro retorno de dados LiDAR.

Recomenda-se que estudos futuros explorem melhor métodos de supressão ou minimização de erros relacionados a ruídos sistemáticos nas imagens ou causados por eventos meteorológicos extremos, que afetam os sinais de retroespalhamento da banda X, causando um aumento nos erros de comissão. Outra sugestão é estender os testes incluindo algoritmos de Aprendizado de Máquina baseados em segmentação semântica, como é o caso da UNet.

6. REFERÊNCIAS

- ABIODUN, O. I.; JANTAN, A.; OMOLARA, A. E.; DADA, K. V.; MOHAMED, N. A. E.; ARSHAD, H. State-of-the-art in artificial neural network applications: A survey. **Heliyon**, v. 4, p. 1–41, 2018.
- ACHIM, A.; KURUOĞLU, E. E.; ZERUBIA, J. SAR image filtering based on the heavy-tailed rayleigh model. **IEEE Transactions on Image Processing**, v. 15, n. 9, p. 2686–2693, 2006.
- ALLEN, M.; CONINCK, H. de; DUBE, O. P.; HOEGH-GULDBERG, O.; JACOB, D.; JIANG, K.; REVI, A.; ROGELJ, J.; ROY, J.; SHINDELL, D.; SOLECKI, W.; TAYLOR, M.; TSCHAKERT, P.; WAISMAN, H. **Technical Summary: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty**, Intergovernmental Panel on Climate Change – IPCC, 2018, 22 p.
- ALMAGRO ARMENTEROS, J. J.; SØNDERBY, C. K.; SØNDERBY, S. K.; NIELSEN, H.; WINTHER, O. DeepLoc: prediction of protein subcellular localization using deep learning. **Bioinformatics**, v. 33, n. 21, p. 3387–3395, 2017.
- ALVARENGA JR., W. J. de. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária**. (Mestrado em Engenharia Elétrica). Belo Horizonte: UFMG, 2018.
- ARGENTI, F.; LAPINI, A.; ALPARONE, L.; BIANCHI, T. A tutorial on speckle reduction in synthetic aperture radar images. **IEEE Geoscience and Remote Sensing Magazine**, v. 1, p. 6–35, 2013.
- ARMENTEROS, J. J. A.; SØNDERBY, C. K.; SØNDERBY, S. K.; NIELSEN, H.; WINTHER, O. DeepLoc: prediction of protein subcellular localization using deep learning. **Bioinformatics**, v. 33, n. 21, p. 3387–3395, 2017.
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 2001.
- ASNER, G. P.; KNAPP, D. E.; BROADBENT, E. N.; OLIVEIRA, P. J. C.; KELLER, M.; SILVA, J. N. Ecology: Selective logging in the Brazilian Amazon. **Science**, v. 305, n. 5747, p. 480–482, 2005.
- ASNER, G. P.; BROADBENT, E.; OLIVEIRA, P. J. C.; KELLER, M. Condition and fate of logged forests in the Brazilian Amazon. **Proceedings of the National Academy of Sciences of the United States of America**, v. 103, n. 34, p. 12947–12950, 2006.
- ASNER, G. P.; KNAPP, D. E.; BALAJI, A.; PÁEZ-ACOSTA, G. Automated mapping of tropical deforestation and forest degradation: CLASlite. **Journal of Applied Remote Sensing**, v. 3, n. 1, p. 033543, 2009.
- ASNER, G. P.; KELLER, M.; SILVA, J. N. Spatial and temporal dynamics of forest canopy gaps following selective logging in the eastern Amazon. **Global Change Biology**, v. 10, p. 765–783, 2004.
- ASPERT, F.; CUADRA, M. B.; CANTONE, A.; HOLECZ, F.; THIRAN, J. P. Time-varying segmentation for mapping of land cover changes. In: ENVISAT SYMPOSIUM, Montreaux,

Suíça. **Anais...** ESA, 2007.

ATKINSON, P. M.; TATNALL, A. R. L. Introduction neural networks in remote sensing. **International Journal of Remote Sensing**, v. 18, p. 699–709, 1997.

BÄCK, T.; HOFFMEISTER, F.; SCHWEFEL, H.-P. A Survey of Evolution Strategies. In: Proceedings of the Fourth International Conference on Genetic Algorithms, São Diego, CA. **Anais...** 1991.

BALL, J. E.; ANDERSON, D. T.; CHAN, C. S. A comprehensive survey of deep learning in remote sensing: Theories, tools and challenges for the community. **Journal of Applied Remote Sens.**, v. 11, n. 4, 042609, 2017.

BARKMAN, J. J. The investigation of vegetation texture and structure. In: WERGER, M. J. A. (Ed.). **The study of vegetation**. 1a ed., Springer, Netherlands, 1979. p. 123–160.

BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.

BERNINGER, A.; LOHBERGER, S.; STÄNGEL, M.; SIEGERT, F. SAR-based estimation of above-ground biomass and its changes in tropical forests of Kalimantan using L- and C-band. **Remote Sensing**, v. 10, p. 831, 2018.

BIRNBAUM, P. **Modalités d ’ occupation de l ’ espace par les arbres en forêt guyanaise** **Modalités d ’ occupation de l ’ espace par les arbres en forêt guyanaise** (Doutorado em Ciências da Vida), Paris: Université Paris-Sorbonne, 1997.

BONGERS, F. Methods to assess tropical rain forest canopy structure: An overview. **Plant Ecology**, v. 153, n. 1, p. 263–277, 2001.

BOSE, T. **Digital Signal and Image Processing**. Nova York: John Wiley & Sons, 2003, 656 p.

BOTTOU, L. Large-scale machine learning with stochastic gradient descent. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL STATISTICS (COMPSTAT 2010), 19., Paris, França. **Anais...** IASC, 2010.

BOUVET, A.; MERMOZ, S.; BALLÈRE, M.; KOLECK, T.; LE TOAN, T. Use of the SAR shadowing effect for deforestation detection with Sentinel-1 time series. **Remote Sensing**, v. 10, p. 1250, 2018.

BULLOCK, E. L.; WOODCOCK, C. E.; JR., C. S.; OLOFSSON, P. Satellite-based estimates reveal widespread forest degradation in the Amazon. **Global Change biology**, v. 26, p. 2956–2969, 2020.

BYRD, R. H.; LU, P.; NOCEDAL, J.; ZU, C. A limited memory algorithm for bound constrained optimization. **SIAM Journal on Scientific Computing**, v. 16, n. 5, p. 1190–1208, 1995.

CAMPBELL, G. S.; NORMAN, J. M. **Plant canopies: their growth, form and function**. Cambridge: Cambridge University Press, 1989.

CASTEL, T.; GUERRA, F.; CARAGLIO, Y.; HOULLIER, F. Retrieval biomass of a large Venezuelan pine plantation using JERS-1 SAR data. Analysis of forest structure impact on radar signature. **Remote Sensing of Environment**, v. 79, n. 1, p. 30–41, 2002.

