

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

Bruna Andriéli Simões de Oliveira

**IDENTIFICAÇÃO DE ÁREAS DE CLAREIRA NA FLORESTA
AMAZÔNICA POR MEIO DE DADOS LIDAR, IMAGENS DE MÉDIA
RESOLUÇÃO ESPACIAL E INTELIGÊNCIA ARTIFICIAL**

Santa Maria, RS
2020

Bruna Andriéli Simões de Oliveira

**IDENTIFICAÇÃO DE ÁREAS DE CLAREIRA NA FLORESTA AMAZÔNICA POR
MEIO DE DADOS LIDAR, IMAGENS DE MÉDIA RESOLUÇÃO ESPACIAL E
INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestre em Engenharia Florestal**.

Orientador: Prof. Dr. Rudiney Soares Pereira

Santa Maria, RS
2020

Oliveira, Bruna Andriéli Simões de
Identificação de clareiras na floresta Amazônica por
meio de dados LiDAR, imagens de média resolução espacial
e inteligência artificial / Bruna Andriéli Simões de
Oliveira.- 2020.
66 p.; 30 cm

Orientador: Rudiney Soares Pereira
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Florestal, RS, 2020

1. Floresta Amazônica 2. Sensoriamento Remoto 3.
Clareiras 4. Inteligência Artificial I. Pereira, Rudiney
Soares II. Título.

Bruna Andriéli Simões de Oliveira

**IDENTIFICAÇÃO DE ÁREAS DE CLAREIRA NA FLORESTA AMAZÔNICA POR
MEIO DE DADOS LIDAR, IMAGENS DE MÉDIA RESOLUÇÃO ESPACIAL E
INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada ao curso de Mestrado do Programa de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Mestra em Engenharia Florestal**.

Aprovada em 20 de fevereiro de 2020:



Rudiney Soares Pereira, Dr. (UFSM)
(Presidente/Orientador)



Emanuel Araújo Silva, Dr. (UFRPE)



Sílvia Margareti de Juli Morais Kurtz, Dr. (UFSM)

Santa Maria, RS
2020

DEDICATORIA

*Dedico esta, como todas as minhas demais conquistas, em memória ao meu amado pai,
Sandro de Oliveira.*

AGRADECIMENTOS

Agradeço a Deus por me dar força a ser persistente nos meus objetivos e por me guiar nos momentos de dificuldade.

À minha família, em especial as mulheres mais extraordinárias minha mãe Leandra e minhas avós, vó Marlene Chagas e vó Marlene Porto, por todo amor incondicional e dedicação de sempre. Pelo incentivo e apoio em todas minhas escolhas e por nunca medirem esforços para alcançar meus objetivos.

Aos meus amigos Amanda e Felipe, pelo apoio e compreensão. Por estarem presentes em todos os momentos da minha vida. A minha amiga Rossana, pelas palavras de apoio e amizade adquirida ao longo da graduação. Ao Pablo, pelo companheirismo, paciência e incentivo a sempre continuar.

Aos meus queridos colegas e amigos do Laboratório de Sensoriamento Remoto (LABSERE): Alessandra Marasciulo, Dionatas Hoeneff, Elisiane Alba, Fábio Batista, Helena Oliveira, Jose Augusto Spiazzi Favarin, Juliana Marchesan, Mateus Schuh, Matheus Frigo e Roberta Fantinel. Agradeço os anos de convívio e pelo apoio, todos contribuíram de alguma forma para a realização deste trabalho. Em especial a Elisiane e Juliana, pelo auxílio desde o meu primeiro dia no LABSERE, sou grata por aprender com mulheres tão fortes, dedicadas e especiais.

Ao meu orientador Prof. Rudiney pela oportunidade, apoio e aprendizado desde a graduação até o mestrado.

Ao Prof. Emanuel Araujo Silva e a Prof. Sivia Margareti de Juli Morais Kurtz por terem aceito fazer parte da banca examinadora do meu trabalho de mestrado.

À Universidade Federal de Santa Maria pela oportunidade de realizar uma graduação e pós-graduação. E ao Programa de Pós-Graduação em Engenharia Florestal possibilitar a concretização de um sonho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pela bolsa de estudo disponibilizada.

Enfim, agradeço a todos que de alguma forma contribuíram para a realização deste trabalho.

*"As soluções sempre aparecem quando saímos
do pensamento e ficamos em silêncio,
absolutamente presentes, ainda que seja só
por um instante".*

Eckhart Tolle

Resumo

IDENTIFICAÇÃO DE ÁREAS DE CLAREIRA NA FLORESTA AMAZÔNICA POR MEIO DE DADOS LIDAR, IMAGENS DE MÉDIA RESOLUÇÃO ESPACIAL E INTELIGÊNCIA ARTIFICIAL

AUTORA: Bruna Andriéli Simões de Oliveira

ORIENTADOR: Rudiney Soares Pereira

As florestas tropicais estão naturalmente submetidas a distúrbios, além de ocorrerem naturalmente podem ser decorrentes do aquecimento global, incêndios florestais e desmatamento. Dessa forma, é importante a realização desse estudo, uma vez que as práticas de extração seletiva nas florestas tropicais propiciam a abertura de clareiras no dossel florestal, as quais necessitam de estudos a fim de avaliar a dinâmica e regeneração desses espaços. Este estudo objetivou identificar a presença de clareiras por meio de imagens de média resolução espacial e sensor LiDAR, utilizando inteligência artificial em áreas de exploração seletiva da floresta no bioma Amazônia. A área de estudo localiza-se na Fazenda Cauaxi, município de Paragominas-PA, na qual é desempenhada a atividade de manejo florestal. Para a identificação das clareiras, utilizou-se imagem orbital do satélite Sentinel-2A, adquirida pelo sensor *Multi-Spectral Instrument* (MSI), no ano de 2017. Para a classificação de clareiras por meio da imagem de satélite foram utilizados os algoritmos *Random Forest* (RF), *Support Vectors Machine* (SVM) e *Artificial Neural Network* (ANN), a classificação supervisionada de imagem orbitais foi desenvolvida em Linguagem R. Além das imagens Sentinel-2A, o estudo englobou ainda a utilização de dados LiDAR para a detecção e análise da dinâmica das clareiras para os anos de 2014 e 2017, a fim permitir a comparação dos resultados obtidos por ambos os métodos. Para a detecção de clareiras com dados LiDAR, utilizou-se a versão 0.0.2 do pacote *ForestGapR*. Os resultados indicaram que para a classificação com imagem Sentinel-2A, todos os algoritmos apresentaram valores superiores a 0,90 de acurácia global e valores superiores a 0,88 de Kappa, ao verificar os algoritmos de aprendizado de máquina e seus respectivos ajustes, o RF foi o que apresentou os maiores valores, demonstrando uma acurácia no processo de classificação de 0,9938, apresentando como o melhor classificador para a identificação de clareiras em áreas de exploração seletiva na Amazônia. Já para a dinâmica das clareiras no dossel da floresta, utilizando dados LiDAR, para os anos de 2014 e 2017, aumentou 10.098,00 m² o número de clareiras em 3 anos e um aumento de 127.521,00 m² de área total. Em relação a comparação dos métodos, para imagem Sentinel-2A foi identificado 229.402,97 m² de clareiras, enquanto que com dados LiDAR foi detectado 301.090,00 m² de clareiras, uma diferença de 71.687,03 m² de clareiras entre os métodos. Ao relacionar os percentuais de clareiras identificadas com o uso de imagens MSI/Sentinel-2A aos detectados com dados LiDAR em condições similares, observou-se o potencial das imagens de média resolução, quando associadas a técnicas de inteligência artificial, na identificação de distúrbios na floresta. Assim, o uso de produtos Sentinel associados as técnicas de processamento complexas permitem a obtenção de parâmetros da cobertura florestal, inclusive para a região Amazônica. E por fim, esse estudo demonstra a importância da identificação e análise de clareiras, através das aplicações de sensoriamento remoto, para o monitoramento do desmatamento e retirada ilegal de madeira na floresta, possibilitando um manejo sustentável na Amazônia Brasileira.

Palavras-chave: Clareiras no dossel florestal. Amazônia. Inteligência Artificial. Sensoriamento Remoto.

Abstract

IDENTIFICATION OF GAP AREAS IN THE AMAZON FOREST THROUGH LIDAR DATA, MEDIUM SPACE RESOLUTION IMAGES AND ARTIFICIAL INTELLIGENCE

AUTHOR: Bruna Andriéli Simões de Oliveira
SUPERVISOR: Rudiney Soares Pereira

Tropical forests are naturally subject to disturbances, in addition to occurring naturally, they can be caused by global warming, forest fires and deforestation. Thus, it is important to conduct this study, since the practices of selective extraction in tropical forests provide the opening of gaps in the forest canopy, which need studies in order to assess the dynamics and regeneration of these spaces. This study aimed to identify the presence of gaps through medium spatial resolution images and LiDAR sensor, using artificial intelligence in areas of selective forest exploration in the Amazon biome. The study area is located at Fazenda Cauaxi, municipality of Paragominas-PA, in which the forest management activity is performed. To identify the clearings, an orbital image from the Sentinel-2A satellite was used, acquired by the Multi-Spectral Instrument (MSI) sensor, in 2017. For classification of clearings by means of the satellite image, the algorithms were used Random Forest (RF), Support Vectors Machine (SVM) e Artificial Neural Network (ANN), the supervised classification of orbital images was developed in Language R. In addition to the Sentinel-2A images, the study also included the use of LiDAR data to detect and analyze the dynamics of the clearings for the years 2014 and 2017, in order to allow the comparison of the results obtained by both methods. For the detection of gaps with LiDAR data, version 0.0.2 of the ForestGapR package was used. The results indicated that for the classification with Sentinel-2A image, all the algorithms presented values above 0.90 of global accuracy and values above 0.88 of Kappa, when verifying the machine learning algorithms and their respective adjustments, the RF was the one with the highest values, demonstrating an accuracy in the classification process of 0.9938, presenting as the best classifier for the identification of clearings in areas of selective exploration in the Amazon. For the dynamics of gaps in the forest canopy, using LiDAR data, for the years 2014 and 2017, the number of clearings increased by 10,098.00 in 3 years and an increase of 127,521.00 m² of total area. Regarding the comparison of methods, for Sentinel-2A image 229,402.97 m² of gaps were identified, while with LiDAR data 301,090.00 m² of gaps were detected, a difference of 71,687.03 m² of gaps between the methods. When relating the percentage of gaps identified with the use of MSI/Sentinel-2A images to those detected with LiDAR data under similar conditions, the potential of medium resolution images, when associated with artificial intelligence techniques, in the identification of disorders in the forest. Thus, the use of Sentinel products associated with complex processing techniques allows obtaining parameters of forest cover, including for the Amazon region. Finally, this study demonstrates the importance of identifying and analyzing clearings, through remote sensing applications, for monitoring deforestation and illegal logging in the forest, enabling sustainable management in the Brazilian Amazon.

Keywords: Gaps in the forest canopy. Amazon. Artificial intelligence. Remote sensing.

LISTA DE FIGURAS

Figura 1 – Aquisição de dados e componentes da varredura <i>LASER</i> aerotransportada.....	21
Figura 2 – Localização da área de estudo na Fazenda Cauaxi, Paragominas – PA.....	27
Figura 3 – Fluxograma de produtos e análises derivados da detecção das lacunas no dossel da floresta, usando o pacote <i>ForestGapR</i>	34
Figura 4 – Teste estatístico de Nemenyi para os algoritmos de aprendizado de máquina.	38
Figura 5 – Classificação das clareiras por meio do algoritmo RF, SVM e ANN com imagens Sentinel-2A.....	40
Figura 6 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2014.....	42
Figura 7 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2017.....	43
Figura 8 – Dinâmica das clareiras no dossel da floresta para os anos de 2014 e 2017.....	45
Figura 9 – Alterações das clareiras no dossel da floresta para os anos de 2014 e 2017.	46
Figura 10 – Distribuição de Frequência de tamanho de clareiras no dossel da floresta para o ano de 2014.....	47
Figura 11 – Distribuição de Frequência de tamanho de clareiras no dossel da floresta para o ano de 2017.....	47
Figura 12 – Identificação de clareiras com imagem Sentinel-2A por meio do algoritmo <i>Random Forest</i>	51
Figura 13 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2017, com área mínima de 100 m ²	52

LISTA DE TABELAS

Tabela 1 – Características das imagens Sentinel-2A.	20
Tabela 2 – Parâmetros utilizados em cada Algoritmos de aprendizado de máquina.	30
Tabela 3 – Especificações técnicas do voo dos anos 2014 e 2017 realizado na Fazenda Cauaxi, Paragominas, Pará.....	32
Tabela 4 – Lista de funções incluídas no pacote <i>ForestGapR</i> e suas características.	33
Tabela 5 – Resultados da classificação supervisionada das clareiras com os algoritmos RF, SVM e ANN.	36
Tabela 6 – Ranking dos algoritmos de aprendizado de máquina obtidos pela validação cruzada a partir de 30 repetições.	37
Tabela 7 – Quantificação das áreas de clareiras e floresta na Fazenda Cauaxi, para cada algoritmo utilizado, para área de 1200 ha cada.	40
Tabela 8 – Matriz de confusão para a classificação supervisionada com o uso do algoritmo RF.	41
Tabela 9 – Estatísticas de clareiras no dossel da floresta na Fazenda Cauaxi nos anos de 2014 e 2017 para uma área de 1200 ha cada.	44
Tabela 10 – Numero de clareiras e área (m ²) no dossel da floresta 2014.	48
Tabela 11 – Numero de clareiras e área (m ²) no dossel da floresta 2017.	49
Tabela 12 – Comparação entre imagem Sentinel-2A e dados LiDAR, na identificação de clareiras na Fazenda Cauaxi no ano de 2017 para uma área de 1200 ha cada.	50

LISTA DE ABREVIATURAS E SIGLAS

ALS	<i>Airbourne Laser Scanner</i>
ANN	<i>Artificial Neural Network</i>
CHM	<i>Canopy Heigh Model</i>
DAP	Diâmetro à Altura do Peito
DEM	<i>Digital Elevation Model</i>
DSM	<i>Digital Surface Model</i>
DTM	<i>Digital Terrain Model</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GNSS	<i>Global Navigation Satelite System</i>
LASER	<i>Light Amplification by Stimulated Emission of Radiation</i>
LiDAR	<i>Light Detection and Ranging</i>
MDT	Modelo Digital do Terreno
ML	<i>Machine Learning</i>
RF	<i>Random Forest</i>
SIG	Sistemas de Informações Georeferenciadas
SVM	<i>Support Vector Machine</i>
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 OBJETIVOS	15
1.1.1 Objetivo geral	15
1.1.2 Objetivos específicos	15
2 REVISÃO DE LITERATURA	16
2.1 FLORESTA AMAZÔNICA.....	16
2.2 CLAREIRAS	17
2.3 SENSORIAMENTO REMOTO	18
2.3.1 Satélite Sentinel-2A.....	19
2.3.2 Sistema LiDAR	20
2.4 APRENDIZAGEM DE MÁQUINAS.....	22
2.4.1 <i>Random Forest</i>	23
2.4.2 <i>Support Vectors Machine</i>	24
2.4.3 <i>Artificial Neural Network</i>	25
3 MATERIAIS E MÉTODOS	27
3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	27
3.1.1 Hidrografia	28
3.1.2 Geomorfologia e Pedologia.....	28
3.1.3 Vegetação	29
3.2 SATÉLITE SENTINEL-2A.....	29
3.2.1 Aquisição e processamento dos dados Sentinel-2A.....	29
3.2.2 Identificação de clareiras a partir de imagens MSI/Sentinel-2A e algoritmos de aprendizado de máquina.....	30
3.3 SISTEMA LIDAR.....	31
3.3.1 Aquisição e processamento dos Dados LiDAR	31
3.3.2 Detecção de clareiras a partir dos dados LiDAR.....	33
4 RESULTADOS E DISCUSSÃO	36
4.1 CARACTERIZAÇÃO DE CLAREIRAS COM DADOS SENTINEL-2A.....	36
4.2 CARACTERIZAÇÃO DE CLAREIRAS COM DADOS LIDAR	41
4.3 COMPARAÇÃO DOS MÉTODOS.....	50
5 CONCLUSÃO	54
REFERÊNCIAS BIBLIOGRÁFICAS	55

1 INTRODUÇÃO

A Amazônia, representa o maior bioma de floresta tropical do mundo. Esse bioma engloba uma grande extensão territorial que cobre parte de nove países da América do Sul, sendo que 69% dessa região pertence ao Brasil (AB'SABER 1997), totalizando uma área de 4.871.000km² a ser dividida entre os estados brasileiros do Amazonas, Pará, Maranhão, Tocantins, Mato Grosso, Acre, Amapá, Rondônia e Roraima (MAPBIOMAS, 2015).