- CENSIPAM. Projeto Cartografia da Amazônia. 2015. Disponível em: <<https://www.marinha.mil.br/dhn/sites/www.marinha.mil.br/dhn/files/arquivos/PT001-2015-Cartografia-da-Amazônia.pdf>>. Acesso em: 21 jul. 2021.
- CHEN, H.; JIAO, L.; LIANG, M.; LIU, F.; YANG, S.; HOU, B. Fast unsupervised deep fusion network for change detection of multitemporal SAR images. **Neurocomputing**, v. 332, p. 56–70, 2019.
- CHEN, S.; LI, X.; CHI, S.; LI, Z.; YUXING, M. Ship Target Discrimination in SAR Images Based on BOW Model With Multiple Features and Spatial Pyramid Matching. **IEEE Access**, v. 8, p. 166071–166082, 2020.
- CHENG, G.; XIE, X.; HAN, J.; GUO, L.; XIA, G. S. Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 3735–3756, 2020.
- COCHRANE, M. A.; ALENCAR, A.; SCULZE, M. D.; SOUZA Jr., C. M.; NEPSTAD, D. C.; LEFEBVRE, P.; DAVIDSON, E. A. Positive feedbacks in the fire dynamic of closed canopy tropical forests. **Science**, v. 284, n. 5421, p. 1832–1835, 1999.
- COCHRANE, M. A. Synergistic interactions between habitat fragmentation and fire in evergreen tropical forests. **Conservation Biology**, v. 15, n. 6, p. 1515–1521, 2001.
- COCHRANE, M. A.; SCHULZE, M. D. Forest Fires in the Brazilian Amazon. **Conservation Biology**, v. 12, n. 5, p. 948–950, 1998.
- CORANI, G.; BENA VOLI, A. A Bayesian approach for comparing cross-validated algorithms on multiple data sets. **Machine Learning**, v. 100, p. 285–304, 2015.
- COSTA, O. B. da; MATRICARDI, E. A. T.; PEDLOWSKI, M. A.; MIGUEL, E. P.; GASPAR, R. de O. Selective Logging Detection in the Brazilian Amazon. **Floresta e Ambiente**, v. 26, n. 2, 2019.
- CUI, B.; ZHANG, Y.; YAN, L.; WEI, J.; WU, H. An unsupervised SAR change detection method based on stochastic subspace ensemble learning. **Remote Sensing**, v. 11, p. 1314, 2019.
- CUTLER, M. E. J.; BOYD, D. S.; FOODY, G. M.; VETRIVEL, A. Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: An assessment of predictions between regions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p. 66–77, 2012.
- DAS, A.; SAHI, A.; NANDINI, U. SAR image segmentation for land cover change detection. In: 2016 ONLINE INTERNATIONAL CONFERENCE ON GREEN ENGINEERING AND TECHNOLOGIES (IC-GET), Coimbatore, India. **Anais...** 2016, 6 p.
- DE GRANDI, G. F.; LEYSEN, M.; LEE, J. S.; SCHULER, D. Radar reflectivity estimation using multiple SAR scenes of the same target: Technique and applications. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS '97). Singapura, **Anais...** IEEE, v. 2, p. 1047–1050, 1997.
- DE, S.; PIRONE, D.; BOVOLO, F.; BRUZZONE, L.; BHATTACHARYA, A. A novel change detection framework based on deep learning for the analysis of multi-temporal polarimetric SAR images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2017), Nova York, EUA **Anais...** IEEE, p. 5193–5196, 2017.

DELGADO-AGUILAR, M. J.; FASSNACHT, F. E.; PERALVO, M.; GROSS, C. P.; SCHMITT, C. B. Potential of TerraSAR-X and Sentinel 1 imagery to map deforested areas and derive degradation status in complex rain forests of Ecuador. **International Forestry Review**, v. 19, p. 102–118, 2017.

DEMŠAR, J.; CURK, T.; ERJAVEC, A.; GORUP, Č.; HOČEVAR, T.; MILUTINOVIČ, M.; MOŽINA, M.; POLAJNAR, M.; TOPLAK, M.; STARIČ, A.; ŠTAJDOHAR, M.; UMEK, L.; ŽAGAR, L.; ŽBONTAR, J.; ŽITNIK, M.; ZUPAN, B. Orange: Data mining toolbox in python. **Journal of Machine Learning Research**, v. 14, p. 2349–2353, 2013.

DEUTSCHER, J.; PERKO, R.; GUTJAHR, K.; HIRSCHMUGL, M.; SCHARDT, M. Mapping tropical rainforest canopy disturbances in 3D by COSMO-SkyMed spotlight inSAR-stereo data to detect areas of forest degradation. **Remote Sensing**, v. 5, n. 2, p. 648–663, 2013.

DINIZ, C. G.; SOUZA, A. A. D. A.; SANTOS, D. C.; DIAS, M. C.; LUZ, N. C. Da; MORAES, D. R. V. De; MAIA, J. S. A.; GOMES, A. R.; NARVAES, I. D. S.; VALERIANO, D. M.; MAURANO, L. E. P.; ADAMI, M. DETER-B: The New Amazon Near Real-Time Deforestation Detection System. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 7, p. 3619–3628, 2015.

DOBLAS, J.; SHIMABUKURO, Y.; SANT'ANNA, S.; CARNEIRO, A.; ARAGÃO, L.; ALMEIDA, C. Optimizing near real-time detection of deforestation on tropical rainforests using sentinel-1 data. **Remote Sensing**, v. 12, n. 23, p. 3922, 2020.

DONG, H.; MA, W.; WU, Y.; GONG, M.; JIAO, L. Local Descriptor Learning for Change Detection in Synthetic Aperture Radar Images via Convolutional Neural Networks. **IEEE Access**, v. 7, p. 15389–15403, 2019.

DORIGO, M.; BIRATTARI, M.; STUTZLE, T. Ant colony optimization. **IEEE Computational Intelligence Magazine**, v. 1, n. 4, p. 28–39, 2006.

DOS SANTOS, J. R.; ARAUJO, L. S.; KUPLICH, T. M.; FREITAS, C. C.; DUTRA, L. V.; SANT'ANNA, S. J. S.; GAMA, F. F. Tropical forest biomass and its relationship with P-band SAR. **Revista brasileira de Cartografia**, 2006.

DU, P.; SAMAT, A.; WASKE, B.; LIU, S.; LI, Z. Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 38–53, 2015.

EL-DARYMLI, K.; MCGUIRE, P.; GILL, E.; POWER, D.; MOLONEY, C. Understanding the significance of radiometric calibration for synthetic aperture radar imagery. In: 2014 IEEE CANADIAN CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING (CCECE), 27. Toronto, Ontário. **Anais... IEEE**, 2014, 6 p.

ELIASCH, J. **Climate Change: Financing Global forests: the Eliasch Review**. Earthscan, 2008, 288 p.

ELIASY, A.; PRZYCHODZEN, J. The role of AI in capital structure to enhance corporate funding strategies. **Array**, v. 6, p. 1–13, 2020.

ESA. **Sentinel Online**. Disponível em: < <https://sentinels.copernicus.eu/web/sentinel/home>>. Acesso em: 21 jul. 2021.

ESTER, M.; KRIEGEL, H. P.; SANDER, J.; XU, X. A density-based algorithm for discovering clusters in large spatial databases with noise. In: KDD-96: INTERNATIONAL

CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 2. Portland, Oregon. **Anais...AAAI**, 1996, p. 226–231.

EVERITT, B. S.; SKRONDAL, A. **The Cambridge Dictionary of Statistics**, 2010.

FAWZI, N. I.; HUSNA, V. N.; HELMS, J. A. Measuring deforestation using remote sensing and its implication for conservation in Gunung Palung National Park, West Kalimantan, Indonesia. In: IOP Conference Series: Earth and Environmental Science, **Anais...2018**. Disponível em: <<https://doi.org/10.1088/1755-1315/149/1/012038>>.

FENG, S.; YU, H.; DUARTE, M. F. Autoencoder based sample selection for self-taught learning. **Knowledge-Based Systems**, v. 192, p. 105343, 2020. Disponível em: <<https://doi.org/10.1016/j.knosys.2019.105343>>.

FERRAZ, S. F. de B.; VETTORAZZI, C. A.; THEOBALD, D. M.; BALLESTER, M. V. R. Landscape dynamics of Amazonian deforestation between 1984 and 2002 in central Rondônia, Brazil: Assessment and future scenarios. **Forest Ecology and Management**, v. 204, n. 1, p. 67–83, 2005.

FLETCHER, R. **Practical Methods of Optimization**. New York, USA: Wiley-Interscience, 2000.

FONSECA, T. L. **Algoritmo genético com regressão: Busca direcionada através de Aprendizado de Máquina** (Mestrado em Modelagem Computacional), Universidade Federal de Juiz de Fora, Juiz de Fora, MG, 2017, 108 p.

FREUND, Y.; SCHAPIRE, R. E. Experiments with a new boosting algorithm. **13th INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML'96)**, 13. Bari, Itália. **Anais...**, v. 28, p. 1733–1746, 1996.

FROST, V. S.; STILES, J. A.; SHANMUGAN, K. S.; HOLTZMAN, J. C. A Model for Radar Images and Its Application to Adaptive Digital Filtering of Multiplicative Noise. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-4, n. 2, p. 157–166, 1982.

GAGNON, L.; JOUAN, A. Speckle filtering of SAR images - A comparative study between complex-wavelet-based and standard filters. In: OPTICAL SCIENCE, ENGINEERING AND INSTRUMENTATION '97, São Diego, CA. **Anais...** v. 3169, Wavelet Applications in Signal and Image Processing, 1997, 12 p.

GENG, J.; MA, X.; ZHOU, X.; WANG, H. Saliency-guided deep neural networks for SAR image change detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 57, n. 10, p. 7365–7377, 2019.

GHARBIA, ALSHIMAA Y. ABO; AMIN, MOHAMED; MOUSA, ASHRAFE.; ABOUALY, NADIA; EL BANBY, GHADA M. EL; EL-SAMIE, F. E. A. Registration-based change detection for SAR images. **NRIAG Journal of Astronomy and Geophysics**, v. 9, n. 1, p. 106–115, 2020.

GHOSH, A.; FASSNACHT, F. E.; JOSHI, P. K.; KOCHB, B. A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 49–63, 2014.

GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data

synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, n. March, p. 29–40, 2018. Disponível em: <<https://doi.org/10.1016/j.apgeog.2018.05.011>>.

GLOVER, F.; LAGUNA, M. **Tabu Search**. Boston: Kluwer Academic Publishers, 1997.

GOFC-GOLD. A Sourcebook of Methods and Procedures for Monitoring and Reporting Anthropogenic Greenhouse.. **GOFC-GOLD Report version COP21-1**, p. 1–266, 2016. Disponível em: <<http://www.gofcgold.wur.nl/redd/>>.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Boston, MA: Addison Wesley, 1989, 372 p.

GOMEZ, L.; BUEMI, M. E.; JACOBO-BERLLES, J. C.; MEJAIL, M. E. A New Image Quality Index for Objectively Evaluating Despeckling Filtering in SAR Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 3, p. 1297–1307, 2016.

GONG, M.; YANG, H.; ZHANG, P. Feature learning and change feature classification based on deep learning for ternary change detection in SAR images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 129, p. 212–225, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, MA: The MIT Press, 2016.

GOODMAN, J. W. Statistical properties of laser speckle patterns. In: **Topics in Applied Physics**. Berlin: Springer-Verlag, v. 9, 1975, p. 9–75.

HALL, M. A. **Correlation-based feature selection for machine learning** (Doutorado em Ciência da Computação), Hamilton, Nova Zelândia: Universidade de Waikato, 1999, 199 p.

HAN, P.; MA, C.; LI, Q.; LENG, P.; BU, S.; LI, K. Aerial image change detection using dual regions of interest networks. **Neurocomputing**, v. 349, p. 190–201, 2019.

HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S. A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. G. High-resolution global maps of 21st-century forest cover change. **Science**, 2013.

HARALICK, R. M.; DINSTEN, I.; SHANMUGAM, K. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973.

HAYKIN, S. **Neural Networks and Learning Machines**. New Jersey, EUA: Pearson Prentice Hall, 2008.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV 2015), Santiago, Chile. **Anais... IEEE**, 2015, p. 1026–1034.

HENDERSON, F. M.; LEWIS, A. J. **Principles and Applications of Imaging Radar. Manual of Remote Sensing**. 3^a ed., v. 2, John Wiley, 1998, 866 p.

HERZOG, A. L.; VIEIRA, R. Brasil destrói 128 campos de futebol de floresta por hora. **Revista Exame**, 2017. Disponível em: <<https://exame.com/revista-exame/brasil-destroi-128-campos-de-futebol-de-floresta-por-hora/>>. Acesso em: 22 ago. 2021.

HUTH, A.; DITZER, T. Long-term impacts of logging in a tropical rain forest - A simulation study. **Forest Ecology and Management**, v. 142, n. 1–3, p. 33–51, 2001.

IANDOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. **ICLR**, p. 1–14, 2016.

IBGE. **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro: IBGE, 2ª ed., 2012, 272 p.

INPE. **Monitoramento Da Cobertura Florestal Da Amazônia Por Satélites**. Ministério da Ciência e Tecnologia, 2008a.

INPE. **Monitoramento da cobertura florestal da Amazônia por satélites: sistemas PRODES, DETER, DEGRAD e Queimadas 2007-2008**. São José dos Campos: INPE, 2008, 47 p.

IPCC. **Definitions and methodological options to inventory emissions from direct human-induced degradation of forests and devegetation of other vegetation types**. Hayama, Japão: IGES, 2003.

IPCC. **Global Warming of 1.5° Catalysis from A to Z**, 2018.

JATURAPITPORNCHAI, R.; MATSUOKA, M.; KANEMOTO, N.; KUZUOKA, S.; ITO, R.; NAKAMURA, R. Newly built construction detection in SAR images using deep learning. **Remote Sensing**, v. 11, p. 1444, 2019.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective**. Pearson Education Limited, Harlow, England, Second Edition, 2014.

JOSHI, N.; BAUMANN, M.; EHAMMER, A.; FENSHOLT, R.; GROGAN, K.; HOSTERT, P.; JEPSEN, M. R.; KUEMMERTE, T.; MEYFROIDT, P.; MITCHARD, E. T. A.; REICHE, J.; RYAN, C. M.; WASKE, B. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, v. 8, 70, 2016.

KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, v. 62, p. 15–25, 2019.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, p. 24–49, 1 mar. 2021.

KINGMA, D. P.; BA, J. L. Adam: A method for stochastic optimization. In: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS (ICLR 2015), 3. São Diego, CA. **Anais...** 2015.

KOENIGUER, E. C.; NICOLAS, J. M. Change detection based on the coefficient of variation in SAR time-series of urban areas. **Remote Sensing**, v. 12, p. 2089, 2020.

KOENIGUER, E.; NICOLAS, J. M.; JANEZ, F. Worldwide multitemporal change detection using Sentinel-1 images. In: BIDS - CONFERENCE ON BIG DATA FROM SPACE, Munique, Alemanha. **Anais...** ESA, 2019.

KUAN, D. T.; SAWCHUK, A. A.; STRAND, T. C.; CHAVEL, P. Adaptive Restoration of Images with Speckle. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 35, n. 3, p. 373–383, 1987.

- KUCK, T. N.; GOMEZ, L. D.; SANO, E. E.; BISPO, P. da C.; HONORIO, D. D. C. Performance of Speckle Filters for COSMO-SkyMed Images from the Brazilian Amazon. **IEEE Geoscience and Remote Sensing Letters**, v. 99, p. 1–5, 2021.
- KUPLICH, T. M.; CURRAN, P. J.; ATKINSON, P. M. Relating SAR image texture to the biomass of regenerating tropical forests. **International Journal of Remote Sensing**, v. 26, n. 21, p. 4829–4854, 2005.
- KUPLICH, T. M.; SALVATORI, V.; CURRAN, P. J. JERS-1/SAR backscatter and its relationship with biomass of regenerating forests. **International Journal of Remote Sensing**, v. 21, n. 12, p. 2513–2518, 2000.
- LANG, H.; WU, S. Ship Classification in Moderate-Resolution SAR Image by Naive Geometric Features-Combined Multiple Kernel Learning. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 10, p. 1765–1769, 2017.
- LAURANCE, W. F.; LAURANCE, S. G.; FERREIRA, L. V.; MERONA, J. M. R.; GASCON, C.; LOVEJOY, T. E. Biomass collapse in Amazonian forest fragments. **Science**, v. 278, n. 5340, p. 1117–1118, 1997.
- LAWRENCE, R.L.; WOOD S.D.; SHELEY, R.L. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (RandomForests). **Remote Sensing of Environment**, 100:356–362, 2006.
- LAURIN, G. V.; LIESENBERG, V.; CHEN, Q.; GUERRIERO, L.; DEL FRATE, F.; BARTOLINI, A.; COOMES, D.; WILEBORE, B.; LINDSELL, J.; VALENTINI, R. Optical and SAR sensor synergies for forest and land cover mapping in a tropical site in West Africa. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 7–16, 2013.
- LE TOAN, T.; BEAUDOIN, A.; RIOM, J.; GUYON, D. Relating forest biomass to SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 403–411, 1992.
- LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 2, n. 2, p. 165–168, 1980.
- LEE, J. Sen. Refined filtering of image noise using local statistics. **Computer Graphics and Image Processing**, v. 15, p. 380–389, 1981.
- LEE, J. S.; GRUNES, M. R.; MANGO, S. A. Speckle reduction in multipolarization, multifrequency SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 4, p. 535–544, 1991.
- LEE, Y. S.; LEE, S.; BAEK, W. K.; JUNG, H. S.; PARK, S. H.; LEE, M. J. Mapping forest vertical structure in Jeju Island from optical and radar satellite images using artificial neural network. **Remote Sensing**, v. 12, n. 5, p. 797, 2020.
- LI, Y.; PENG, C.; CHEN, Y.; JIAO, L.; ZHOU, L.; SHANG, R. A Deep Learning Method for Change Detection in Synthetic Aperture Radar Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 57, p. 5751–5763, 2019.
- LIU, R.; WANG, R.; HUANG, J.; LI, J.; JIAO, L. Change Detection in SAR Images Using Multiobjective Optimization and Ensemble Strategy. **IEEE Geoscience and Remote Sensing Letters**, v. 18, n. 9, p. 1585–1589, 2020.