As florestas tropicais estão naturalmente submetidas a distúrbios de intensidade, fazendo com que esses ecossistemas estejam sempre em curso (CHAZDON, 2016). Estes distúrbios, além de ocorrerem naturalmente podem ser decorrentes do aquecimento global, incêndios florestais e desmatamento (NOBRE, 2007), este último sendo causado por atividade madeireira ilegal, por invasão de terras para criação de pastos ou ainda, pela atividade ilegal de garimpeiros. As consequências deixadas por essas atividades são amplas áreas sem cobertura florestal, bem como aberturas no interior das florestas (PESSOA, 2019).

Nesse sentido, várias medidas já foram tomadas para a conservação desse ecossistema, uma delas consiste na adoção de planos de manejo que visam a utilizar a floresta de forma racional (SOUZA et al., 2006).

O conhecimento da composição florística e da estrutura da floresta permite o planejamento e o estabelecimento de sistemas de manejo com produção sustentável e condução da floresta a uma estrutura balanceada, bem como as práticas silviculturais adequadas (SOUZA et al., 2006). A partir desse conhecimento pode-se fazer suposições sobre a origem, as características ecológicas, a dinâmica e as tendências de desenvolvimento da floresta, sendo esses, elementos básicos para o planejamento do manejo florestal (JARDIM et al., 2008). Uma forma de se obter dados sobre estrutura, composição florística e a dinâmica de florestas é a partir do monitoramento.

O sensoriamento remoto pode ser definido como uma técnica para obter informações sobre objetos por meio de dados coletados por instrumentos que não estejam em contato físico como os objetos investigados (MENESES, 2001). As técnicas de sensoriamento remoto são uma alternativa para o monitoramento de grandes áreas, principalmente aquelas de difícil acesso. Em virtude disso, há uma crescente necessidade de estudos destinados ao monitoramento do bioma Amazônia com dados de sensoriamento remoto (OLIVEIRA, 2011).

Com o avanço do aprendizado de máquina, passaram a ser utilizadas as técnicas de inteligência artificial (FACELI et al., 2011), por meio do uso de algoritmos. Segundo Lary et al. (2016), as técnicas de aprendizado de máquina são eficazes para regressão e classificação,

possibilitando utilizar milhares de variáveis. Dentre os algoritmos, destacam-se *Random Forest* (RF), *Support Vectors Machine* (SVM) e *Artificial Neural Network* (ANN).

Na constante evolução dos sensores, surgiu em 2015 o satélite Sentinel-2A que apresenta um sensor multiespectral (*MultiSpectral Instrument* - MSI) de resolução espacial média/alta produzido pela Agência Espacial Europeia (ESA). Esse sistema sensor corresponde a uma importante fonte de dados para a avaliação da cobertura terrestre, sendo disponibilizadas de modo gratuito aos seus usuários. As imagens Sentinel apresentam grandes melhorias quando comparados aos demais satélites de monitoramento ambiental com acesso gratuito, destacando-se a maior cobertura de faixas do espectro eletromagnético, disponibilizando bandas na faixa Red Edge com 20 m de resolução espacial, bem como bandas da região do visível e infravermelho próximo com 10 m de resolução espacial.

Apesar da capacidade dos sensores ópticos multiespectrais passivos para mapear variações na densidade de cobertura vegetal ou na estrutura horizontal dos dosséis, eles apresentam limitações para caracterizar a estrutura vertical da vegetação. Assim, os sensores ativos apresentam-se como importantes aliados na avaliação da estrutura vertical e horizontal de formações florestais densas como a região Amazônica. Nesse sentido, os dados LiDAR (*Light Detection And Ranging*) podem quantificar as dimensões verticais e volumétricas da estrutura da vegetação (BERGEN et al., 2009).

O sistema LiDAR aerotransportado (*Airborne LiDAR System* - ALS) é uma tecnologia que tem a capacidade de obter informações de todo o perfil vertical da vegetação, incluindo informações do sub-bosque (JENSEN, 2009). O LiDAR vem sendo testado em inúmeras aplicações florestais, como por exemplo, estimativa de crescimento, quantificação de biomassa e estoques de carbono (NÆSSET et al., 2005; ASNER et al., 2011; GIANNICO et al., 2016) e em estudos sobre degradação em florestas tropicais (D'OLIVEIRA et al., 2012; ANDERSEN et al., 2014; ELLI et al., 2016). Sensores LiDAR de alta frequência conseguem gerar uma densa nuvem de pontos, em três dimensões, descrevendo com elevado grau de detalhes a estrutura do objeto imageado (GIONGO et al., 2010).

Nesse contexto, é importante a realização desse estudo, uma vez que as práticas de extração seletiva nas florestas tropicais propiciam a abertura de clareiras no dossel florestal, as quais necessitam de estudos a fim de avaliar a dinâmica e regeneração desses espaços.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo do estudo foi identificar a presença de clareiras por meio de imagens de média resolução espacial e sensor LiDAR, utilizando inteligência artificial em áreas de exploração seletiva da floresta no bioma Amazônia.

1.1.2 Objetivos específicos

1. Classificar imagens de média resolução espacial por meio dos algoritmos *Random Forest* (RF), *Support Vectors Machine* (SVM) e *Artificial Neural Network* (ANN);
2. Identificar e analisar a dinâmica de clareiras por meio de dados LiDAR no pacote *ForestGap*;
3. Desenvolver um método de identificação de áreas exploradas no Bioma Amazônia.

2 REVISÃO DE LITERATURA

2.1 FLORESTA AMAZÔNICA

A Floresta Amazônica é a maior floresta tropical do mundo, estende-se por nove países (Brasil, Paraguai, Bolívia, Peru, Equador, Colômbia, Venezuela, Guiana Francesa e Suriname). No Brasil, ocupa uma área de 4,2 milhões Km², o que corresponde aproximadamente a 49,3% do território nacional (SNIF, 2018), e abriga a maior rede hidrográfica do mundo, a bacia Amazônica, sendo responsável por escoar cerca de um quinto do volume de água doce do mundo (SARAIVA, 2017).

A floresta Amazônica é vista como uma grande extensão de floresta tropical homogênea. No entanto, é composta por um variado “mosaico” de fisionomias vegetais, onde cada tipologia possui suas especificidades, variando desde a formação e composição do solo, composição florística, inter-relações fauna e flora e as muitas relações abióticas (SILVA, 2015). O bioma Amazônia caracteriza-se por uma enorme diversidade de ambientes, com mais de 600 tipos diferentes de habitats terrestres e de água doce, que abriga rica biodiversidade: cerca de 45 mil espécies de plantas e vertebrados conhecidos (BRASIL 2013).

O bioma Amazônia é formado principalmente por florestas densas e abertas, abrigando uma diversidade de outros ecossistemas, como florestas estacionais, florestas de igapó, campos alagados, várzeas, savanas, refúgios montanhosos, campinaranas e formações pioneiras. Esse bioma abriga vastos estoques de madeira comercial e de carbono, possui uma grande variedade de produtos florestais não madeireiros que permite a manutenção de diversas comunidades locais (SNIF, 2018).

As mudanças no uso da terra e na cobertura do solo ocorrem em todo o mundo, mas a maior preocupação atual concentra-se sobre o desmatamento tropical, que impulsiona espécies à extinção, libera gases de efeito estufa e dificulta a sustentabilidade dos ambientes locais (VASCONCELOS, 2015). O desmatamento tropical e a mudança na cobertura da terra são processos complexos que envolvem uma multiplicidade de agentes, os pequenos agricultores, fazendeiros, madeireiros e garimpeiros, têm contribuído para a perda de floresta (MENDONÇA et al., 2012).

A região amazônica é vista como prioridade mundial devido a sua importância na manutenção dos estoques de carbono e a sua contribuição em outros serviços ambientais valiosos (FEARNSIDE, 2016). Segundo Pereira et al. (2010), a extração seletiva de madeira na Amazônia corresponde a uma prática sustentável, tendo na indústria madeireira a maior

atividade econômica na região. A exploração de impacto reduzido permite que a floresta se recupere até a próxima colheita, uma vez que são deixadas árvores em pé, sendo realizado o planejamento dos danos à toda a vegetação, inclusive à regeneração natural (HIRAI et al., 2012).

2.2 CLAREIRAS

Na Amazônia existem áreas de exploração florestal sob domínio de um manejo sustentável, que por sua vez acarretam em aberturas no dossel da floresta, denominadas de clareiras. No estudo de clareiras é possível encontrar variadas formas de delimitação da área afetada pela abertura no dossel, pois a clareira pode ser definida de formas diferentes e a adoção desses critérios na sua delimitação e mensuração podem produzir resultados muito distintos (MEER et al., 1994).

O método proposto por Runkle (1981), a clareira é uma área do solo sob a abertura do dossel. Segundo o autor, as árvores do dossel com alturas entre 10 e 20 m, bem como diâmetro maior que 25 cm, permitiriam delimitar a clareira, sendo consideradas como “árvores do seu entorno”, embora não pertencessem a ela (SANTOS, 2007). No entanto, o dossel florestal não se constitui de uma camada maciça e homogênea, sendo por vezes difícil estabelecer a diferença entre uma irregularidade na altura do dossel e uma clareira propriamente dita (DAVISON, 2009).

As clareiras podem ser formadas pelos diferentes tipos de quedas, como a altura e o diâmetro das árvores, o tipo de morte característico de cada espécie (JANS et al., 1993) e por fenômenos meteorológicos. Outros fatores importantes na formação de clareiras são as variações edáficas e topográficas (PALMIOTTO et al., 2004), a pluviosidade anual (BROKAW, 1982b, MARTINEZ-RAMOS et al., 1988), as características da madeira e a infestação por insetos (ARRIAGA, 1988).

Entretanto, na maior parte das vezes, a morte de árvores está relacionada a uma somatória de eventos (JANS et al., 1993). Os principais tipos de quedas de árvores que originam clareiras são causados por: a) queda de galhos, b) queda contínua de partes da copa (árvores mortas em pé), c) árvores com tronco quebrado, d) árvores desenraizadas, e) queda múltipla de árvores (efeito dominó) (LIN et al., 2004). De acordo com o tipo de queda é possível prever o formato da clareira que será gerada, sendo esse o principal fator que influencia a incidência de luz (SALVADOR-VAN EYSENRODE et al., 1999) e conseqüentemente, a colonização por espécies pioneiras e secundárias (HOWE, 1990).

O fluxo de luz nas clareiras está diretamente relacionado com o seu tamanho (BARTON et al., 1989), além disso, a luz incidente apresenta maior quantidade de radiação fotossinteticamente ativa, favorável para o desenvolvimento das plantas (LIMA, 2005a). Clareiras grandes apresentam maior quantidade de luz disponível em relação aos demais ambientes da floresta (DUPUY & CHAZDON, 2006), além de maior heterogeneidade da intensidade luminosa em relação às clareiras pequenas (YAMAMOTO, 1992).

Nesse sentido, as clareiras podem ser facilmente identificadas por meio de imagens disponibilizadas pelo sensoriamento remoto. Assim, as geotecnologias são importantes ferramentas para o estudo de clareiras em florestas tropicais, especialmente em áreas de extração seletiva.

2.3 SENSORIAMENTO REMOTO

O Sensoriamento Remoto (SR) pode ser entendido como um conjunto de atividades que permite a obtenção de informações dos objetos que compõem a superfície terrestre sem a necessidade de contato direto com os mesmos. A energia eletromagnética utilizada na obtenção dos dados por sensoriamento remoto é também denominada de radiação eletromagnética (MORAES, 2002). Segundo Meneses, (2001) o sensoriamento Remoto pode ser definido como uma técnica para obter informações sobre objetos através de dados coletados por instrumentos que não estejam em contato físico como os objetos investigados.

O sensoriamento remoto, nos últimos anos, tornou-se uma importante ferramenta para monitorar os recursos naturais da Terra. Os estudos de detecção de mudanças na cobertura da terra por meio do sensoriamento remoto são baseados no fato de que distúrbios, tanto naturais quanto de origem antrópica, no meio ambiente, produzem variações detectáveis na resposta espectral do alvo ou do fenômeno estudado (FERNANDES, 2007).

Os níveis de aquisição de dados de sensoriamento remoto dependem do veículo de suporte para a operação de um sistema sensor. Os sistemas sensores podem ser ativo ou passivo, quanto a fonte de energia, imageadores ou não-imageadores (NOVO, 2008). Os sensores passivos são aqueles que obtêm dados por meio da radiação natural refletida ou emitida da superfície da Terra, por exemplo sensor Sentinel, também é possível produzir ondas ou radiações eletromagnéticas específicas e iluminar a superfície terrestre. Já os sensores ativos produzem sua própria radiação, uma câmera fotográfica que produz flash é considerada um sensor ativo, por exemplo sistema LiDAR. Os sensores passivos ou ativos podem gerar imagens ou não, como câmera e radiômetro de não-varredura, respectivamente (CARNEIRO, 2018).

Os sensores ópticos e radiométricos trabalham normalmente em três níveis de coleta: terrestre, aéreo (suborbital) e orbital (MOLIN et al., 2015). Os sensores em nível terrestre espectrorradiômetro e radiômetro portátil, podendo ser instalados em máquinas agrícolas; em nível aéreo destacam-se radiômetros hiperespectrais e fotografias aéreas; e em nível orbital radiômetros do tipo escâner acoplados em satélites conhecidos como sensores imageadores (MOREIRA, 2011).

De modo geral, o sensoriamento remoto apresenta inúmeras opções de aplicações no meio ambiente, dentre elas, citam-se aplicação: agrícola, urbana, ecológica, geológica, florestais, cartográficas, hidrológicas, militares, oceanográficas, limnológicas, entre outras (NOVO, 2010). É uma ferramenta muito utilizada para o estudo da Terra, uma vez que fornece visão panorâmica de uma dada região, sendo esta uma característica muito importante para a realização de estudos de fenômenos dinâmicos (CENTENO, 2003).

2.3.1 Satélite Sentinel-2A

Dentre os produtos disponíveis no SR, destaca-se o Sentinel-2A, que consiste em um satélite com sensor multiespectral de média resolução espacial produzido pela Agência Espacial Europeia (ESA), o qual foi arquitetado para garantir a continuidade da cobertura de dados globais da Terra fornecidos pelas séries de satélites LANDSAT e SPOT O Sentinel-2A opera a uma altitude de 786 km, numa órbita circular heliosíncrona com inclinação de 98,6° (ligeiramente retrógrada) (BEZERRA, 2019). O Sentinel-2A foi desenvolvido para apoiar estudos sobre a vegetação, a cobertura da terra e o monitoramento ambiental. (USGS, 2019).

Esta missão foi lançada em 2015, de modo que o sensor *MultiSpectral Instrument* (MSI) apresenta uma larga faixa imageada (290 km), associado a uma alta resolução temporal (cinco dias). Esse sistema possui diferentes parâmetros quanto a resolução espacial, podendo ser classificado como de alta e média resolução espacial pois contempla bandas com 10, 20 e 60 m. A resolução espectral é alta, uma vez que apresenta 13 bandas espectrais (SOTHE et al., 2017).

As bandas do Sentinel-2A cobrem as regiões espectrais do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). As quatro bandas com resolução espacial de 10 metros (2, 3, 4 e 8), foram definidas para manter a compatibilidade com os produtos SPOT, enquanto que as bandas de 20 metros de resolução espacial, foram arquitetadas para observar principalmente as características da vegetação (borda vermelha da vegetação e a banda de absorção da lignina). As bandas de resolução espacial de 60 metros são

destinadas a correção atmosférica (ESA, 2019). A Tabela 1 demonstra as diferentes faixas espectrais abrangidas pelo satélite (ENGESAT, 2016).

Tabela 1 – Características das imagens Sentinel-2A.

Resolução espacial	Banda	Nome da banda	Comprimento de onda central (nanômetro)	Combinações de bandas
10 m	2	Blue (Azul)	490	Cor verdadeira
	3	Green (Verde)	560	RGB 4/3/2
	4	Red (Vermelho)	665	Falsa Cor 1 e 2
	8	NIR (Infravermelho Próximo)	842	RGB 8/4/3 e 4/8/3
20 m	5	Red Edge 1	705	SWIR 1 RGB 12/11/8 ^a
	6	Red Edge 2	740	
	7	Red Edge 3	783	
	8A	Red Edge 4	865	
	11	SWIR 1	1610	
	12	SWIR 2	2190	
60 m	1	Aerossol	443	–
	9	Water Vapor	940	
	10	Cirrus	1375	

Fonte: Adaptação de Engesat (2016).