- LOCKS, C. J. **Aplicações da tecnologia LiDAR no monitoramento da exploração madeireira em áreas de concessão florestal** (Mestrado em Ciências Florestais), Brasília: UnB, 2017, 97 p.
- LOHBERGER, S.; STÄNGEL, M.; ATWOOD, E. C.; SIEGERT, F. Spatial evaluation of Indonesia's 2015 fire-affected area and estimated carbon emissions using Sentinel-1. **Global Change Biology**, v. 24, n. 2, p. 644–654, 2018.
- LOPES, A.; NEZRY, E.; TOUZI, R.; LAUR, H. Maximum a posteriori speckle filtering and first order texture models in SAR images. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'90), College Park, MD. **Anais...** IEEE, p. 2409–2412, 1990.
- LOUREIRO, V. R.; PINTO, J. N. A. A questão fundiária na Amazônia. **Estudos Avançados**, v. 19, n. 54, p. 77–98, 2005.
- MACEDO, C. R.; OGASHAWARA, I. Comparação de filtros adaptativos para redução do ruído speckle em imagens SAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. Foz do Iguaçu, PR. **Anais...** São José dos Campos: INPE, p. 8358–8365, 2013.
- MAHDAVI, S.; SALEHI, B.; MOLONEY, C.; HUANG, W.; BRISCO, B. Speckle filtering of Synthetic Aperture Radar images using filters with object-size-adapted windows. **International Journal of Digital Earth**, v. 11, p. 703–729, 2018.
- MATRICARDI, E. **Spatiotemporal dynamics of forest degradation by selective logging and forest Fire in the Brazilian Amazon** (Tese de doutorado em Geografia). East Lansing: Michigan State University, 2007.
- MATRICARDI, E. A. T.; SKOLE, D. L.; PEDLOWSKI, M. A.; CHOMENTOWSKI, W. Assessment of forest disturbances by selective logging and forest fires in the Brazilian Amazon using Landsat data. **International Journal of Remote Sensing**, v. 34, p. 1057–1086, 2013.
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784–2817, 2018.
- MELO, V. V. **Técnicas de aumento de eficiência para metaheurísticas aplicadas a otimização global contínua e discreta** (Tese de doutorado em Ciências de Computação e Matemática Computacional). São Carlos: USP, 2009.
- MERMOZ, S.; LE TOAN, T.; VILLARD, L.; RÉJOU-MÉCHAIN, M.; SEIFERT-GRANZIN, J. Biomass assessment in the Cameroon savanna using ALOS PALSAR data. **Remote Sensing of Environment**, v. 155, p. 109–119, 2014.
- MERRY, F.; SOARES-FILHO, B.; NEPSTAD, D.; AMACHER, G.; RODRIGUES, H. Balancing conservation and economic sustainability: The future of the amazon timber industry. **Environmental Management**, v. 44, p. 395–407, 2009.
- MITCHARD, E. T. A.; SAATCHI, S. S.; WOODHOUSE, I. H.; NANGENDO, G.; RIBEIRO, N. S.; WILLIAMS, M.; RYAN, C. M.; LEWIS, S. L.; FELDPAUSCH, T. R.; MEIR, P. Using satellite radar backscatter to predict above-ground woody biomass: A consistent relationship across four different African landscapes. **Geophysical Research Letters**, v. 36, L23401, 2009.
- MITCHARD, E. T. A.; SAATCHI, S. S.; LEWIS, S. L.; FELDPAUSCH, T. R.; WOODHOUSE, I. H.; SONKÉ, B.; ROWLAND, C.; MEIR, P. Measuring biomass changes

due to woody encroachment and deforestation/degradation in a forest-savanna boundary region of central Africa using multi-temporal L-band radar backscatter. **Remote Sensing of Environment**, v. 115, n. 11, p. 2861–2873, 2011.

MITCHELL, A. L.; ROSENQVIST, A.; MORA, B. Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+. **Carbon Balance and Management**, v. 12, 9, 2017.

MITCHELL, T.; COHEN, W.; HRUSCHKA, E.; TALUKDAR, P.; BETTERIDGE, J.; CARLSON, A.; DALVI, B.; GARDNER, M.; KISIEL., B.; KRISHNAMURTHY, J.; LAO, N.; MAZAITIS, K.; MOHAMED, T.; NAKASHOLE, N.; PLATANIOS, E.; RITTER, A.; SAMADI, M.; SETTLES, B.; WANG, R.; WIJAYA, D.; GUPTA, A.; CHEN, X.; SAPAROV, A.; GREAVES, M.; WELLING, J. Never-Ending Learning. **Proceedings of the National Conference on Artificial Intelligence**, v. 3, p. 2302–2310, 2015.

MURA, J. C. **Geocodificação automática de imagens de radar de abertura sintética interferométrico: sistema Geo-InSAR** (Tese de doutorado em Computação Aplicada). São José dos Campos: INPE, 2000.

NEPSTAD, D. C.; VERÍSSIMO, A.; ALENCAR, A.; NOBRE, C.; LIMA, E.; LEFEBVRE, P.; SCHLESINGER, P.; POTTER, C.; MOUTINHO, P.; MENDOZA, E.; COCHRANE, M.; BROOKS, V. Large-scale impoverishment of Amazonian forests by logging and fire. **Nature**, n. 398, p. 505–508, 1999.

NICHOL, K. 2016. **Painter by Numbers. Does Every Painter Leave a Fingerprint?** Disponível em: <<https://www.kaggle.com/c/painter-by-numbers>>. Acesso em: 8 jun. 2021.

NIELSEN, M. A. **Neural Networks and Deep Learning**. Determination Press, 2015, 224 p.

NOVO, E. M. L. M. **Sensoriamento Remoto. Princípios e Aplicações**. 3ª, São Paulo: Blucher, 2008, 388 p.

NOWAKOWSKI, A. Remote Sensing Data Binary Classification Using Boosting with Simple Classifiers. **Acta Geophysica**, v. 63, n. 5, p. 1447–1462, 2015.

OLANDER, L. P.; GIBBS, H. K.; STEININGER, M.; SWENSON, J. J.; MURRAY, B. C. Reference scenarios for deforestation and forest degradation in support of REDD: A review of data and methods. **Environmental Research Letters**, v. 3, n. 2, 025011, 2008.

OLDEMAN, R. A. A. **Tropical Forests: Botanical Dynamics, Speciation and Diversity**. Cornwall: Academic Press, 1989.

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, n. 5, p. 1633–1644, 2007.

PICKERING, J.; STEHMAN, S. V.; TYUKAVINA, A.; POTAPOV, P.; WATT, P.; JANTZ, S. M.; BHOLANATH, P.; HANSEN, M. C. Quantifying the trade-off between cost and precision in estimating area of forest loss and degradation using probability sampling in Guyana. **Remote Sensing of Environment**, v. 221, p. 122–135, 2019.

PINHEIRO, T. F. **Padrões e trajetórias de degradação florestal em fronteiras madeireiras da Amazônia** (Tese de doutorado em Ciência do Sistema Terrestre). São José dos Campos: INPE, 2015.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da**

vegetação. 2a. ed. São Paulo: Oficina de Textos, 2012.

PULLIAINEN, J.; ENGBAHL, M.; HALLIKAINEN, M. Feasibility of multi-temporal interferometric SAR data for stand-level estimation of boreal forest stem volume. **Remote Sensing of Environment**, v. 85, n. 4, p. 397–409, 2003.

QGIS PROJECT. **QGIS User Guide**, 2016.

QIN, Y.; XIAO, X.; WIGNERON, J. P.; CIAIS, P.; BRANDT, M.; FAN, L.; LI, X.; CROWELL, S.; WU, X.; DOUGHTY, R.; ZHANG, Y.; LIU, F.; SITCH, S.; MOORE, B. Carbon loss from forest degradation exceeds that from deforestation in the Brazilian Amazon. **Nature Climate Change**, v. 11, n. 5, p. 442–448, 2021. Disponível em: <<http://dx.doi.org/10.1038/s41558-021-01026-5>>.

QUIN, G.; PINEL-PUYSSÉGUR, B.; NICOLAS, J. M.; LOREAUX, P. MIMOSA: An automatic change detection method for sar time series. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 9, p. 5349–5363, 2014.

REAGAN, D. P.; WAIDE, R. B. **The Food Web of a Tropical Rain Forest**. Chicago: University Chicago Press, 1996.

REICHE, J.; SOUZA, C. M.; HOEKMAN, D. H.; VERBESSELT, J.; PERSAUD, H.; HEROLD, M. Feature level fusion of multi-temporal ALOS PALSAR and Landsat data for mapping and monitoring of tropical deforestation and forest degradation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 5, p. 2159–217, 2013.

REICHE, J.; HAMUNYELA, E.; VERBESSELT, J.; HOEKMAN, D.; HEROLD, M. Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. **Remote Sensing of Environment**, v. 204, p. 147–161, 2018.

RENÓ, V. F.; NOVO, E.M. L. M.; SUEMITSU, C.; RENNÓ, C. D. Assessment of deforestation in the Lower Amazon floodplain using historical Landsat MSS/TM imagery. **Remote Sensing of Environment**, v. 115, n. 12, p. 3446–3456, 2011.

REZENDE, S. O. **Sistemas Inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005.

RICHARDS, J. A. **Remote Sensing With Imaging Radar**. [s.l.] Springer, 2009.

ROMSHOO, S. A.; SHIMADA, M. Employing SAR for biomass retrieval from tropical forests of Southeast Asia. In: ASIAN CONFERENCE ON REMOTE SENSING (ACRS 2001), 22., Singapore. **Anais...** Singapura: The Centre, 2001.

ROSENBLATT, M. Remarks on Some Nonparametric Estimates of a Density Function. **The Annals of Mathematical Statistics**. 27 (3): 832–837, 1956.

RYAN, C. M.; HILL, T. C.; WOOLLEN, E.; GHEE, C. Quantifying small-scale deforestation and forest degradation in African woodlands using radar imagery. **Global Change Biology**, v. 18, n. 1, p. 243–257, 2012.

SAATCHI, S.; MARLIER, M.; CHAZDON, R. L.; CLARK, D. B.; RUSSELL, A. E. Impact of spatial variability of tropical forest structure on radar estimation of aboveground biomass. **Remote Sensing of Environment**, v. 115, n. 11, p. 2836–2849, 2011.

SANTORO, M.; FRANSSON, J. E. W.; ERIKSSON, L. E. B.; MAGNUSSON, M. Signatures

of ALOS PALSAR L-band backscatter in Swedish forest. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 12, p. 4001–4019, 2009.

SANTOS, J. R.; FREITAS, C. C.; ARAÚJO, L. S.; DUTRA, L. V.; MURA, J. C.; GAMA, F. F.; SOLER, L. S.; SANT'ANNA, S. J. S. Airborne P-band SAR applied to the aboveground biomass studies in the Brazilian tropical rainforest. **Remote Sensing of Environment**, v. 87, n. 4, p. 482–493, 2003.

SANTOS, J. R.; ARAÚJO, L. S.; KUPLICH, T. M.; FREITAS, C. C.; DUTRA, L. V.; SANT'ANNA, S. J. S.; GAMA, F. F. Tropical forest biomass and its relationship with P-band SAR. **Revista brasileira de Cartografia**, v. 58, n. 1, p. 37–42, 2006.

SCHLUND, M.; VON PONCET, F.; KUNTZ, S.; SCHMULLIUS, C.; HOEKMAN, D. H. TanDEM-X data for aboveground biomass retrieval in a tropical peat swamp forest. **Remote Sensing of Environment**, v. 158, p. 255–266, 2015.

SEEG. Sistema de Estimativa de Emissões de Gases de Efeito Estufa. **Total emissions**. Disponível em: <http://plataforma.seeg.eco.br/total_emission#>. Acesso em: 17 jun. 2021.

SEO, D. K.; KIM, Y. H.; EO, Y. D.; LEE, M. H.; PARK, W. Y. Fusion of SAR and multispectral images using random forest regression for change detection. **ISPRS International Journal of Geo-Information**, v. 7, n. 10, 401, 2018.

SFB. Serviço Florestal Brasileiro. **Floresta Nacional do Jamari (RO)**. Disponível em: <<http://www.florestal.gov.br/florestas-sob-concessao/92-concessoes-florestais/florestas-sob-concessao/101-floresta-nacional-do-jamari-ro>>. Acesso em: 21 jun. 2021, 2021a.

SFB. Serviço Florestal Brasileiro. **Monitoramento das concessões florestais**. Disponível em: <<https://www.florestal.gov.br/monitoramento>>. Acesso em: 21 jun. 2021b.

SHI, J.; LIU, X.; LEI, Y. SAR images change detection based on self-adaptive network architecture. **IEEE Geoscience and Remote Sensing Letters**, v. 18, p. 1204–1208, 2020a.

SHI, W.; ZHANG, M.; ZHANG, R.; CHEN, S.; ZHAN, A. Change detection based on artificial intelligence: State-of-the-art and challenges. **Remote Sensing**, v. 12, n. 10, 1688, 2020b.

SHI, Z.; FUNG, K. B. Comparison of digital speckle filters. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'94), Pasadena, CA. **Anais... IEEE**, 1994.

SHIMADA, M.; ITOH, T.; MOTOOKA, T.; WATANABE, M.; SHIRAISHI, T.; THAPA, R.; LUCAS, R. New global forest/non-forest maps from ALOS PALSAR data (2007-2010). **Remote Sensing of Environment**, v. 155, p. 13–31, 2014.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: 3rd INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS (ICLR 2015), San Diego, CA. **Anais... 2015**, 14 p.

SIMPSON, P. K. **Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations**. 1^a ed., Nova York: MacGraw-Hill, 1990, 209 p.

SKOLE, D.; TUCKER, C. Tropical deforestation and habitat fragmentation in the Amazon: Satellite data from 1978 to 1988. **Science**, v. 260, n. 5116, p. 1905–1910, 1993.

STONE, M. Cross-validators Choice and Assessment of Statistical Predictions. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 36, n. 2, p. 111–133, 1974.

SUN, G.; SIMONETT, D. S.; STRAHLER, A. H. A radar backscatter model for discontinuous coniferous forests. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 4, p. 639–650, 1991.

SZEGEDY, C.; VANHOUCHE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. In: 2016 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, Las Vegas, NE. **Anais...** IEEE Computer Society, v. 1, p. 2818–2826, 2016.