2.3.2 Sistema LiDAR

O uso de sistemas LiDAR (*Light Detection and Ranging*) vem mostrando uma ótima capacidade para a aquisição de uma grande quantidade de informações, em pequeno intervalo de tempo. O sistema de varredura LiDAR não apresenta uma terminologia oficial. Alguns autores preferem denominar esse sistema como LADAR (*Laser Detection and Ranging*), para deixar claro que se trata de um sistema a laser (WEHR; LOHR, 1999).


A tecnologia LiDAR não é nova, porém sua utilização na aquisição de dados geográficos pode ser considerada recente. O primeiro LiDAR foi desenvolvido após a II Guerra Mundial e a sua primeira grande evolução ocorreu em 1960, com a invenção do sistema a laser e a mudança no sistema de posicionamento dos dados geográficos (HASSEBO, 2012; CARTER

et al., 2012). Inicialmente, o LiDAR foi desenvolvido para mapeamento topográfico, com intuito de gerar Modelos Digitais de Elevação (MDE) com elevada acurácia de áreas de difícil acesso (WAGNER et al., 2004; GIONGO et al., 2010).

Nos últimos anos, o LiDAR tem sido frequentemente utilizado em diversas áreas do conhecimento, como em aplicações florestais, na agricultura, no planejamento urbano, na avaliação de risco de inundações, em telecomunicações, no transporte, em mineração, etc. Em aplicações florestais, o uso do LiDAR tem se destacado devido aos bons resultados apresentados (GIONGO et al., 2010). Por meio do LiDAR, é possível obter medidas diretas da vegetação, como a altura do dossel, o número de indivíduos e o diâmetro da copa. Além disso, podem ser adquiridas medidas indiretas, tais como a estimativa de AGB (biomassa acima do solo), o volume, a área basal, o DAP, o carbono estocado e o material combustível (DUBAYAH et al., 2000; POPESCU et al., 2011).

A tecnologia LiDAR é baseada nos mesmos princípios utilizados no sistema de RADAR, com a diferença de que, ao invés do uso de ondas de rádio para localizar os objetos de interesse, o sistema LiDAR utiliza pulsos laser. Para estudos de aplicações florestais e terrestres, o pulso de laser é comumente emitido no comprimento de onda do infravermelho próximo (900-1064 nm) do espectro eletromagnético (SATO, 2016). A Figura 1 apresenta um esquema de como é realizada a aquisição dos dados LiDAR e os componentes do sistema.

Figura 1 - Aquisição de dados e componentes da varredura *LASER* aerotransportada.



Nas aplicações florestais, esse comprimento de onda é utilizado, pois é a região de maior refletância da vegetação, fornecendo um melhor sinal de retorno ao LiDAR. Além disso, no comprimento de onda do infravermelho próximo, ocorre menor perda do sinal através do espalhamento e absorção pela atmosfera. Entretanto, nesse comprimento de onda, ocorre absorção do sinal pelas nuvens, o que impede o uso deste sensor em condições nubladas (LEFSKY et al., 2002). O primeiro conjunto de pulsos que interage com a vegetação e que retorna para o sensor contém os sinais que atingem o topo das copas das árvores da floresta. Os conjuntos de pulsos seguintes representam os retornos provenientes de galhos e folhas. A medida que o feixe laser se desloca através do dossel florestal, informações sobre os componentes das árvores que estão no sub-bosque da floresta podem ser adquiridas. (SATO, 2017).

Apesar dos avanços na qualidade das informações florestais com emprego de técnicas de precisão com o uso do receptor GPS e geoprocessamento incorporados ao planejamento da exploração florestal (FIGUEIREDO et al., 2007), os custos e a morosidade do inventário censitário para florestas tropicais, continuam sendo um problema de base tecnológica a ser resolvido. No meio florestal, a expectativa da adoção do perfilamento por meio do LIDAR aerotransportado é que os inventários proporcionarão uma combinação desejada de baixo custo, precisão, qualidade e confiabilidade. (FIGUEIREDO et al., 2014).

Os dados oriundos do SR podem ser melhor explorados para a observação de parâmetros florestais quando associados a técnicas de inteligência artificial, especialmente aquelas que utilizam algoritmos de aprendizado de máquina.

2.4 APRENDIZAGEM DE MÁQUINAS

O aprendizado de máquina, do inglês *Machine Learning* (ML) é uma das mais importantes áreas da Inteligência Artificial, que trabalha com técnicas que realizam induções sobre os dados utilizados. Segundo Bishop (2006), o aprendizado de máquina é um campo de pesquisa fundamentado na Inteligência Artificial e na estatística. Essas técnicas são comumente utilizadas para realizar tarefas de classificação, isto é, após a criação de um modelo, este deve classificar uma nova instância do problema em uma das classes definidas (SANTOS, 2016).

Segundo Gama et al. (2011), os algoritmos de aprendizagem de máquina têm sido usados para diversas tarefas e podem ser organizados de acordo com diferentes critérios. Um deles é o paradigma de aprendizado que pode ser escolhido para tratar uma tarefa. Essas tarefas

podem ser: descritivas e preditivas. As tarefas descritivas tentam explorar um conjunto de dados e seguem o paradigma de aprendizado não supervisionado (SANTOS, 2016). Em tarefas preditivas (paradigma de aprendizado supervisionado), o objetivo é obter uma função ou hipótese a partir de dados de treinamento para ser usada na predição de um rótulo (atributo alvo) com base em seus atributos de entrada (GAMA, 2011).

Na aprendizagem não supervisionada, os algoritmos assumem que não se conhece a classe à qual os exemplos pertencem e procuram encontrar nos valores de atributos similaridades ou diferenças que possam, respectivamente, agrupar os exemplos pertencentes a mesma classe ou dispersar os exemplos de classes distintas (RUSSEL; NORVIG, 2002). Na aprendizagem supervisionada, é fornecido ao sistema de aprendizado um conjunto de exemplos com a saída conhecida, ou seja, cada exemplo observado é descrito por um conjunto de atributos e pelo valor da classe à qual o exemplo pertence (STANGE, 2011).

Na aprendizagem supervisionada, a tarefa de aprendizado é determinada como classificação ou regressão em função do tipo do atributo classe, que pode ser discreto ou contínuo. Quando o rótulo da classe é um valor discreto, a tarefa de aprendizado é chamada classificação, caso o rótulo da classe seja um valor contínuo, a tarefa é denominada regressão (DUDA et. al., 2001).

Segundo Lary et al. (2016), as técnicas de aprendizado de máquina são eficazes para regressão e classificação. Os algoritmos frequentemente utilizados são florestas aleatórias (BREIMAN, 2001), máquinas de vetores de suporte (CORTES et al., 1995), redes neurais artificiais (MCCULLOCH e PITTS, 1943), entre outros.

2.4.1 *Random Forest*

A floresta aleatória, ou *Random Forest* – RF, é um algoritmo para métodos de ensemble utilizando classificadores do tipo árvore. A RF constrói uma grande quantidade de árvores de decisão para fora do sub-conjunto de dados a partir de um treinamento único definido (LOPES, 2017).

Esta técnica funciona criando uma grande quantidade de árvores de decisão com configurações diversas. A partir das árvores geradas, são agrupados os resultados com objetivo de encontrar o melhor resultado possível. Normalmente, a escolha do melhor resultado possível entre as árvores é feita utilizando a técnica do voto majoritário (BERRY; LINOFF, 1999).

As RFs são obtidas por meio de *bootstrapping aggregating* (ou simplesmente bagging), um método utilizado para gerar múltiplas versões de um preditor [Breiman 1996]. Tais versões

são construídas a partir de reamostras do conjunto original, obtidas via sorteio simples com reposição.

Segundo Seyedhosseini e Tasdizen (2015), o algoritmo RF é um classificador/regressor cuja ideia principal da “Floresta aleatória” é fazer crescer um conjunto de árvores de decisão tal que a correlação entre essas árvores permaneça tão baixa quanto possível. Tal condição é alcançada através do método bagging, em que a aleatoriedade é injetada na floresta usando um subconjunto diferente de amostras de treinamento para cada árvore, assim, randomicamente são extraídas instâncias do conjunto de treinamento, visando treinar determinado número de árvores da floresta (valor esse definido pelo usuário) (SCHIKOWSKI, 2016). Além disso, em cada nó da árvore um subconjunto aleatório das variáveis de entrada é usado para aprender a função de partição. A ideia principal é fazer com que as árvores de decisão sejam as mais independentes possível, melhorando a robustez e a generalização do conjunto (BREIMAN, 2001).

2.4.2 Support Vectors Machine

A Máquina de Vetor de Suporte, do inglês *Support Vectors Machine* – SVM, foi desenvolvida pelo pesquisador russo Vladimir Vapnik (VAPNIK, 1995). Constitui uma técnica fundamentada na Teoria de Aprendizado Estatístico visando a proposição de técnicas de aprendizado de máquina que buscam a maximização da capacidade de generalização e a minimização do risco estrutural (HAYKIN 2001).

Algoritmos baseados em SVM são aplicados em diversos ramos da ciência em problemas de classificação e regressão (RAGHAVENDRA e DEKA, 2014). São utilizados por possuir uma boa capacidade de generalização, ou seja, uma vez que as SVM são apresentadas ao conjunto de treinamento, são capazes de aprender a regra que pode classificar corretamente outro conjunto de objetos (SMOLA et al., 2000);

O uso das chamadas funções *Kernel* torna possível a construção de um hiperplano de separação ótimo no espaço de características (também chamado de espaço de alta dimensão), sem ter que considerar o próprio espaço de características de forma explícita (HAYKIN, 1999). Isto torna o algoritmo eficiente do ponto de vista computacional (BURGES, 1998). Máquina de Vetor de Suporte é uma técnica baseada em métodos estatísticos. Esta técnica funciona dividindo os dados por meio de um hiperplano traçado entre as instâncias (LORENA; CARVALHO, 2007), buscando minimizar o erro com relação ao conjunto de treinamento, assim como o erro em relação ao conjunto de teste, isto é, conjunto de amostras não empregadas no treinamento do classificador (ADREOLA, 2009).

Esta técnica, originalmente desenvolvida para classificação binária, busca a construção de um hiperplano como superfície de decisão, de tal forma que a separação entre exemplos seja máxima, isso considerando padrões linearmente separáveis. Já para padrões não-linearmente separáveis, busca-se uma função de mapeamento apropriada para tornar o conjunto mapeado linearmente separável. Devido à sua eficiência em trabalhar com dados de alta dimensionalidade e reportada na literatura como uma técnica altamente robusta, muitas vezes é comparada as Redes Neurais (SUNG; MUKKAMALA, 2003; DING; DUBCHAK, 2001).

2.4.3 Artificial Neural Network

As Redes Neurais Artificiais (*Artificial Neural Network* – ANN), são sistemas computacionais que se assemelham as redes neurais biológicas presentes no cérebro (VAPNIK, 1995). Nesses sistemas os conhecimentos são adquiridos a partir de seu ambiente por meio de um processo de aprendizagem e pela força de conexão entre os neurônios, no caso do cérebro humano, e nas redes artificiais por meio dos sistemas, denominados pesos sinápticos, os quais são utilizados para armazenar o conhecimento adquirido (BISI, 2015).

A principal característica das ANN é o aprendizado, ou seja, sua capacidade de aprender com ambiente e melhorar o desempenho (MENDONÇA et al., 2016). O algoritmo de aprendizado deve conter um conjunto de regras bem definidas para a solução de um problema. Sabe-se, conforme Silva et al., (2010), que há algoritmos específicos para cada modelo de ANN, a diferença está na forma com que cada um modifica seus pesos para alcançar o objetivo desejado.

Essa técnica também se destaca pelas seguintes propriedades: aprendizagem de conjuntos linearmente inseparáveis, mapeamento de entrada-saída, adaptação, tolerância à falhas e uniformidade de análise e projeto. É importante destacar também que ANN são baseadas na minimização do risco empírico, ou seja, minimização do erro de treinamento (SANTOS, 2002).

O processamento de dados se inicia com uma fase de aprendizagem, na qual um conjunto de dados, em que já se conhecem as respostas, é apresentado, fazendo com que as forças das conexões da rede se alterem de modo a gerar um resultado que seja o mais próximo possível daquele observado nos dados de treinamento. Espera-se, posteriormente, que a Rede Neural Artificial adquira capacidade de fornecer respostas para dados não conhecidos previamente (BRAGA et al., 2000).

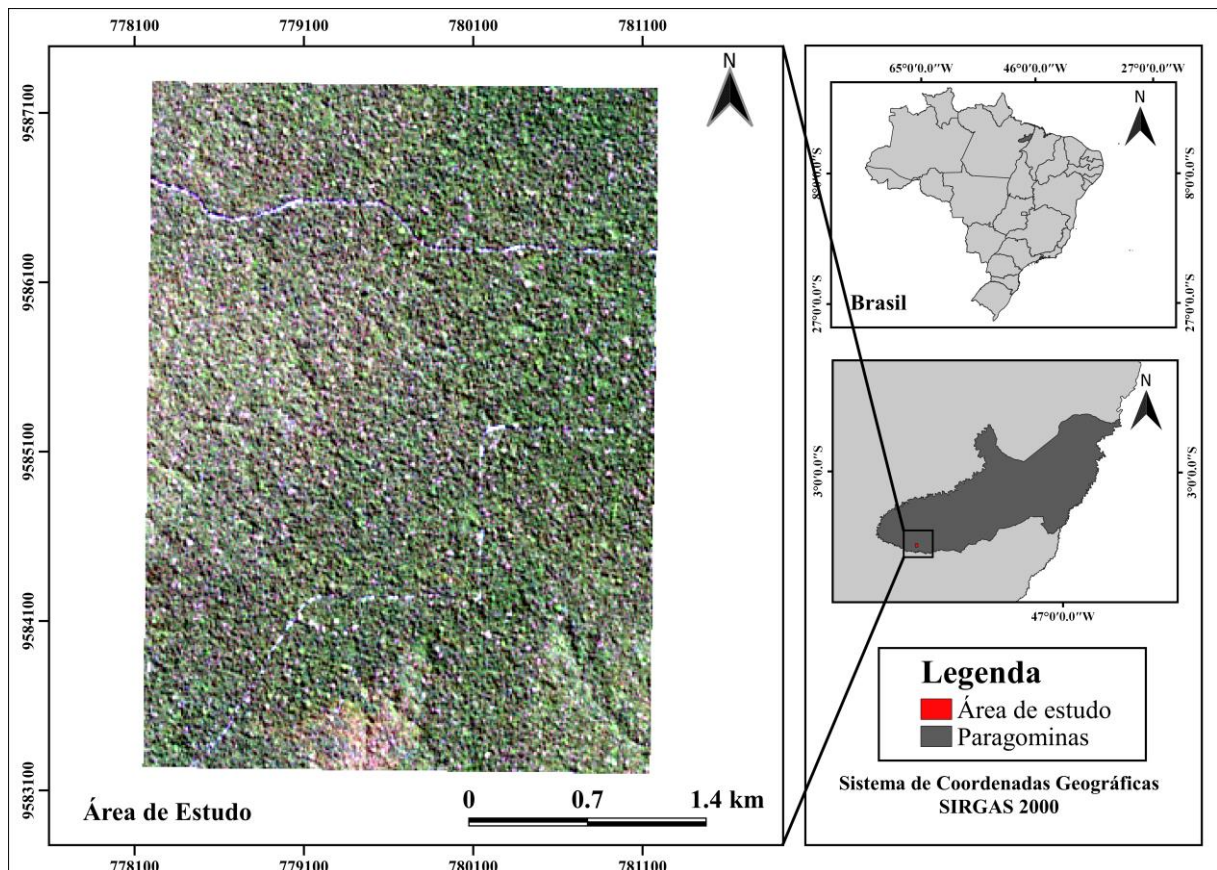
De um modo geral, ANN tem a capacidade de generalização, a qual pode ser definida como a capacidade de se obter saídas corretas para novos dados de entrada a partir de diferentes amostras de treinamento (ZHANG et al., 2003). Outra característica é a capacidade de auto-organização ou plasticidade dos neurônios, ou seja, num processo de aprendizagem é possível alterar os padrões de interconexão entre seus elementos (SPANDRI, 2000).