TANASE, M. A.; VILLARD, L.; PITAR, D.; APOSTOL, B.; PETRILA, M.; CHIVULESCU, S.; LECA, S.; BORLAF-MENA, I.; PASCU, I. S.; DOBRE, A. C.; PITAR, D.; GUIMAN, G.; LORENT, A.; ANGHELUS, C.; CICEU, A.; NEDEA, G.; STANCULEANU, R.; POPESCU, F.; APONTE, C.; BADEA, O. Synthetic aperture radar sensitivity to forest changes: A simulations-based study for the Romanian forests. **Science of the Total Environment**, v. 689, p. 1104–1114, 2019.

TOPOUZELIS, K.; PSYLLOS, A. Oil spill feature selection and classification using decision tree forest on SAR image data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 68, p. 135–143, 2012.

TOUZI, R.; LOPES, A.; BOUSQUET, P. A Statistical and Geometrical Edge Detector for SAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 26, n. 6, p. 764–773, 1988.

TREUHAF, R.; GONÇALVES, F.; SANTOS, J. R.; KELLER, M.; PALACE, M.; MADSEN, S. N.; SULLIVAN, F.; GRAÇA, P. M. L. A. Tropical-forest biomass estimation at X-band from the spaceborne TanDEM-X interferometer. **IEEE Geoscience and Remote Sensing Letters**, v. 12, p. 239–243, 2015.

TREUHAF, R.; LEI, Y.; GONÇALVES, F.; KELLER, M.; SANTOS, J. R.; NEUMANN, M.; ALMEIDA, A. Tropical-forest structure and biomass dynamics from TanDEM-X radar interferometry. **Forests**, v. 8, 277, 2017.

UHL, C.; BARRETO, P.; VERÍSSIMO, A.; VIDAL, E. Natural resource management in the Brazilian Amazon. **BioScience**, v. 47, n. 3, p. 160–168, 1997.

VALIANT, L. G. A theory of the learnable. **Communications of the ACM**, v. 27, n. 11, p. 1134–1142, 1984.

VAN DER SANDEN, J. J. **Radar Remote Sensing to Support Tropical Forest Management**. Tropenbos-Guyana Series 5, Georgetown: Tropenbos-Guyana Programme, 1997, 332 p.

VAN LAARHOVEN, P. J. M.; AARTS, E. H. L. Simulated annealing. In: VAN LAARHOVE, P. J. M.; AARTS, E. H. L. (eds.), **Simulated Annealing: Theory and Applications**. Mathematics and Its Applications, v. 37, p. 7–15. Dordrecht: Springer. 1987.

VERISSIMO, A.; BARRETO, P.; MATTOS, M. M.; TARIFA, R.; UHL, C. Logging impacts and prospects for sustainable forest management in an old Amazonian frontier: The case of Paragominas. **Forest Ecology and Management**, v. 55, n. 1–4, p. 169–199, 1992.

VERÍSSIMO, A.; BARRETO, P.; TARIFA, R.; UHL, C. Extraction of a high-value natural

resource in Amazonia: the case of mahogany. **Forest Ecology and Management**, v. 72, n. 1, p. 39–60, 1995.

VILLARD, L.; BORDERIES, P. Backscattering border effects for forests at C-band. **PIERS Online**, v. 3, n. 5, p. 731–735, 2007.

WALKER, W. S.; STICKLER, C. M.; KELLNDORFER, J. M.; KIRSCH, K. M.; NEPSTAD, D. C. Large-area classification and mapping of forest and land cover in the Brazilian Amazon: A comparative analysis of ALOS/PALSAR and Landsat data sources. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 3, p. 594–604, 2010.

WANG, X.; LIU, S.; DU, P.; LIANG, H.; XIA, J.; LI, Y. Object-based change detection in urban areas from high spatial resolution images based on multiple features and ensemble learning. **Remote Sensing**, v. 10, n. 276, p. 1–14, 2018.

WANG, Z.; ZHANG, J.; VERMA, N. Realizing Low-Energy Classification Systems by Implementing Matrix Multiplication Directly Within an ADC. **IEEE Transactions on Biomedical Circuits and Systems**, v. 9, n. 6, p. 825–837, 2015.

WATANABE, M.; SHIMADA, M.; ROSENQVIST, A.; TADONO, T. Forest structure dependency of the relation between L-band and biophysical parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 11, p. 3154–3165, 2006.

WHITTLE, M.; QUEGAN, S.; URYU, Y.; STÜEWE, M.; YULIANTO, K. Detection of tropical deforestation using ALOS-PALSAR: A Sumatran case study. **Remote Sensing of Environment**, v. 124, p. 83–98, 2012.

WIDROW, B.; LEHR, M. A. 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation. **Proceedings of the IEEE**, v. 78, n. 9, p. 1415–1442, 1990.

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. 1^a ed., Boca Raton: CRC Press, 2006a.

WOODHOUSE, I. H. Predicting backscatter-biomass and height-biomass trends using a macroecology model. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 4, p. 871–877, 2006b.

WU, C.; ZHANG, L.; DU, B. Kernel Slow Feature Analysis for Scene Change Detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, p. 2367–2384, 2017.

WULDER, M. A.; FRANKLIN, S. E. **Remote Sensing of Forest Environments: Concepts and Case Studies**. 1^a ed., Nova York: Springer, 2003.

YU, Y.; LI, M.; FU, Y. Forest type identification by Random Forest classification combined with SPOT and multitemporal SAR data. **Journal of Forestry Research**, v. 29, n. 5, p. 1407–1414, 2018.

ZHAN, Y.; FU, K.; YAN, M.; SUN, X.; WANG, H.; QIU, X. Change Detection Based on Deep Siamese Convolutional Network for Optical Aerial Images. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 10, p. 1845–1849, 2017.

ZHANG, C.; MA, Y. **Ensemble machine learning: Methods and applications**. 1. ed. Boston, MA: Springer, 2012.

ZHANG, F.; WANG, Y.; NI, J.; ZHOU, Y.; HU, W. SAR Target Small Sample Recognition

Based on CNN Cascaded Features and AdaBoost Rotation Forest. **IEEE Geoscience and Remote Sensing Letters**, v. 17, n. 6, p. 1008–1012, 2020.

ZHANG, P.; GONG, M.; SU, L.; LIU, J.; LI, Z. Change detection based on deep feature representation and mapping transformation for multi-spatial-resolution remote sensing images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 24–41, 2016.

ZHAO, X.; JIANG, Y.; STATHAKI, T. Automatic target recognition strategy for synthetic aperture radar images based on combined discrimination trees. **Computational Intelligence and Neuroscience**, v. 2017, 7186120, 19 p.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G. S.; ZHANG, L.; XU, F.; FRAUNDORFER, F. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. **IEEE Geoscience and Remote Sensing Magazine**, v. 5, n. 4, p. 8–36, 2017.

ZHUANG, H.; TAN, Z.; DENG, K.; FAN, H. It is a misunderstanding that log ratio outperforms ratio in change detection of SAR images. **European Journal of Remote Sensing**, v. 52, n. 1, p. 484–492, 2019.

7. ANEXOS

7.1 Lista das espécies comerciais da FLONA do Jamari¹¹

AMATA S.A.
Rua Funchal, 263 – 17º andar – sala 172
Vila Olímpia – São Paulo – SP – CEP 04551-060
Fone: (11) 3054-3557 / Fax: (11) 3054-3550
www.amatabrasil.com.br