3 MATERIAIS E MÉTODOS

3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O estudo foi desenvolvido em áreas florestais com aproximadamente 1.200 ha de extensão, localizadas a 3° 35' 00" e 3° 45' 00" de latitude Sul e 48° 15' 00" e 48° 25' 00" de longitude Oeste, na Fazenda Cauaxi, situado no município de Paragominas, nordeste do Estado do Pará. A fazenda está inserida na Área de Manejo Florestal (AMF) Rio Capim de propriedade da empresa CIKEL (FIGURA 2).

Figura 2– Localização da área de estudo na Fazenda Cauaxi, Paragominas – PA.



Fonte: Autora.

O estado do Pará está localizado no Leste da Amazônia, onde o desmatamento e a exploração madeireira são partes integrantes da economia há décadas (FEARNSIDE, 2005; FEARNSIDE, 2007). O objetivo da empresa CIKEL é produzir madeira de forma sustentável,

para o abastecimento contínuo das unidades do grupo CIKEL e fornecimento de matéria prima para indústrias locais CIKEL (2010).

A classificação climática para a região, segundo Köppen, é do tipo “Aw”, isto é, tropical chuvoso com estação seca bem definida. A precipitação média anual está em torno de 1.800 mm com temperatura média anual de 26,3 °C e umidade relativa do ar de 81% (ALVARES et al. 2013).

Na Fazenda Cauaxi encontra-se sediado o Centro de Manejo Florestal Roberto Bauch, o qual é utilizado desde 1995 pelo Instituto Floresta Tropical (IFT) como um centro de treinamento para demonstração de exploração de impacto reduzido (EIR) (PEREIRA JR. et al., 2002). O IFT opera uma das maiores áreas de treinamento e demonstração de manejo florestal na Amazônia brasileira, com mais de 3.000 ha de floresta sob manejo (KEEFE et al., 2009).

3.1.1 Hidrografia

Os rios são os limites territoriais naturais em quase todo o seu perímetro, sendo formada por duas bacias hidrográficas principais: rio Capim, que limita a área ao noroeste, e o rio Surubijú, que faz limite ao sul (CARDONA, 2012). O rio Capim se situa na fronteira norte, com o município de Ipixuna, e oeste de Paragominas com Ipixuna. Por sua vez, o rio Surubiju estabelece a divisa de Paragominas com os municípios de Goianésia e Dom Eliseu ao sul, (PINTO et al., 2009).

3.1.2 Geomorfologia e Pedologia

O Município de Paragominas encontra-se no Domínio Morfo-estrutural dos Planaltos em Sequência Sedimentares não Dobradas (IBGE, 2003), caracterizados por superfícies estruturais aplainadas, na forma de extensos chapadões, com altitudes médias em torno de 180 m, limitadas por planaltos dissecados sob a forma de cristas, interflúvios tabulares, e desenvolvidos em rochas sedimentares constituídas de argilitos, da Formação Ipixuna, do período Cretáceo Superior e por planícies aluviais. As unidades geomorfológicas, frutos da associação de formas de relevo recorrentes, geradas de uma evolução são: Platôs de Paragominas, Vales de Paragominas, Depressão do Gurupi e Planícies do Rio Capim (RURAL, 2010)

Segundo Rodrigues et al., (2003), em mais de 81% da área do município os solos são classificados como Latossolos Amarelos Distróficos de texturas média e muito argilosa. Os

Latossolos Amarelos apresentam características que favorecem a presença de áreas de floresta nativa, com elevada profundidade, boa drenagem e permeabilidade (BRASIL, 1973).

3.1.3 Vegetação

Originalmente, o município de Paragominas era majoritariamente coberto por floresta tropical. Em 2008, 45% de sua área estavam desmatadas ou altamente degradadas, o equivalente a 874 mil hectares (PIMENTEL, 2016). O restante (55%) do território estava coberto por florestas em diversos estágios de uso e conservação.

A vegetação originária do município é representada pela Floresta Densa da sub-região dos Altos Platôs do Pará-Maranhão, pela Floresta Densa de Planície Aluvial e dos Terraços, mas, com os desmatamentos, provocados pelo avanço da agropecuária da região, reduziram, drasticamente, as grandes áreas cobertas pela floresta original, dominadas, hoje, por extensas áreas de Mata Secundária (CARDONA, 2012).

3.2 SATÉLITE SENTINEL-2A

3.2.1 Aquisição e processamento dos dados Sentinel-2A

Para este estudo foi utilizada imagem orbital do satélite Sentinel-2A, adquirida pelo sensor *Multi-Spectral Instrument* (MSI). Esta imagem foi obtida gratuitamente por meio do *United States Geological Survey* (USGS), a qual possui nível 1C de processamento, que conta com a imagem geometricamente corrigida (ortoretificada), valores de reflectância no topo da atmosfera (TOA) e resolução espacial de 10, 20 e 60 metros (ESA, 2013).

Foi selecionada a imagem datada em 31 de maio de 2018, na órbita 124, de modo que a cena apresentou 2,6 % de cobertura de nuvens na cena, não afetando a área de estudo. A imagem utilizada foi aprovada em todos os parâmetros de qualidade do produto 1C estabelecido pela ESA, conforme o documento de requisitos da missão Sentinel-2A (ESA, 2013). Neste estudo foram utilizadas quatro bandas, sendo elas a 4, 3, 2 (RGB) e 8 (Infravermelho Próximo) por apresentarem resolução de 10 metros.

As bandas foram recortadas conforme a área de estudo e posteriormente efetuado a composição falsa-cor (RGB), as quais foram contrastadas a fim de proporcionar melhor conforto visual na identificação dos alvos.

3.2.2 Identificação de clareiras a partir de imagens MSI/Sentinel-2A e algoritmos de aprendizado de máquina

Para a identificação de clareiras com imagem Sentinel-2A foi criado um arquivo vetorial, do tipo *shapefile*, contendo os polígonos de amostras das áreas com cobertura florestal e de áreas com clareiras, sendo essas, as duas classes temáticas em estudo. Esses processos foram realizados no *software* Qgis versão 3.8.3.

A composição falsa cor (RGB - 432) foi utilizada para a vetorização dos polígonos dessas classes. Foram realizados treinamentos até a obtenção de amostras suficientes para a representação correta das classes de interesse. Para maior confiabilidade das amostras, utilizou-se o *Google Earth Pro* para auxiliar na obtenção das amostras, assim como para a conferência do resultado final.

Na sequência, realizou-se a extração da informação espectral das bandas do sensor MSI/Sentinel-2A a partir dos polígonos amostrados para cada uma das classes temáticas, formando desse modo, o arquivo base para o treinamento dos algoritmos de aprendizado de máquina, este processo foi realizado na extensão para classificação supervisionada semiautomática - SCP (Semi-Automatic Classification Plugin), incorporada no programa de código aberto Qgis versão 3.8.3. Para a classificação de clareiras por meio da imagem de satélite foram utilizados os algoritmos RF, SVM e ANN (TABELA 2).

Tabela 2 – Parâmetros utilizados em cada Algoritmos de aprendizado de máquina.

Algoritmo	Sigla	Tipo de parâmetro	Parâmetro
Random Forest	RF	mtry: número de variáveis amostradas aleatoriamente	2
		nree: número de árvores	1000
Support vector machine	SVM	kernel: tipo de função kernel utilizada na predição	Radial
		C: ajusta a sensibilidade da margem de decisão de vetores de suporte classificados errados	0,5
Artificial Neural Networks	ANN	maxit: número máximo de interações	100
		weights: peso para cada exemplo	1

Fonte: Adaptação de Souza et al. (2016).

Para os três algoritmos de aprendizado de máquina foi utilizada a mesma base de amostras para o treinamento. Conforme Souza et al. (2016), a escolha dos parâmetros a serem usados no treinamento dos algoritmos foram obtidos por meio de testes preliminares e escolhidos as combinações de parâmetros que apresentaram maior precisão durante os ajustes dos modelos.

A classificação supervisionada de imagem orbitais foi desenvolvida em Linguagem R, versão 3.5.1 (R DEVELOPMENT CORE TEAM, 2019), a partir de uma abordagem não paramétrica. Para isto, foram utilizados os pacotes *raster* (HIJMANS, 2016), *caret* (KUHNS et al., 2016) e *rgdal* (BIVAND et al., 2016).

Para a verificação do melhor algoritmo de aprendizado de máquina para a classificação das clareiras foram utilizados a acurácia global e o índice Kappa. A acurácia global foi o parâmetro utilizado na validação, uma vez que informa o quanto um valor é correto e livre de erros, sendo um importante parâmetro de avaliação da classificação de imagens. A avaliação dos algoritmos se deu por meio da validação cruzada, com 30 repetições, observando o valor do índice de acurácia para cada um dos algoritmos de aprendizado de máquina. Posteriormente, foi utilizado o teste de Friedman e Nemenyi para comparar os resultados das acurácias e verificar se os algoritmos diferiram entre si.

3.3 SISTEMA LIDAR

3.3.1 Aquisição e processamento dos Dados LiDAR

Os dados LiDAR utilizados neste estudo foram adquiridos do *WebGis* do Projeto Paisagens Sustentáveis Brasil, apoiado pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), pelo Serviço Florestal dos Estados Unidos (USDA), pela Agência dos Estados Unidos para o Desenvolvimento Internacional (USAID) e pelo Departamento de Estado dos EUA. De acordo com Embrapa (2014), o projeto visa gerar informações detalhadas da superfície do terreno e da vegetação, contribuindo para o desenvolvimento de técnicas de medição e mitigação dos efeitos do dióxido de carbono e outros gases de efeito estufa (Tabela 3).

Tabela 3 – Especificações técnicas do voo dos anos 2014 e 2017 realizado na Fazenda Cauaxi, Paragominas, Pará.

Especificações	2014	2017
Área recoberta	1.216ha	1.214ha
Número de cenas	20	20
Datum	SIRGAS 2000	SIRGAS 2000
Sistema de coordenadas da UTM	22S	22S
Densidade média de retornos	61,38ppm ²	28,59ppm ²
Densidade média de primeiros retornos	37,5ppm ²	22,61ppm ²
Altitude média do voo	850m	850m
Campo de visão	12°	15°
Porcentagem de sobreposição	65%	70%
Sensor	OPTECH, ORION M300	OPTECH, ALTM 3100
Frequência de varredura	83 Hz	40 Hz
GNSS	APPLANIX, 09SEN243	OMNISTAR, PGPS16
Frequência GNSS	5 Hz	1 Hz
IMU	LITTON, 413996	APLANNIX, Av510 IMU8
Frequência da IMU	100 kHz	200 kHz

Fonte: adaptação de Paisagens sustentáveis Brasil (2017).

O processamento dos dados LiDAR deu-se com auxílio do *software* FUSION/LDV versão 3.8, que foi desenvolvido pelo Serviço Florestal Norte Americano. Este *software* permite analisar e visualizar os dados de LiDAR, além de ser uma eficiente ferramenta de processamento (MCGAUGHEY, 2016). Para o processamento dos dados no *software* FUSION/LDV, foram utilizadas as seguintes ferramentas:

- a) *ThinData* – homogeneização da densidade de retornos, criando um mosaico (extensão *.las);
- b) *Catalog* – cria uma descrição de importantes características do LiDAR em um relatório. Tem como entrada a nuvem de pontos (extensão *.las);
- c) *GroundFilter* – filtragem dos retornos que foram refletidos ao nível do solo. O qual é baseado no algoritmo de filtragem, fundamentado em Kraus e Pfeifer (1998).
- d) *GridSurfaceCreate* – gera os Modelos Digitais de Terreno (MDT). Usa o produto do *GroundFilter*, ou seja, os pontos classificados de solo;
- e) *ClipData* – normalização das alturas da área de estudo. Tem como entrada os produtos das ferramentas *ThinData* e *GridSurfaceCreate*;
- f) *Canopymodel* – tem como resultado o *Canopy Heigh Model* (CHM).

3.3.2 Detecção de clareiras a partir dos dados LiDAR

Além das imagens Sentinel-2A, o estudo englobou ainda a utilização de dados LiDAR para a detecção e análise da dinâmica das clareira para os anos de 2014 e 2017, a fim permitir a comparação dos resultados obtidos por ambos os métodos. Para a detecção de clareiras com dados LiDAR, utilizou-se a versão 0.0.2 do pacote *ForestGapR* (SILVA et al., 2019), possuindo seis funções para detecção e análise de clareiras no dossel da floresta (Tabela 4).

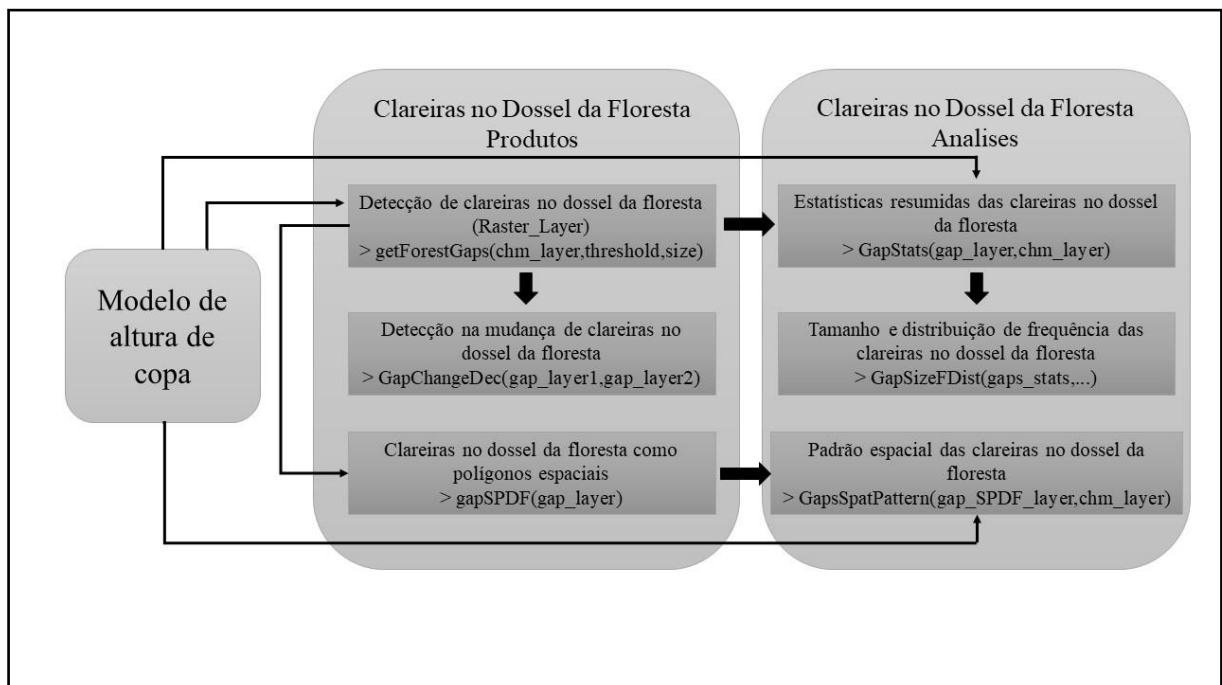
Tabela 4 - Lista de funções incluídas no pacote *ForestGapR* e suas características.

Função	Funcionalidade	Entrada	Resultado
<i>getForestGaps</i>	Detecta clareiras no dossel da floresta	O modelo de altura do dossel do ALS (CHM) como um objeto <i>RasterLayer</i>	<i>Objeto</i> binário <i>RasterLayer</i> de clareiras no dossel da floresta
<i>GapStats</i>	Estatísticas resumidas das clareiras no dossel da floresta.	<i>Objeto</i> binário <i>RasterLayer</i> de clareiras no dossel da floresta	<i>Quadro</i> de dados das estatísticas de clareiras no dossel da floresta
<i>GapSizeFDist</i>	Análise de distribuição de frequências de clareiras no dossel da floresta	<i>Quadro</i> de dados das estatísticas de clareiras no dossel da floresta	A probabilidade máxima se ajusta a uma distribuição Zeta e calcula λ .
<i>GapChangeDec</i>	Comparações multitemporais de clareiras no dossel da floresta	<i>Objetos</i> binários <i>RasterLayer</i> de clareiras no dossel da floresta	<i>Objeto</i> binário <i>RasterLayer</i> de diferenças multitemporais
<i>GapSPDF</i>	Cria objetos espaciais das clareiras do dossel da floresta	<i>Objeto</i> binário <i>RasterLayer</i> de clareiras no dossel da floresta	<i>Objetos SpatialPolygon</i> de clareiras no dossel da floresta
<i>GapsSpatPattern</i>	Análise de padrões espaciais de clareiras no dossel da floresta	<i>Objetos SpatialPolygon</i> de falhas de dossel de floresta detectadas	Funções K e L de Ripley e índice de Clark - Evans

Fonte: Adaptação de Silva et al. (2019).