Tabela 11: Volume e número de árvores por espécie a serem exploradas na UPA 03

Nome Vulgar	Nome Científico	Volume UPA (m³)	Nº Árvores UPA	Volume (m³/ha)	Nº Árvores (nº/ha)
Angelim	Hymenolobium modestum Ducke	74,288	11	0,045	0,007
Angelim-amargoso	Vataireopsis sp.	109,949	22	0,067	0,013
Angelim-pedra	Hymenolobium heterocarpum Ducke	778,338	87	0,477	0,053
Angelim-rajado	Vatairea guianensis Aubl.	1.014,176	195	0,621	0,119
Arurá-vermelho	Iryanthera paradoxa (Schwacke) Warb.	974,356	205	0,597	0,126
Cambará-rosa	Qualea paraensis Ducke	125,138	21	0,077	0,013
Caroba	Jacaranda copaia (Aubl.) D.Don	45,653	11	0,028	0,007
Cedrilho	Erismia fuscum Ducke	321,629	58	0,197	0,036
Cedromara	Cedrelinga cateniformis (Ducke) Ducke	1.065,382	67	0,652	0,041
Cedro-rosa	Cedrela fissilis Vell.	335,990	47	0,206	0,029
Cinzeiro	Erismia bicolor Ducke	258,623	37	0,158	0,023
Cumarú	Dipteryx odorata (Aubl.) Willd.	815,414	141	0,499	0,086
Cumarurana	Dipteryx alata Vogel	632,505	109	0,387	0,067
Cupiúba	Goupia glabra Aubl.	510,020	56	0,312	0,034
Embireira	Couratari stellata A. C. Sm.	3.810,598	348	2,333	0,213
Faveira-ferro	Dinizia excelsa Ducke	3.152,314	152	1,930	0,093
Freijó	Cordia goeldiana Huber	505,493	97	0,310	0,059
Garapeira	Apuleia leiocarpa (Vogel) J.F.Macbr.	2.654,526	273	1,625	0,167
Garrote	Bagassa guianensis Aubl.	910,327	106	0,557	0,065
Guariúba	Clarisia racemosa Ruiz & Pav.	518,375	121	0,317	0,074
Ipê-amarelo	Handroanthus incanus (A.H. Gentry) S. O. Grose	528,181	83	0,323	0,051
Ipê-roxo	Tabebuia sp.	135,420	13	0,083	0,008
Jatobazinho	Hymenaea intermedia Ducke	494,107	100	0,303	0,061
Jequitibá	Allantoma decandra (Ducke)	657,941	79	0,403	0,048
Maçaranduba	Manilkara huberi (Ducke) A. Chev.	25,621	4	0,016	0,002
Muiracatiara	Astronium lecontei Ducke	4.388,670	559	2,687	0,342
Paricá	Schizolobium parahyba (Vell.) Blake var. amazonicum (Huber ex Ducke) Barneby	182,363	31	0,112	0,019
Pequi	Caryocar villosum (Aubl.) Pers.	343,001	29	0,210	0,018
Pequiarana	Caryocar glabrum Pers.	445,284	64	0,273	0,039
Peroba-rosa	Aspidosperma sandwithianum Markgr.	58,121	10	0,036	0,006
Roxão	Peltogyne sp.	222,868	42	0,136	0,026
Roxinho	Peltogyne paniculata Benth.	2.360,012	579	1,445	0,355
Sucupira-amarela	Bowdichia nitida Spruce ex Benth.	177,173	36	0,108	0,022
Sucupira-preta	Diploptropis rodriguesii H.C. Lima	84,374	20	0,052	0,012
Tamarindo	Martiodendron elatum (Ducke) Gleason	446,426	77	0,273	0,047
Tamboril	Hymenolobium cf. modestum Ducke	232,012	19	0,142	0,012
Tauari-vermelho	Cariniana micrantha Ducke	4.380,308	258	2,682	0,158
Total Geral		33.774,973	4.167	20,682	2,552

11

<https://www.florestal.gov.br/documentos/concessoes-florestais/concessoes-florestais-florestas-sob-concessao/flona-do-jamari/producao-2/amata/execucao-tecnica-2/170-poa-03-amata-umf-3-2012-jamari/file>

7.2 Artigos Publicados

This article has been accepted for inclusion in a future issue of this journal. Content is final as presented, with the exception of pagination.

IEEE GEOSCIENCE AND REMOTE SENSING LETTERS

1

Performance of Speckle Filters for COSMO-SkyMed Images From the Brazilian Amazon

Tahisa N. Kuck¹, Luis D. Gomez², *Senior Member, IEEE*, Edson E. Sano³, Polyanna da C. Bispo, and Douglas D. C. Honório⁴

Abstract—Speckle filtering is an important step for target detection in SAR images since this effect makes it difficult or even impossible to extract information from these images. There are several filters available in the literature although evaluating their performances is not a trivial task since it requires comparing the filtered images with a speckle-free image, which is generally unknown. This evaluation is even more complex when the features in the images are heterogeneous, for example, from tropical forests. The objective of this study is to evaluate the performance of the Lee, deGrandi, GammaMAP, single Anisotropic Nonlinear Diffusion (ANLD), multitemporal ANLD, Fast Adaptive Nonlocal SAR (FANS), and Fast GPU-Based Enhanced Wiener filters to reduce the speckle present in the COSMO-SkyMed Stripmap X-band images from the Brazilian Amazon forest region. The evaluation was conducted qualitatively through the visual inspection of the ratio image and the edge detection in the ratio images and quantitatively through the $\alpha\beta$ estimator and other statistical parameters of the filtered images. The GammaMAP filter showed the best performances, both qualitatively and quantitatively, and the FANS filter only qualitative.

Index Terms—SAR images, speckle filtering, tropical forest, X-band.

I. INTRODUCTION

DUE to the coherent nature of the imaging systems that operate in the microwave electromagnetic range, the radar images present speckle effects, which are the result of interference between echoes from individual backscatters within a resolution cell [1]. The pattern of the speckle effect is random and generally considered as noise although it is a deterministic and reproducible phenomenon.

One important aspect of the speckle effect is that it varies over homogeneous targets. As radar resolution cell contains

a random collection of backscattered signals, each from a slightly different location of the instrument (and, consequently, a different phase) and each one with a slightly different radar cross section (signal amplitude), we can model the return signal as the coherent addition of all individual signals [1].

Two techniques commonly used to reduce the speckle effect are multilook processing and postprocessing filters. The disadvantage of multilook processing is the reduction of information related to texture, equivalent to a low-pass filter [2]. Postprocessing techniques rely on applying despeckling filters. Among them, adaptive filters [3]–[5] are specially designed to reduce speckle while preserving the textural information of the images. Such filter is diverse and widely compared through different methodologies that seek to evaluate, in most cases, the signal-to-noise ratio of the filtered image [2], [6].

In fact, evaluating the quality of a particular filter is not a trivial task, mainly because the noise-free backscatter values to be estimated are generally unknown. Another important issue is the relationship between the quality and fidelity of the filtered images. The quality of the filters is generally evaluated in terms of undesired “blurring” effects over homogeneous areas, preservation of details (targets, bright scatterers, edges, and man-made structures), and the relative backscattering values [7].

One approach to evaluate the quality of a filter is the visual inspection of the filtered image by an expert, which allows the detection of elements perceptible to human eyes, such as edge preservation and backscatter homogeneity. However, such an approach does not allow quantitative assessments of the effects of filtering on the backscatter values. Several methodologies were developed to overcome this limitation. Indexes with reference depend on the availability of a reference image, free of speckle (usually not available). Note that speckle-free images synthetically generated can differ substantially from the ground truth in terms of their statistical properties [7]. Indexes without reference are based solely on statistical hypotheses of the modeled signal. In this case, as the signal model depends on the degree of heterogeneity of the scene, supervised sampling of more appropriate areas for the calculation of a specific index, such as homogeneous regions, such as water bodies, for example, maybe required [7]. The equivalent number of looks (ENLs) is an index commonly used to assessing the smoothness of a filtered image when no ground truth is available. Large ENL values relate to large speckle reduction and also to large image smoothing [8].

Manuscript received October 22, 2020; revised December 23, 2020 and January 20, 2021; accepted February 1, 2021. (Corresponding author: Tahisa N. Kuck.)

Tahisa N. Kuck and Douglas D. C. Honório are with the Institute for Advanced Studies (IEAv), São José dos Campos 12228-001, Brazil (e-mail: tahisakuck@yahoo.com.br; honoriodch@iah.mil.br).

Luis D. Gomez is with the Department of Electronic Engineering and Automatic (DIEA), University of Las Palmas de Gran Canaria, 35017 Las Palmas de Gran Canaria, Spain (e-mail: luis.gomez@ulpgc.es).

Edson E. Sano is with Embrapa Cerrados, Brasília 73310-970, Brazil (e-mail: edson.sano@embrapa.br).

Polyanna da C. Bispo is with the Department of Geography, School of Environment, Education and Development, University of Manchester, Manchester M13 9PL, U.K. (e-mail: polyanna.bispo@manchester.ac.uk).