O pacote *ForestGapR* tem como objetivo fornecer uma ferramenta de código aberto para análise de clareiras no dossel de florestas, permitindo também o ajuste do limite da altura e o alcance das áreas que constituem uma clareira na floresta (SILVA et al., 2019) sendo o pacote executado no *software* R (R DEVELOPMENT CORE TEAM, 2019). A principal função do pacote é detectar lacunas no dossel da floresta usando CHMs derivados de ALS ou outras fontes de sensoriamento remoto e gerar estatísticas relevantes. Segundo Silva et al., (2019), as funções do pacote produzem três tipos de produtos e três tipos de análise (Figura 3).

Figura 3 - Fluxograma de produtos e análises derivados da detecção das lacunas no dossel da floresta, usando o pacote *ForestGapR*.



Fonte: Adaptada de Silva et al. (2019).

Para gerar as estatísticas foi utilizado como dado de entrada o CHM. As análises que são consideradas mais úteis para a ecologia florestal são estatísticas resumidas das clareiras *GapStats*, onde gera os valores de área das clareiras (m²), altura máxima da copa (m), altura mínima da copa (m), altura média da copa (m), desvio padrão da altura da copa (m), coeficiente de Gini da altura da copa (%) e faixa de altura do dossel (m) e através do *GapSizeFDist* gera estimativa de um expoente da lei de potência a partir de suas distribuições de frequência de tamanho.

Para a realização da dinâmica das clareiras entre os anos de 2014 e 2017, foi utilizado como limite de altura 10 m, área mínima de 1 m² e área máxima de 1000 m² (HUNTER et al., 2015). Já para a comparação dos métodos, com imagens Sentinel-2A, foi utilizado imagem do ano de 2018, como data mais próxima de 2017 em que não haviam nuvens, e com dados LiDAR utilizou o ano de 2017 e um limite de altura 10 m, área mínima de 100 m² e área máxima de 1000 m².

4 RESULTADOS E DISCUSSÃO

4.1 CARACTERIZAÇÃO DE CLAREIRAS COM DADOS SENTINEL-2A

A seguir será apresentado os dados obtidos pela classificação supervisionada das clareiras, por meio dos classificadores *Random Forest* (RF), *Support Vectors Machine* (SVM) e *Artificial Neural Network* (ANN) obtidos com o sensor Sentinel-2A.

Os valores obtidos para os índices de acurácia global e Kappa para os classificadores utilizados estão descritos na Tabela 5. Em geral, todos os algoritmos apresentaram valores superiores a 0,90 de acurácia global e valores superiores a 0,88 de Kappa. Esses resultados são considerados como excelentes ao considerar a classificação proposta por LANDIS e KOCH (1977).

Tabela 5 – Resultados da classificação supervisionada das clareiras com os algoritmos RF, SVM e ANN.

Algoritmos	Acurácia global	Kappa
RF	0,9938	0,9350
SVM	0,9937	0,9278
ANN	0,9001	0,8869

Fonte: Autora.

Ao verificar os algoritmos de aprendizado de máquina e seus respectivos ajustes, o RF foi o que apresentou os maiores valores, demonstrando uma acurácia no processo de classificação de 0,9938, seguido pela SVM (0,9937). Já, o algoritmo ANN foi o que possuiu maiores erros na classificação supervisionada das clareiras, mostrando um valor de 0,9001 de acurácia global.

Corroborando com esse resultado, Bezerra (2019), observou que a classificação pelo método RF apresentou melhores resultados na classificação de índices espectrais comparado aos outros classificadores, resultando numa acurácia de 95% e coeficiente kappa de 0,94, também utilizando imagem Sentinel-2. Em estudo desenvolvido por Cavalcanti (2016) os classificadores RF e SVM apresentaram valores próximos de acurácia, porém o algoritmo RF foi mais eficiente apresentando acurácia de 0,930, enquanto que o classificador SVM obteve acurácia de 0,915 para detecção de elementos antrópicos em aéreas da floresta amazônica.

A validação da classificação apresentada pelos algoritmos ocorreu com base nas 30 repetições realizadas na validação cruzada. A partir dos valores apresentados pelos algoritmos quanto a acurácia global gerou-se a Tabela 6, a qual demonstra a posição dos algoritmos no ranking de acordo com sua precisão.

Tabela 6 – Ranking dos algoritmos de aprendizado de máquina obtidos pela validação cruzada a partir de 30 repetições.

Repetições	RF	SVM	ANN
1	1	2	3
2	1	2	3
3	2	1	3
4	1	2	3
5	1	2	3
6	1	2	3
7	1	2	3
8	1	2	3
9	2	1	3
10	1	2	3
11	2	1	3
12	1	2	3
13	2	3	1
14	1	2	3
15	1	2	3
16	1	2	3
17	2	1	3
18	1	2	3
19	1	2	3
20	2	1	3
21	1	2	3
22	1	2	3
23	1	2	3
24	1	2	3
25	2	3	1
26	2	3	1
27	1	2	3
28	1	2	3
29	1	2	3
30	2	1	3
Média dos escores	1,3	1,9	2,8

Fonte: Autora.

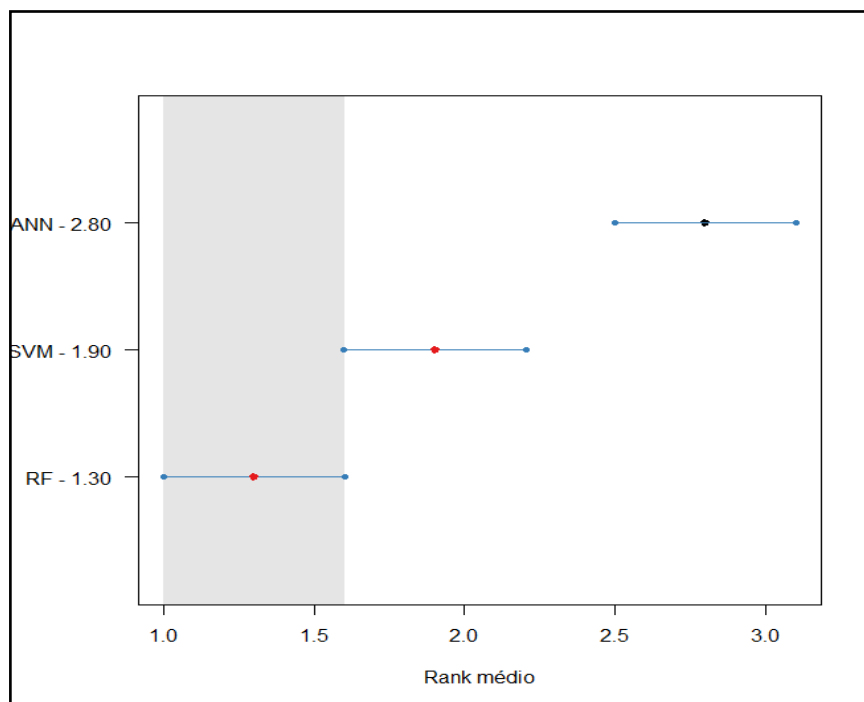
Do mesmo modo que na classificação (com um único conjunto de dados), no processo de validação o algoritmo ANN demonstrou menores valores de acurácia quando comparado aos demais algoritmos. Este algoritmo pode ter apresentado esse valor por englobar muitas soluções de acordo com os pesos e configurações iniciais do processamento (BURGES, 1998).

Destaca-se que na maioria das observações o RF foi o melhor método, tendo como média o valor de 1,3. Na sequência, o algoritmo SVM ficou na segunda posição, com os escores médios no valor de 1,9.

Para Tharwat (2018), os resultados dos algoritmos de aprendizado precisam ser avaliados e analisados cuidadosamente, de modo a viabilizar a avaliação de diferentes algoritmos de aprendizado. Assim, o teste de Friedman e Nemenyi foi aplicado a esses escores a fim de verificar a existência de diferenças significativas, especialmente entre o RF e SVM.

A distância crítica (CD - *Critical Distance*), obtida pelo teste de Friedman e Nemenyi, foi de 0,6051. Desse modo, o algoritmo RF e o algoritmo SVM apresentaram uma distância de 0,6 (1,9 - 1,3), o que indica que não existe diferença significativa entre eles, pois o valor da distância entre os algoritmos é menor que a distância crítica. Desse modo, não é possível afirmar, estatisticamente, que o RF é superior ao SVM para a identificação de clareiras com imagens Sentinel-2A, conforme demonstrado na Figura 4.

Figura 4 - Teste estatístico de Nemenyi para os algoritmos de aprendizado de máquina.



Esses resultados têm implicações importantes para a seleção de classificadores apropriados. Nesse sentido, o RF e SVM apresentam-se como os melhores classificadores para a identificação de clareiras em áreas de exploração seletiva na Amazônia.

O algoritmo RF tem sido usado por apresentar bons resultados, uma vez que consegue acomodar diferentes respostas espectro-temporais, boa velocidade de classificação e de treinamento, com poucos parâmetros definidos pelo usuário (SILVEIRA, 2018). O RF possui ainda desempenho melhor, ao mesmo tempo em que supera algumas deficiências de encapsulamento e impulso existentes em outras abordagens de aprendizado de máquina (WASKE et al., 2009).

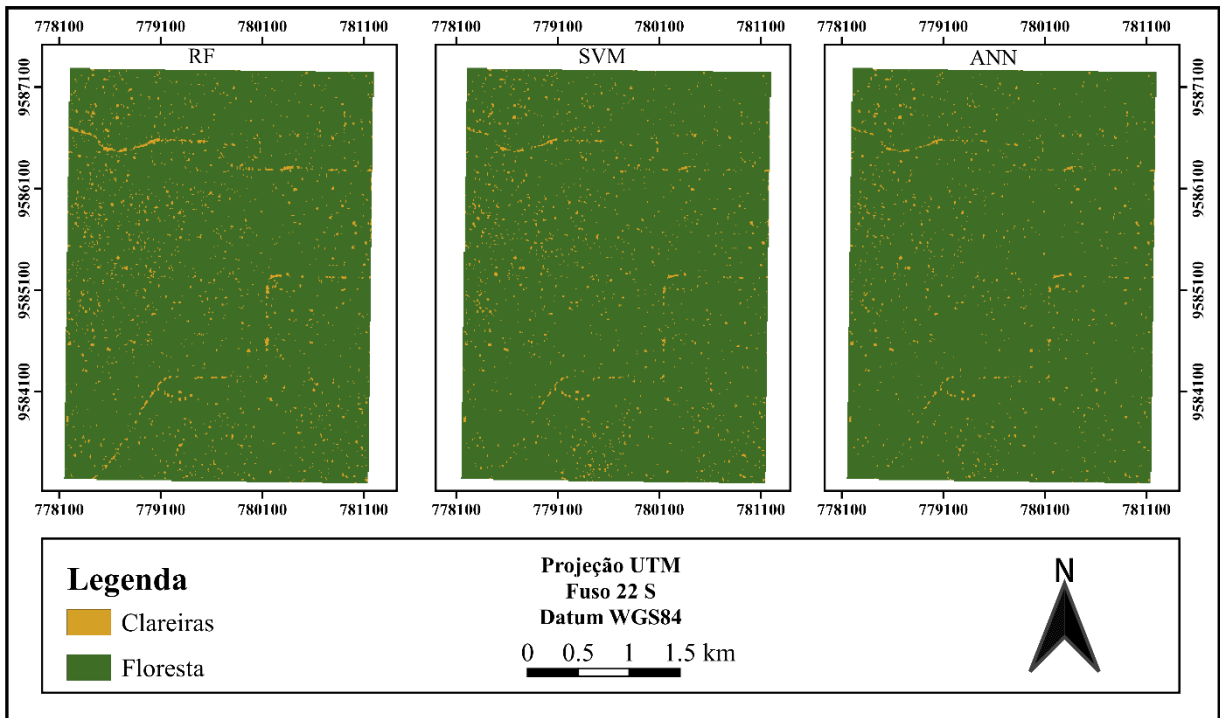
Por outro lado, existe diferença significativa entre o algoritmo RF e ANN, uma vez que seus escores apresentaram uma distância (1,5) maior que a distância crítica (0,6051) obtida pelo teste de Friedman e Nemenyi. Esse comportamento evidencia que o RF apresenta resultados superiores quando comparado ao ANN.

Destaca-se que os algoritmos RF e SVM apresentaram diferenças significativas quando comparados ao algoritmo ANN, demonstrando que podem gerar melhores resultados no processo de classificação de imagens orbitais. Do mesmo modo, no estudo desenvolvido por Pessoa et al. (2019) o RF demonstrou um bom desempenho para detecção de clareiras na Floresta Amazônica.

Em relação aos algoritmos SVM e ANN, estes exigem um maior tempo de processamento e são considerados sistemas de “caixas pretas”, devido à dificuldade na interpretação de como encontraram determinados resultados (RUIZ et al., 2014).

O mapeamento das clareiras pode ser observado na Figura 5, onde apresenta a classificação temática das áreas com floresta e clareiras na área de estudo. Classificação essa obtida a partir da aplicação dos modelos gerados pelos algoritmos utilizados, ou seja, para os algoritmos RF, SVM e ANN.

Figura 5 – Classificação das clareiras por meio do algoritmo RF, SVM e ANN com imagens Sentinel-2A.



Fonte: Autora.

A Tabela 7 mostra os valores de área total de clareira e percentagem para cada algoritmo, assim como para a floresta. Para o algoritmo RF, que apresentou melhor desempenho na classificação, apresentou uma área total de 229.402,97 m² de clareiras. Já para os algoritmos SVM e ANN, os valores foram menores na classificação da área total de clareiras.

Tabela 7 – Quantificação das áreas de clareiras e floresta na Fazenda Cauaxi, para cada algoritmo utilizado, para área de 1200 ha cada.

Algoritmo	Área total de clareias (m ²)	% de clareiras	Área total de floresta (m ²)	% de florestas
RF	229.402,97	1,88%	11.968.597,60	98,12%
SVM	164.607,16	1,35%	12.033.393,42	98,65%
ANN	131.419,89	1,08%	12.066.580,69	98,92%

Fonte: Autora.

Na Tabela 8 encontram-se os valores da matriz de confusão obtida pelo algoritmo de melhor desempenho, que correspondeu ao RF. Assim, as colunas referem-se à classe estimada

no processo de classificação e as linhas a verdade de campo, ou seja, as amostras coletas manualmente para cada classe, em que a diagonal principal representa previsões corretas e a demais indicam previsões incorretas.

Tabela 8 - Matriz de confusão para a classificação supervisionada com o uso do algoritmo RF.