Color versions of one or more figures in this letter are available at <https://doi.org/10.1109/LGRS.2021.3057263>.

Digital Object Identifier 10.1109/LGRS.2021.3057263

1545-598X © 2021 IEEE. Personal use is permitted, but republication/redistribution requires IEEE permission. See <https://www.ieee.org/publications/rights/index.html> for more information.

Article

A Comparative Assessment of Machine-Learning Techniques for Forest Degradation Caused by Selective Logging in an Amazon Region Using Multitemporal X-Band SAR Images

Tahisa Neitzel Kuck ^{1,2,*}, Edson Eyji Sano ^{2,3}, Polyanna da Conceição Bispo ⁴, Elcio Hideiti Shiguemori ¹, Paulo Fernando Ferreira Silva Filho ¹ and Eraldo Aparecido Trondoli Matricardi ⁵

¹ Command, Control, Communications, Computers, Intelligence, Surveillance and Reconnaissance Division, Institute for Advanced Studies (IEAv), São José dos Campos 12228-001, Brazil; elcio@ieav.cta.br (E.H.S.); silvafilho@ieav.cta.br (P.F.F.S.F.)

² Geoscience Institute, Universidade de Brasília (UnB), Brasília 70910-900, Brazil; edson.sano@embrapa.br

³ Embrapa Cerrados, Planaltina 73310-970, Brazil

⁴ Department of Geography, School of Environment, Education and Development, University of Manchester, Manchester M13 9PL, UK; polyanna.bispo@manchester.ac.uk

⁵ Forestry Department, Universidade de Brasília (UnB), Brasília 70919-970, Brazil; ematricardi@unb.br

* Correspondence: tahisa@ieav.cta.br



Citation: Kuck, T.N.; Sano, E.E.; Bispo, P.F.C.; Shiguemori, E.H.; Silva Filho, P.F.F.; Matricardi, E.A.T. A Comparative Assessment of Machine-Learning Techniques for Forest Degradation Caused by Selective Logging in an Amazon Region Using Multitemporal X-Band SAR Images. *Remote Sens.* **2021**, *13*, 3341. <https://doi.org/10.3390/rs13173341>

Academic Editors: Enrico Borgogno Mondino and Klaus Scipal

Received: 12 July 2021

Accepted: 19 August 2021

Published: 24 August 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: The near-real-time detection of selective logging in tropical forests is essential to support actions for reducing CO₂ emissions and for monitoring timber extraction from forest concessions in tropical regions. Current operating systems rely on optical data that are constrained by persistent cloud-cover conditions in tropical regions. Synthetic aperture radar data represent an alternative to this technical constraint. This study aimed to evaluate the performance of three machine learning algorithms applied to multitemporal pairs of COSMO-SkyMed images to detect timber exploitation in a forest concession located in the Jamari National Forest, Rondônia State, Brazilian Amazon. The studied algorithms included random forest (RF), AdaBoost (AB), and multilayer perceptron artificial neural network (MLP-ANN). The geographical coordinates (latitude and longitude) of logged trees and the LiDAR point clouds before and after selective logging were used as ground truths. The best results were obtained when the MLP-ANN was applied with 50 neurons in the hidden layer, using the ReLu activation function and SGD weight optimizer, presenting 88% accuracy both for the pair of images used for training (images acquired in June and October) of the network and in the generalization test, applied on a second dataset (images acquired in January and June). This study showed that X-band SAR images processed by applying machine learning techniques can be accurately used for detecting selective logging activities in the Brazilian Amazon.

Keywords: synthetic aperture radar; machine learning; random forest; AdaBoost; multilayer perceptron

1. Introduction

Anthropogenic activities are responsible for the current global temperature increase of about 1.0 °C and for an expected increase of 1.5 °C sometime between 2030 and 2052. Potential impacts and risks associated with increasing temperature include elevation of the sea level, higher frequency and intensity of extreme temperatures, storms, and droughts, loss of biodiversity, reduction in oxygen concentration in the oceans, and shortage of food production [1]. A reduction in anthropogenic CO₂ emissions is mandatory to control the global rise in temperature. Deforestation and forest degradation are the second largest anthropogenic sources of CO₂ emissions into the atmosphere, since they are related to the combustion of forest biomass, as well as to the decomposition of remaining plant materials. Approximately 65% of Brazilian CO₂ emissions in 2019 came from deforestation and forest degradation [2]. According to Qin et al. [3], forest degradation contributes three times more to the aboveground gross biomass loss than deforestation in the Brazilian Amazon. This is

Article

Change Detection of Selective Logging in the Brazilian Amazon Using X-Band SAR Data and Pre-Trained Convolutional Neural Networks

Tahisa Neitzel Kuck ^{1,2}, Paulo Fernando Ferreira Silva Filho ¹, Edson Eyji Sano ^{2,3}, Polyanna da Conceição Bispo ^{4,*}, Elcio Hideiti Shiguemori ¹ and Ricardo Dalagnol ^{4,5}

¹ Command, Control, Communications, Computers, Intelligence, Surveillance and Reconnaissance Division, Institute for Advanced Studies (IEAv), São José dos Campos 12228-001, Brazil; tahisa@ieav.cta.br (T.N.K.); elcio@ieav.cta.br (E.H.S.); silvafilho@ieav.cta.br (P.F.F.S.F.)

² Geoscience Institute, Universidade de Brasília (UnB), Brasília 70910-900, Brazil; edson.sano@embrapa.br (E.E.S.)

³ Embrapa Cerrados, Planaltina 73310-970, Brazil

⁴ Department of Geography, School of Environment, Education and Development, University of Manchester, Manchester M13 9PL, UK; polyanna.bispo@manchester.ac.uk (P.C.B.); ricds@hotmail.com (R.D.)

⁵ Earth Observation and Geoinformatics Division, National Institute for Space Research-INPE, São José dos Campos, SP, Brazil;

* Correspondence: polyanna.bispo@manchester.ac.uk

Citation: Kuck, T.N.; Silva Filho, P.F.F.; Sano, E.E.; Bispo, P.C.; Shiguemori, E.H.; Dalagnol, R. Change Detection of Selective Logging in the Brazilian Amazon Using X-Band SAR Data and Pre-Trained Convolutional Neural Networks. *Remote Sens.* **2021**, *13*, x. doi:10.3390/xxxxx

Academic Editor: Firstname Last-name

Received: date

Accepted: date

Published: date

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright © 2021 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: It is estimated that, in the Brazilian Amazon, the forest degradation contributes three times more than the deforestation for the loss of gross above ground biomass. Degradation, in particular those caused by selective logging, result in features whose detection is a challenge to remote sensing, due to its size, space configuration and geographical distribution. From the available remote sensing technologies, SAR data allow monitoring even during adverse atmospheric conditions. The aim of this study was to test different pre-trained models of Convolutional Neural Networks (CNNs) for change detection associated to forest degradation in bitemporal products obtained from a pair of SAR COSMO-SkyMed images acquired before and after logging in the Jamari National Forest. This area contains areas of legal and illegal logging, and to test the influence of the speckle effect on the result of this classification by applying the classification methodology on previously filtered and unfiltered images, comparing the results. A method of cluster detections was also presented, which would make it possible, for example, to guide inspection actions and allow the calculation of the intensity of exploitation (IEX). Although the differences between the tested models were in the order of less than 5%, the tests on the RGB composition (where R=coefficient of variation; G=minimum values; and B=gradient) showed the best results, especially the embedder Painters (accuracy = 92%), even in the generalization tests, which presented an overall accuracy index of 87%, but also in the test on RGB from the unfiltered image pair (accuracy and precision of 90%). These results indicate that multitemporal X-band SAR data have potential for monitoring selective logging in tropical forests, especially in combination with CNN techniques.

Keywords: selective logging; synthetic aperture radar; convolutional neural networks

1. Introduction

Land use, land use changes and forests have historically been the sectors that most contribute to greenhouse gas emissions in Brazil, according to the Greenhouse Gas Emissions and Removal Estimates System – SEEG [1]. Therefore, the necessary containment of the increase in emissions is closely related to the control and combat of deforestation and