	Floresta	Clareira
Floresta	192 (97,46%)	8 (3,95%)
Clareira	5 (2,54%)	195 (96,05%)
Total	197 (100%)	203 (100%)

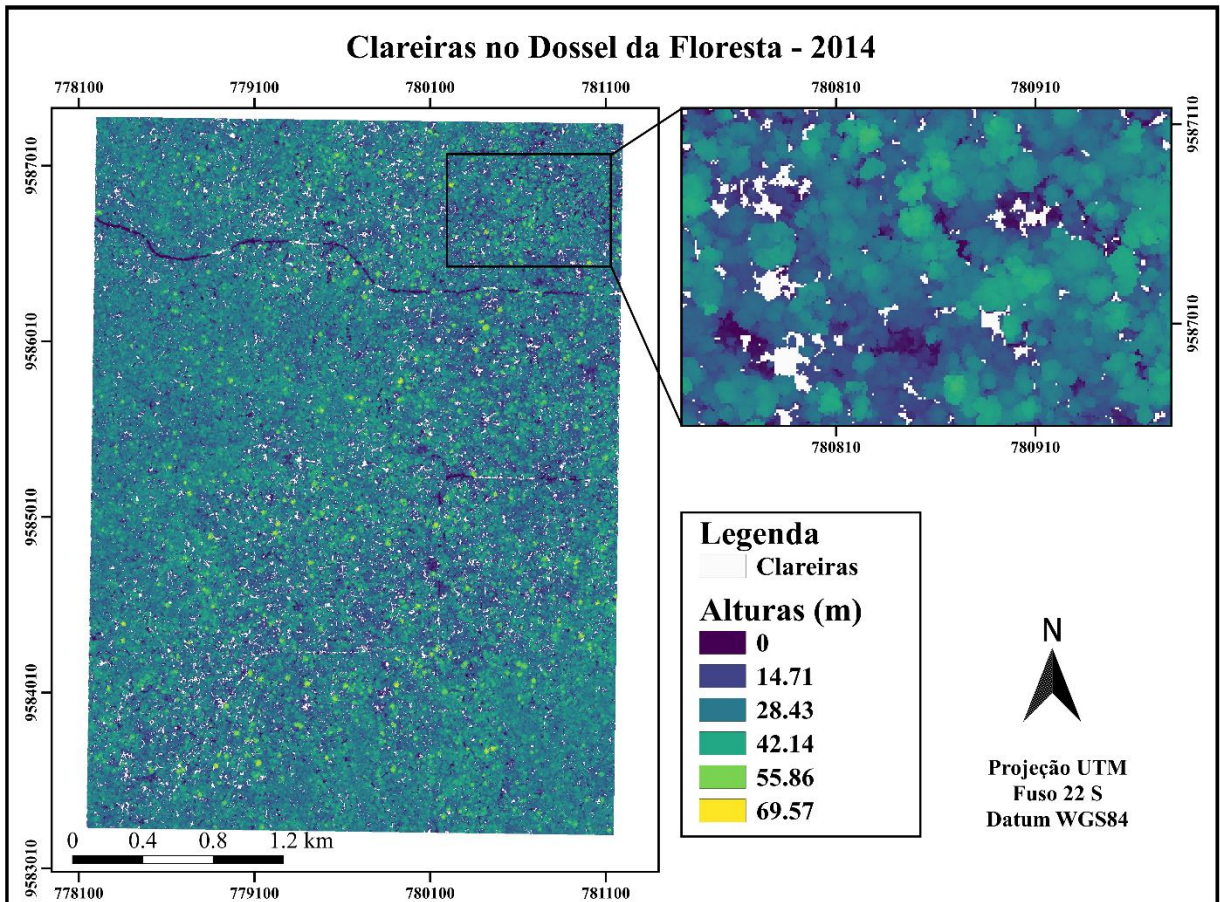
Fonte: Autora.

A partir da análise da matriz de confusão, observou-se que a identificação de clareiras e florestas por RF englobou maior erro de classificação na classe de clareiras, sendo que 96,05% dos pixels classificados corretamente, havendo confusão com floresta (3,95%), já na identificação de florestas obteve um percentual de 97,46% de acerto. A confusão gerada na classificação da classe de clareiras com a classe de florestas pode ser justificada devido ao fato de áreas sombreadas na floresta, serem classificadas como clareiras, por vezes, a resposta espectral serem similares. Para Gaiad et al. (2017), o RF possibilita uma melhor interpretação dos resultados, já que esta constrói árvores com as regras da classificação.

4.2 CARACTERIZAÇÃO DE CLAREIRAS COM DADOS LIDAR

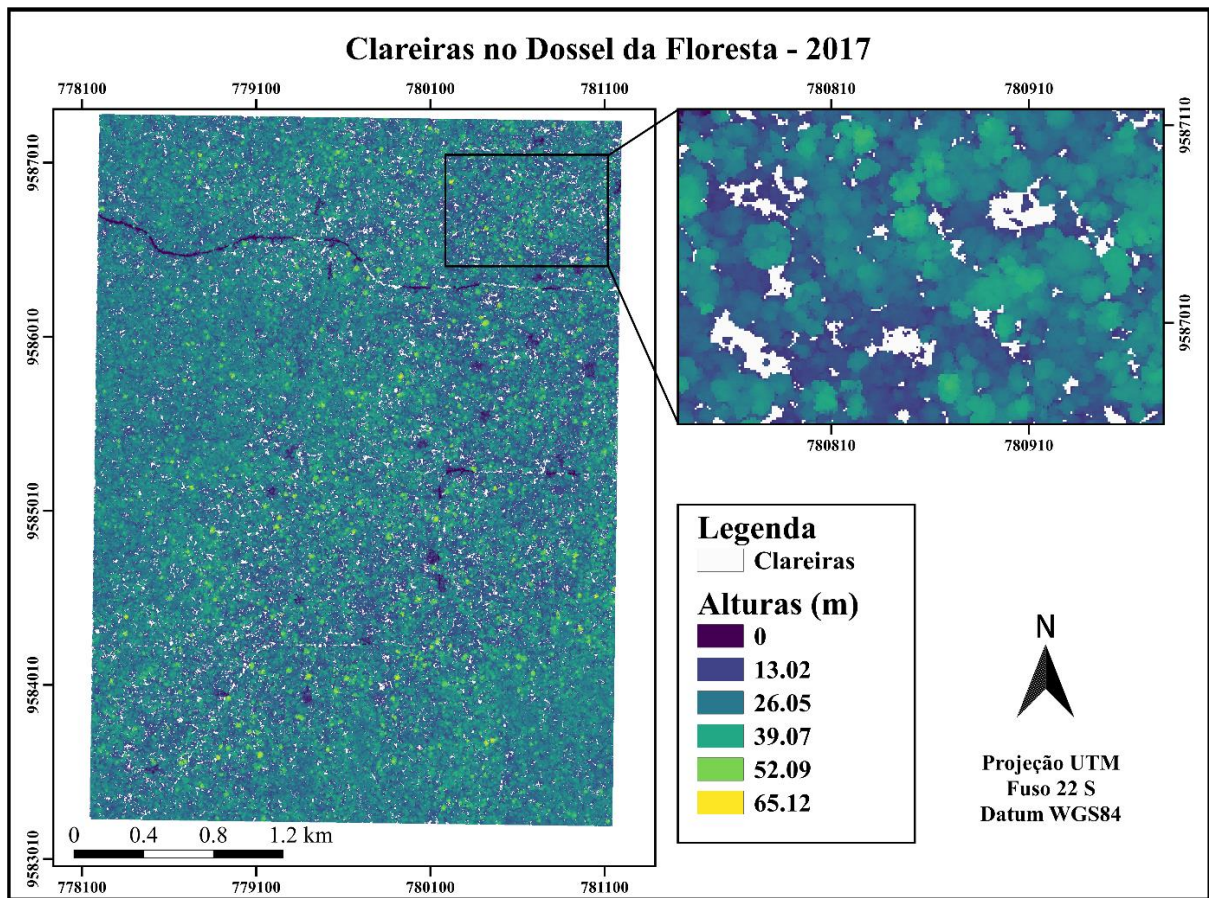
Para caracterização e identificação das clareiras no dossel da floresta, utilizou-se as funções do pacote *ForestGapR*, detalhadas na Tabela 4, por meio da varredura a laser da área de estudo gerou-se o CHM e posteriormente, as clareiras no dossel da floresta. A identificação das clareiras para os anos de 2014 e 2017 podem ser observadas na Figura 6 e figura 7.

Figura 6 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2014.



Fonte: Autora.

Figura 7 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2017.



Fonte: Autora.

As distribuições de altura do dossel mostram alturas médias de aproximadamente 35,12 m no ano de 2014 e 32,56 m para o ano de 2017. Para o ano de 2014 foi identificado 34.575,00 clareiras, com uma área total de 516.225,00 m². Já para o ano de 2017, observou um aumento de clareiras para 44.673,00, com uma área total de 643.746,00 m². Para ambos os anos o coeficiente de Gini obtiveram valores considerados baixos, o coeficiente de Gini varia de 0 a 1, são uma indicação adicional de que as atividades de extração de madeira não causaram grandes perturbações no ambiente de luz do ecossistema florestal (VALBUENA et al., 2017) (TABELA 9).

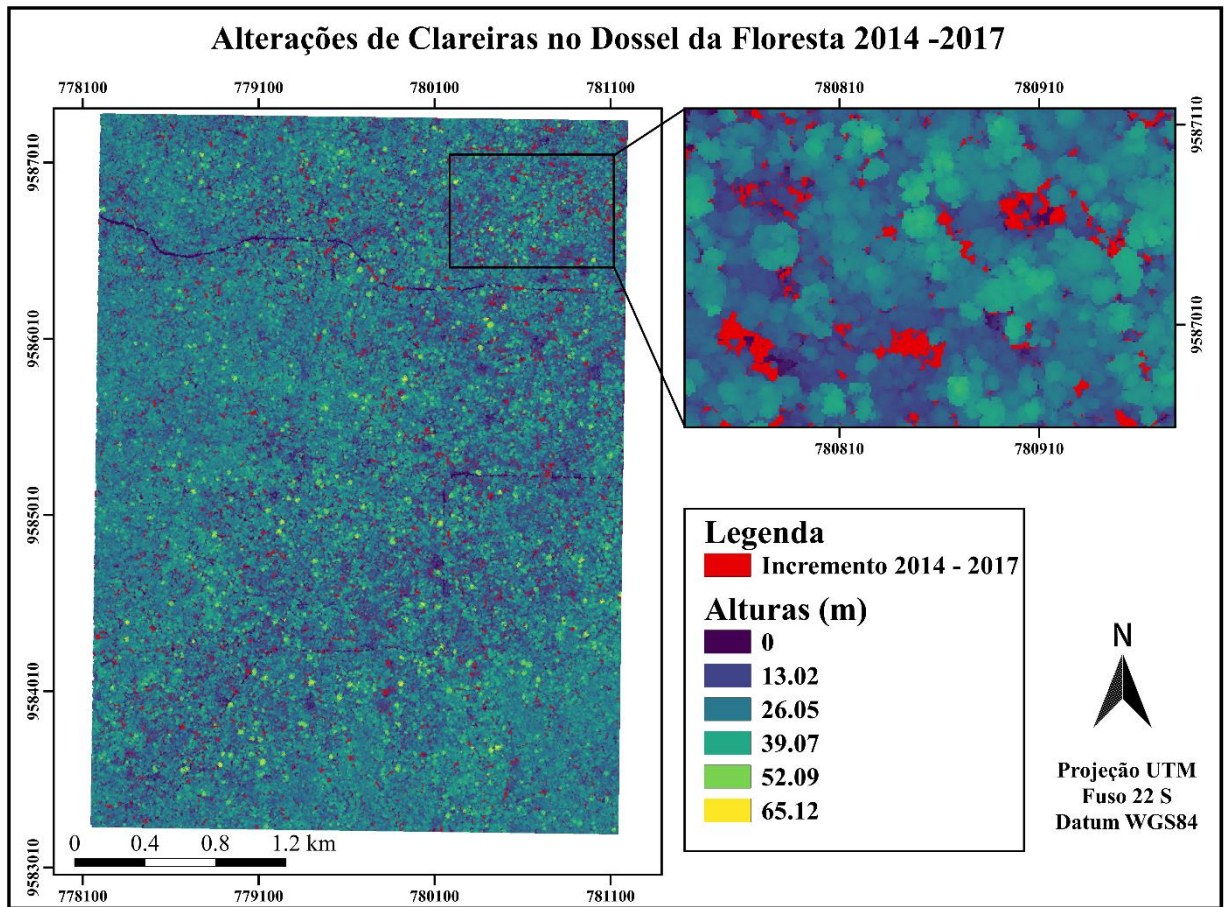
Tabela 9 - Estatísticas de clareiras no dossel da floresta na Fazenda Cauaxi nos anos de 2014 e 2017 para uma área de 1200 ha cada.

Ano	Número de clareiras	Área total de clareias (m²)	Média da área total das clareiras (m²)	% de clareiras na área de estudo	Coef. Gini (Média)
2014	34.575,00	516.225,00	14,93	4,23%	0,10
2017	44.673,00	643.746,00	14,41	5,28%	0,12

Fonte: Autora.

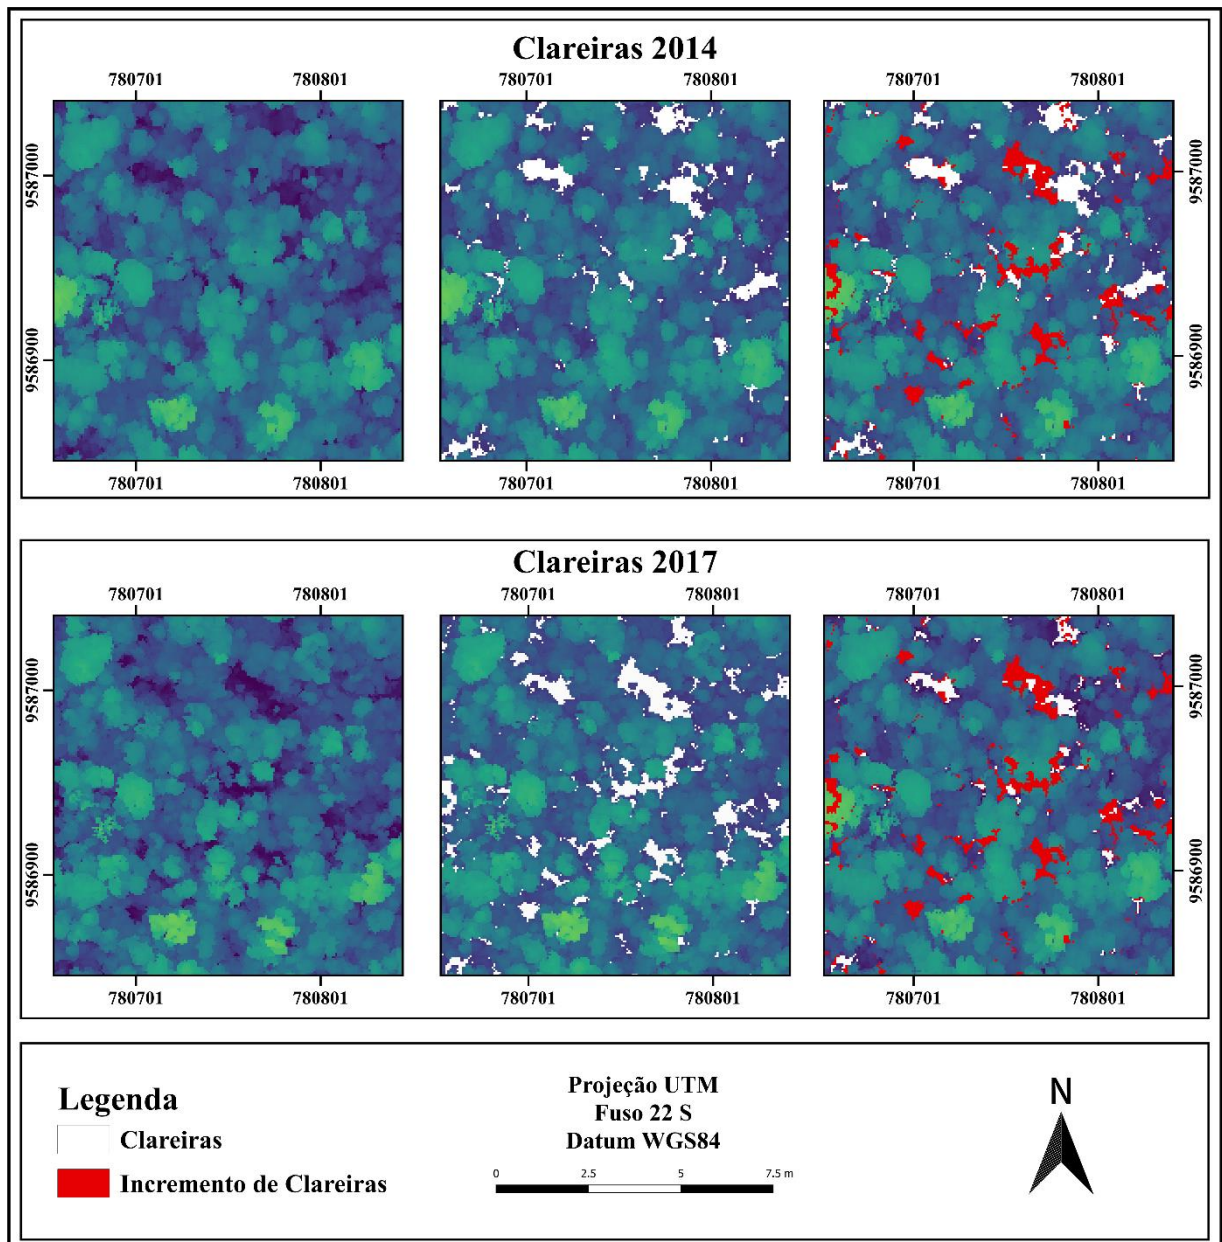
Em relação a dinâmica das clareiras no dossel da floresta para os anos de 2014 e 2017, aumentou 10.098,00 o número de clareiras em 3 anos e um aumento de 127.521,00 m² de área total. A dinâmica de alterações das clareiras para estes anos pode ser observada na Figura 8. Na Figura 9, pode-se observar melhor o padrão das clareiras antes da identificação das mesmas, de modo que as clareiras demonstradas em branco representam as do ano correspondente e as manchas em coloração avermelhada apresentam o incremento observado no período de 2014 a 2017.

Figura 8 – Dinâmica das clareiras no dossel da floresta para os anos de 2014 e 2017.



Fonte: Autora.

Figura 9 – Alterações das clareiras no dossel da floresta para os anos de 2014 e 2017.




Fonte: Autora.

Na análise da dinâmica de clareiras, o parâmetro λ da distribuição zeta das clareiras no dossel representa a relevância que o tamanho das clareias influenciam para o aumento de perturbações florestais. Quando o valor de λ for maior ou igual a 2 ($>2,0$), indicaria que a floresta é dominada por clareiras menores e tem menor ocorrência de perturbações intensas (ASNER et al., 2013 ; WHITE et al., 2008), e quando o valor de λ for menor que 2 ($\leq 2,0$), indicaria o domínio de clareiras maiores, associadas à mortalidade de grandes copas ou árvores emergentes (ASNER et al., 2013). Nas Figuras 10 e 11, podemos observar as diferenças de

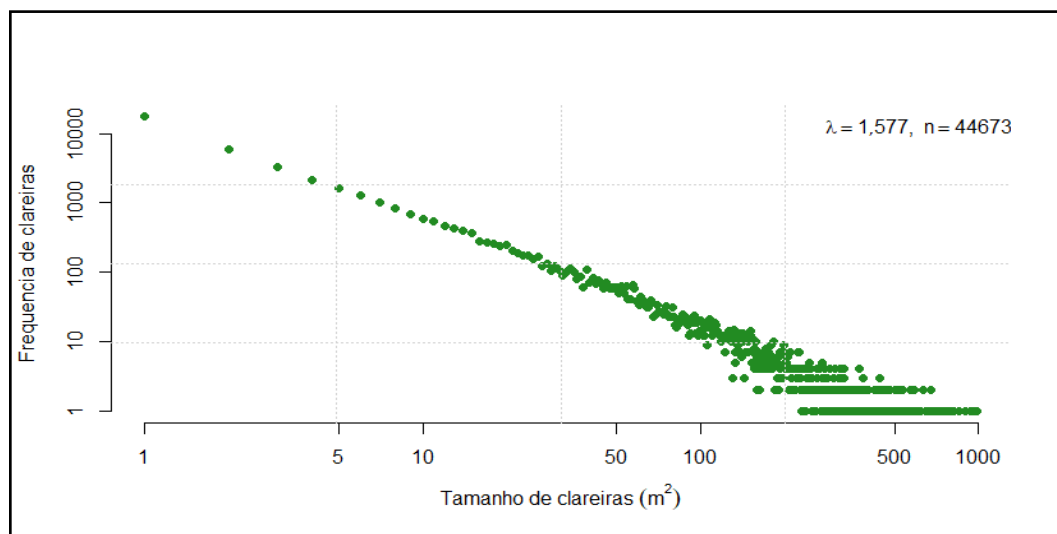
tamanho de clareira e a distribuição espacial. O valor de λ para o ano de 2014 foi de 1,571 (Figura 10), e para o ano de 2017 foi de 1,577 (Figura 11). Estes valores são semelhantes aos encontrados por Silva et al. (2019) na Estação Biológica La Selva o valor de λ foi 1,515 e na Reserva Florestal Pasoh com o valor de λ foi 1,54.

Figura 10 – Distribuição de Frequência de tamanho de clareiras no dossel da floresta para o ano de 2014.



Fonte: Autora.

Figura 11 – Distribuição de Frequência de tamanho de clareiras no dossel da floresta para o ano de 2017.



Fonte: Autora.

Analisando os gráficos, observou-se que a maioria das clareiras na área de estudo para os anos de 2014 e 2017, apresentam tamanhos de 1 m² a 15 m². Já as clareiras de 20 m² a 1000 m² aparecem com menor frequência, porém o dossel da floresta é dominado por clareiras maiores devido ao λ ser menor que 2.

As Tabelas 10 e 11 demonstram as classes de altura das clareiras, no intervalo de 0 m até o limite de altura de 10 m, bem como o número de clareiras e a área em m². Com elas explica-se a distribuição de frequência de tamanho nas clareiras do dossel da floresta.

Para o ano de 2014, o número de clareiras foi maior na faixa de altura 0 a 1 m, com 18.018,00 clareiras e o total da área dela é 25.264,00 m², já na faixa de 9,01 a 10,00 m, observou-se 1.988,00 clareiras com um total de 220.707,00 m² de área (Tabela 10). No ano de 2017, o número de clareiras também foi maior na faixa de altura 0 a 1 m, com 22.704,00 e o total da área dessa classe foi 30.998,00 m². Por outro lado, a faixa compreendida pelo intervalo de 9,01 a 10,00 m demonstrou englobar 4.115,00 clareiras com um total de área de 365.765,00 m² (Tabela 11). Estes valores justificaram o λ menor que 2, sendo a área de estudo dominada por clareiras maiores.

Tabela 10 – Numero de clareiras e área (m²) no dossel da floresta 2014.

Faixa de alturas das Clareiras (m)	Número de clareiras	Área (m²)
0,00 - 1,00	18.018,00	25.264,00
1,01 - 2,00	2.647,00	12.588,00
2,01 - 3,00	2.103,00	14.738,00
3,01 - 4,00	1.943,00	19.565,00
4,01 - 5,00	1.681,00	23.571,00
5,01 - 6,00	1.628,00	31.156,00
6,01 - 7,00	1.540,00	39.966,00
7,01 - 8,00	1.533,00	53.247,00
8,01 - 9,00	1.494,00	75.423,00
9,01 - 10,00	1.988,00	220.707,00
Total	34.575,00	516.225,00

Fonte: Autora.

Tabela 11 – Numero de clareiras e área (m²) no dossel da floresta 2017.

Faixa de alturas das Clareiras (m)	Número de clareiras	Área (m²)
0,00 - 1,00	22.704,00	30.998,00
1,01 - 2,00	3.211,00	13.257,00
2,01 - 3,00	2.528,00	14.917,00
3,01 - 4,00	2.307,00	19.538,00
4,01 - 5,00	2.069,00	22.452,00
5,01 - 6,00	1.912,00	27.651,00
6,01 - 7,00	1.797,00	34.911,00
7,01 - 8,00	1.812,00	44.910,00
8,01 - 9,00	2.218,00	69.347,00
9,01 - 10,00	4.115,00	365.765,00
Total	44.673,00	643.746,00

Fonte: Autora.

As clareiras maiores nessa área, explica-se por sua maioria pela ação antrópica, sugerindo a atividade de extração seletiva de madeira na floresta, mas também podem ter ocorrido por causas naturais. Segundo Laurance et al. (2015), mostraram aumento da mortalidade em até 100 m de borda da floresta e sugeriram que isso pode ser devido ao aumento da turbulência do vento e mudanças no microclima local. Enquanto as lacunas naturais dentro da matriz florestal podem não sofrer aumento da turbulência do vento, ocorrem mudanças no microclima local (RAY et al., 2005).

Segundo Lima (2005), as clareiras podem ser formadas devido à queda de galhos, morte de árvores em pé que vão tendo suas copas fragmentadas e até mesmo desenraizamento das árvores, de qualquer forma, causam danos ao sub-bosque, variando a intensidade do dano. As clareiras também podem ser abertas a partir de fenômenos meteorológicos, ataques de insetos e doenças. Grandes clareiras são formadas quando o dossel é composto de grandes árvores, as quais são capazes de produzir grandes aberturas quando caem (MARTINS e RODRIGUES, 2002; MCCARTHY 2001).

Para Andersen et al. (2014), o LiDAR aerotransportado demonstrou o potencial para quantificar mudanças estruturais, a nível de dossel, e exploração seletiva de madeira em florestas tropicais, inclusive em exploração com intensidade muito baixa. A identificação de clareiras e a partir de dados LiDAR pode ser uma aliada no monitoramento do desmatamento e extração ilegal de madeira.

4.3 COMPARAÇÃO DOS MÉTODOS

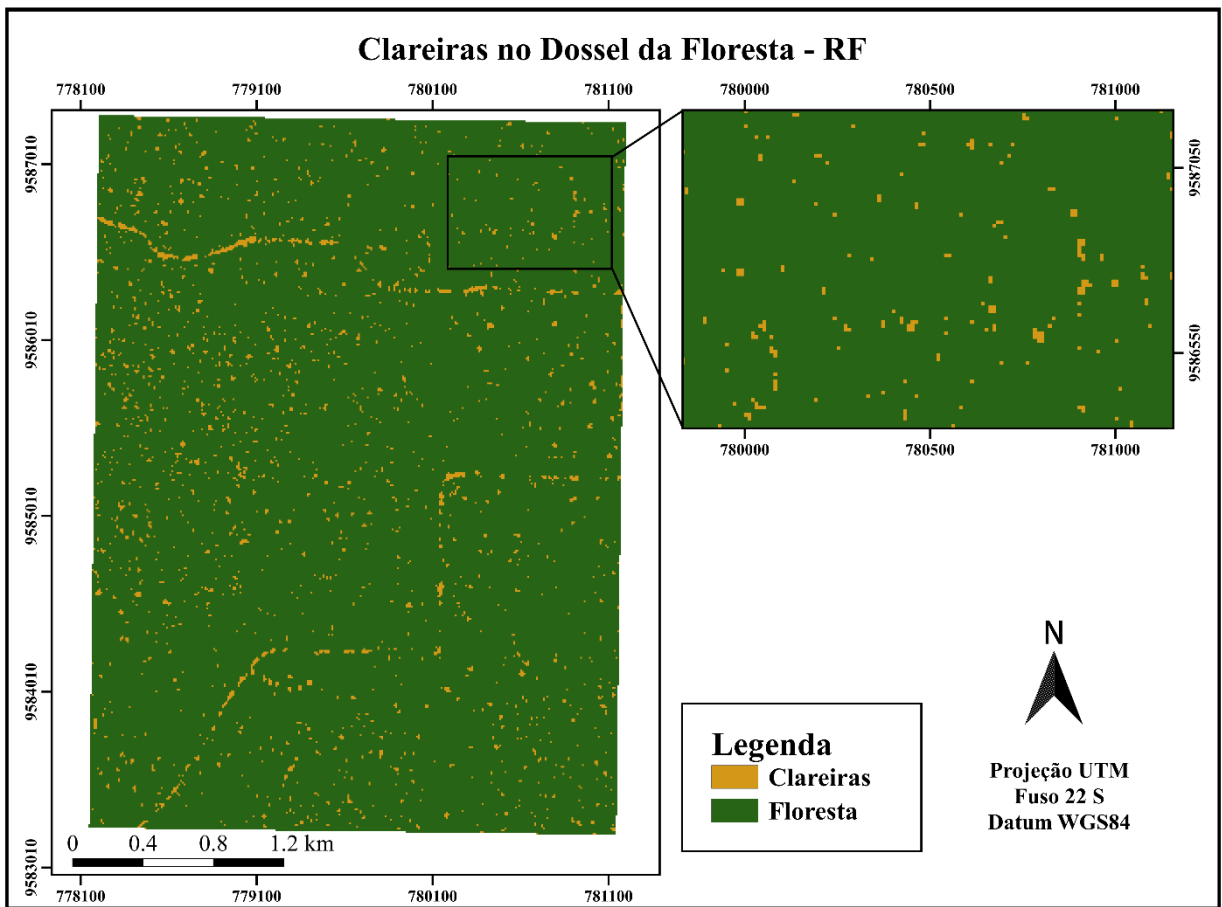
Para a comparação dos métodos foi realizada a análise entre a imagem do Sentinel-2A classificada com RF, uma vez que apresentou melhor desempenho, e a classificação a partir de dados LiDAR com área mínima de 100 m² e área máxima de 1000 m² para as clareiras. Na Tabela 12, podemos observar os valores de área de clareiras e floresta, podem ser observadas na Figura 6 e figura 7. Para a imagem Sentinel-2A foi identificada 229.402,97 m² de clareiras, enquanto que com dados LiDAR foi detectado 301.090,00 m² de clareiras, uma diferença de 71.687,03 m² de clareiras entre os métodos.

Tabela 12 – Comparação entre imagem Sentinel-2A e dados LiDAR, na identificação de clareiras na Fazenda Cauaxi no ano de 2017 para uma área de 1200 ha cada.

	Área total de clareias (m²)	% de clareiras na área de estudo	Área total de floresta (m²)	% de floresta na área de estudo
Sentinel-2A	229.402,97	1,88%	11.968.597,60	98,12%
LiDAR	301.090,00	2,47%	11.896.910,58	97,53%

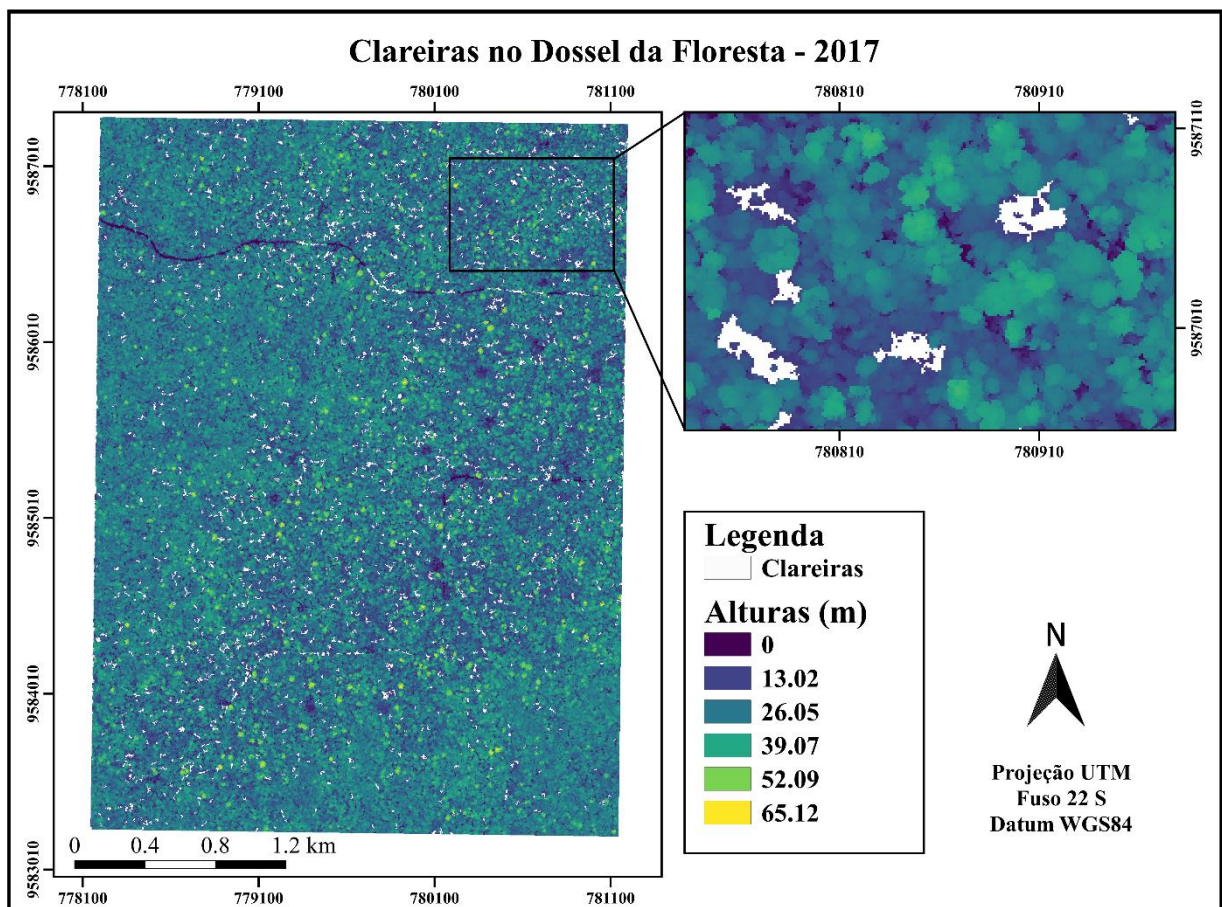
Fonte: Autora.

Figura 12 – Identificação de clareiras com imagem Sentinel-2A por meio do algoritmo *Random Forest*.



Fonte: Autora.

Figura 13 – Identificação das Clareiras no dossel da floresta com dados LiDAR para o ano de 2017, com área mínima de 100 m².



Fonte: Autora.

Em comparação, os dois métodos apresentaram percentuais próximos, portanto, os dados Sentinel podem vir a ser utilizados para análise de clareiras, pois os resultados quando comparados aos dados LiDAR foram promissores, porém vale destacar que os dados LiDAR permitem maior precisão devido estes disponibilizarem a elevação da vegetação não havendo interferência do sombreamento da floresta como acontece nas imagens orbitais. Dessa forma, os dados lidar foram utilizados para realizar a dinâmica de clareiras na área de estudo

Por outro lado, os sensores ópticos multiespectrais passivos quando aplicados na caracterização da estrutura vertical da vegetação podem apresentar limitações quando comparados com os sensores ativos LiDAR (Light Detection And Ranging) (SILVEIRA, 2018). Os instrumentos LiDAR podem quantificar as dimensões verticais e volumétricas da estrutura da vegetação (BERGEN et al., 2009). Como resultado deste poder de quantificação, diversos trabalhos surgem todos os anos, com novas aplicações para os dados LiDAR, como,

por exemplo, o mapeamento e a caracterização de espécies arbustivas (MUNDT et al., 2006; VIERLING et al., 2012); a caracterização de habitats para vida selvagem (GARCIA-FECED et al., 2011); e o cálculo da biomassa acima do solo (HICKEY et al., 2018).

5 CONCLUSÃO

A partir do uso de inteligência artificial foi possível a identificação de clareiras através de imagens de média resolução espacial, do sensor MSI/Sentinel-2A. Para esse processo, o algoritmo *RF* apresentou melhores resultados, demonstrando ser mais adequado para a identificação de clareiras em áreas de extração seletiva no bioma Amazônia.

A identificação e análise da dinâmica clareiras no período de 2014 a 2017 por meio de dados LiDAR, foi possível a realização por meio do pacote *ForestGapR*. Observou-se o aumento do número de clareiras no ano de 2017, englobando 5,28% da área total no final do monitoramento, com dominância de clareiras maiores, devido a extração seletiva de madeira que ocorrem na floresta.

Ao relacionar os percentuais de clareiras identificadas com o uso de imagens MSI/Sentinel-2A aos detectados com dados LiDAR em condições similares, observou-se o potencial das imagens de média resolução, quando associadas a técnicas de inteligência artificial, na identificação de distúrbios na floresta. Assim, o uso de produtos Sentinel associados as técnicas de processamento complexas permitem a obtenção de parâmetros da cobertura florestal, inclusive para a região Amazônica.

E por fim, esse estudo demonstra a importância da identificação e análise de clareiras, através das aplicações de sensoriamento remoto, para o monitoramento do desmatamento e retirada ilegal de madeira na floresta, possibilitando um manejo sustentável na Amazônia brasileira.

REFERÊNCIAS BIBLIOGRÁFICAS

AB'SABER, A. N. (1997). O caráter diferencial das diretrizes para uso e preservação da natureza, a nível regional no Brasil.

ADREOLA, R. **Support Vector Machines na Classificação de Imagens Hiperespectrais**, 130f. Dissertação de Mestrado, Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

ALVARES, C. A et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v.22, p. 711-728. 2013.

ANDERSEN, H. E. et al. Monitoring selective logging in western Amazonia with repeat LiDAR flights. **Remote Sensing of Environment**, New York, v. 151, p. 157-165, 2014.

ARRIAGA, L. 1988. **Gap dynamics of a tropical cloud forest in northeastern Mexico**. *Biotropica* 20, 3: 178-184.

ASNER, G. P. et al. **A universal airborne LiDAR approach for tropical forest carbon mapping**. *Oecologia*, Berlin, v. 168, n. 4, p. 1147-1160, 2011.

ASNER, G. P., KELLNER, J. R., KENNEDY-BOWDOIN, T., KNAPP, D. E., ANDERSON, C., & MARTIN, R. E. (2013). **Forest Canopy Gap Distributions in the Southern Peruvian Amazon**. *PLoS ONE*, 4, e60875. <https://doi.org/10.1371/journal.pone.0060875>

BARTON, A.M., FETCHER, N. & REDHEAD, S. 1989. **The relationship between treefall gap size and light flux in a Neotropical rain forest in Costa Rica**. *Journal of Tropical Ecology* 5: 437-439.

BERGEN, K. M.; GOETZ, S. J.; DUBAYAH, R. O.; HENEBRY, G. M.; HUNSAKER, C. T.; IMHOFF, M. L.; NELSON, R. F.; PARKER, G. G.; RADELOFF, V. C. Remote sensing of vegetation 3-D structure for biodiversity and habitat: review and implications for lidar and radar spaceborne missions. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. 4, p. 1–13, 2009.

BERRY, M.; LINOFF, G. **Mastering Data Mining: The Art and Science of Customer Relationship Management**. 1st. ed. New York, NY, USA: John Wiley & Sons, Inc., 1999. ISBN 978-0-471-33123-0.

BEZERRA, U. A., **Índices espectrais utilizando os sensores OLI/Landsat-8 e MSI/Sentinel-2, na bacia hidrográfica do rio Moxotó-PE**. 2019. 112 f. Dissertação. Programa de Pós-Graduação em Engenharia Cartográfica e de Agrimensura. Universidade Federal de Pernambuco. Recife, PE, 2019.

BISHOP, C. M. **“Pattern Recognition and Machine Learning (Information Science and Statistics)”**. Springer-Verlag New York, Inc., 2006.

BISI, B. S.; NETO, A. B.; BONINI, C. S. B. Redes neurais artificiais: utilização do algoritmo retropropagação para classificação de grupos em biosistemas, parte 2: aplicação. 2015. **Fórum Ambiental da Alta Paulista**. v. 11, n. 02, 2015.

BIVAND, R.; KEITT, T.; ROWLINGSON, B. **rgdal**: Bindings for the Geospatial Data Abstraction Library. R package version 1.2-6. Disponível em: '<https://CRAN.R-project.org/package=rgdal>'. Acesso em 21 de dez. 2018.

BRAGA, A. P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: LTC; 2000.

BRASIL. Departamento Nacional de Produção Mineral. **Levantamento de recursos minerais**. Folhas AS.23 – São Luís e parte da folha AS.24 – Fortaleza. Geologia, geomorfologia, solos, vegetação e uso potencial da terra. Rio de Janeiro, Ministério de Minas e Energia. 1973. V3.

BRASIL. Ministério do Meio Ambiente – MMA & Serviço Florestal Brasileiro – SFB. **Florestas do Brasil em resumo** (Relatório). Dados de 2007-2012. Brasília, DF: MMA e SFB, 2013, p. 50.

BREIMAN, L. (1996). **Bagging predictors**. Machine Learning, 24:123–140.

BREIMAN, L. **Random Forests**. Machine Learning, v. 45, n. 1, p. 5-32, 2001.

BROKAW, N. V. L. **The definition of treefall gap and its effect on measures of forest dynamics**. Biotropica. Lawrence, v. 14, n. 2, p. 158-160, 1982b.

BURGES, C. J. C. **A Tutorial on Support Vector Machines for Pattern Recognition**. Data Mining and Knowledge Discovery, 2, p.121-167, 1998. Disponível em: <http://dx.doi.org/10.1023/A:1009715923555>>. doi: 10.1023/A:1009715923555

BURGES, C. J. C. **Atutorial on support vector machines for pattern recognition**. 1998.

CARDONA, M. A. Q. **Efeitos do manejo florestal na estrutura da avifauna na floresta Amazônica de Paragominas (Pará)**. 2012. 108 f. Tese (Doutorado em Recursos Florestais) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2012.

CARNEIRO, F. M. (2018). **Sensores de dossel no monitoramento da variabilidade das culturas da soja e do amendoim**. Doutorado. Universidade Estadual Paulista. Faculdade de Ciências Agrárias e Veterinárias. 2018.

CARTER, J.; SCHMID, K.; WATERS, K.; BETZHOLD, L.; HADLEY, B.; MATAOSKY, R.; HALLERAN, J.; CENTER, N. C. S. **An Introduction to Lidar Technology, Data, and Applications**. [S.l.: s.n.], 2012.

CAVALCANTI, L. C. A. M. **Detecção de elementos antrópicos em imagens aéreas da floresta amazônica**. Dissertação (Mestrado em Informática) - Universidade Federal do Amazonas. 2016.

CENTENO, J. S. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Ed. UFPR, 2003. 210 p.

CHAZDON, R. L. **Renascimento de florestas: regeneração da era do desmatamento**. Tradução de AMAZONAS, N.; CESAR, R. São Paulo: Oficina de Textos. 2016. 430 p. Original em Inglês.

CIKEL BRASIL VERDE MADEIRAS LTD. – COMPLEXO RIO CAPIM. **Plano de manejo florestal sustentável de uso múltiplo empresarial**. Belem, 2010. 69 p.

CORTES, C.; VAPNIK, V.; SAITTA, L. Support-Vector Networks Editor. Machine Learning. **Kluwer Academic Publishers**, 1995. Disponível em <<https://link.springer.com/content/pdf/10.1007%2FBF00994018.pdf>>. Acesso em: 20 out. 2019.

D'OLIVEIRA, M. V. N. et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning LiDAR in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, New York, v. 124, p. 479-491, 2012.

DAVISON, C. P. **Estrutura de clareiras e a presença de bambus em um fragmento de Floresta Atlantica, SP, Brasil**. 2009. 98 f. Dissertação. Instituto de Botânica da Secretaria do Meio Ambiente, São Paulo, SP, 2009

DING, C. H.; DUBCHAK, I. **Multi-class protein fold recognition using support vector machines and neural networks**. *Bioinformatics*, v. 17, n. 4, p. 349–358, 2001.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel2: ESA's optical high resolution mission for GMES operational services. **Remote sensing of Environment**, v. 120, n. sp-1322/2, p. 25–36, maio 2012.

DUBAYAH, R.; KNOX, R.; HOFTON, M.; BLAIR, J. B.; DRAKE, J. Land surface characterization using lidar remote sensing. **Spatial information for land use management**, International Publishers Direct Singapore, p. 25–38, 2000.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2º Edição. Wiley, 2001. ISBN1:0471056693.

DUPUY, J.M. & CHAZDON, R.L. 2006. **Effects of vegetation cover on seedling and sapling dynamics in secondary tropical wet forests in Costa Rica**. *Journal of Tropical Ecology* 22: 65-76.

ELLI, P. et al. Mapping selective logging impacts in Borneo with GPS and airborne LiDAR. **Forest Ecology and Management**, Amsterdam, v. 365, p. 184-196, 2016.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Paisagens Sustentáveis**. Brasília, 2016. Disponível em: < <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3862/paisagens-sustentaveis>>. Acessado em: 15 nov. 2019.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Programa internacional reúne cientistas em evento sobre uso de dados LiDAR e inventários florestais**. Brasília, 2014. Disponível em: < <https://www.embrapa.br/busca-de-noticias/-/noticia/1671905/programa-internacional-reune-cientistas-em-evento-sobre-uso-de-dados-lidar-e-inventarios-florestais>>. Acessado em: 21 out. 2019.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **WebGIS Paisagens Sustentáveis Brasil**. Brasília, 2017. Disponível em: <<http://www.paisagenslidar.cnptia.embrapa.br/webgis/>>. Acessado em: 15 nov. 2019.

ENGESAT. **Sentinel-2**. 2016. Disponível em: <<http://www.engesat.com.br/sentinel-2/>>. Acesso em: 24 ago. 2019.

ESA - European Space Agency. 2013. “**Sentinel-1 User Handbook**”. Disponível em: <https://sentinel.esa.int/documents/247904/685163/Sentinel1_User_Handbook/06fa0b55-9eca-47ff-a45f-242012951564>. Acesso em: 18 ago. 2019.

EUROPEAN SPACE AGENCY (2010). GMES Sentinel-2 Requires Document <<<https://tinyurl.com/y8s4es6f>>>. Acesso em: 22 nov 2019.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2011.

FEARNSIDE, P. M. **Deforestation in Amazonia Encyclopedia of Earth ed CJ Cleveland (Washington, DC: Environmental Information Coalition, National Council of Science and the Environment)**. pp. 395-400. 2007.

FEARNSIDE, P. M. Deforestation in Brazilian Amazonia: history, rates, and consequences. **Conservation biology**, v. 19, n. 3, p. 680-688, 2005.

FEARNSIDE, P.M. Brazil’s Amazonian forest carbon: the key to Southern Amazonia’s significance for global climate. **Reg Environ Change**. v. 18, n. 1, 2016.

FERNANDES, G. A. **Utilização de imagens Landsat para identificação da área de vegetação natural alteradas pela ação antrópica na zona de amortecimento da Floresta 107 Nacional do Jamari**. Brasília. Monografia de Conclusão Pós-Graduação em Geoprocessamento, IG/UNB, 2007.

FIGUEIREDO, E. O.; BRAZ, E. M.; OLIVEIRA, M. V. N. d’. **Manejo de precisão em florestas tropicais: modelo digital de exploração florestal**. Rio Branco: Embrapa Acre, 2007. 183 p.

FIGUEIREDO, E. O.; OLIVEIRA, M. V. N. D’.; FEARNSIDE, P. M.; PAPA, D. A. Modelos para estimativa de volume de árvores individuais pela morfometria da copa obtida com lidar. **CERNE**. v. 20, n. 4, p. 621-628, 2014.

FLOOD, N. **Comparing Sentinel-2A and Landsat 7 and 8 Using Surface Reflectance over Australia**. Remote Sensing. v. 9, n. 7, p.659, 2017.

GAIAD, N. P. et al. **Uso e cobertura da terra apoiados em algoritmos baseados em aprendizado de máquina: o caso de Mariana – MG**. Enciclopédia Biosfera, v. 14, n. 25, p. 1212-1220, 2017.

GAMA, J.; FACELI, K.; LORENA, A.; DE CARVALHO, A. “**Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**”. Grupo Gen - LTC, 2011.

GARCIA-FECED, C.; TEMPEL, D. J.; KELLY, M. Lidar as a tool to characterize wildlife habitat: California spotted owl nesting habitat as an example. **Journal of Forestry**, p. 436–443, Dec. 2011.

GIANNICO, V. et al. **Estimating stand volume and above-ground biomass of urban forests using LiDAR**. Remote Sensing, Basel, v. 8, p. 14, 2016.

GIONGO, M.; KOEHLER, H.; MACHADO, S.; KIRCHNER, F.; MARCHETTI, M. Lidar: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231, 2010. ISSN 1983-2605.

HASSEBO, Y. Active remote sensing: Lidar snr improvements. **REMOTE SENSING—ADVANCED TECHNIQUES AND PLATFORMS**, p. 313, 2012.

HAYKIN, S. **Neural networks: A comprehensive foundation**. Prentice Hall. Learning from imbalanced data, 1999.

HAYKIN, S. **Redes Neurais: Princípios e prática**, Bookman, 2001.

HICKEY, S. M.; CALLOW, N. J.; PHINN, S.; LOVELOCK, C. E.; DUARTE, C. M. Spatial complexities in aboveground carbon stocks of a semi-arid mangrove community: a remote sensing height-biomass-carbon approach. **Estuarine, Coastal and Shelf Science**, v. 200, p. 194–201, 2018.

HIJMANS, R. J. **Raster**: Geographic data analysis and modeling. R package version 2.5-8. Disponível em: ‘<https://CRAN.R-project.org/package=raster>’. Acesso em 21 de dez. 2018.

HIRAI, E. H. et al. Efeito da exploração florestal de impacto reduzido sobre a regeneração natural em uma floresta densa de terra firme no município de Paragominas na Amazônia brasileira. **Sci. For.** v. 40, n. 95, p. 306 – 315, 2012.

HOWE, H.F. 1990. **Habitat implications of gap geometry in tropical forests**. *Oikos* 59, 1: 141-144.

HUNTER, M. O., KELLER, M., MORTON, D., COOK, B., LEFSKY, M., DUCEY, M., SCHIETTI, J. (2015). **Structural dynamics of tropical moist forest gaps**. *PLoS ONE*, 10(7), e0132144. <https://doi.org/10.1371/journal.pone.0132144>.

INPE. Instituto Nacional de Pesquisas Espaciais. **Sistema de Detecção do Desmatamento em Tempo Real na Amazônia – DETER: aspectos gerais, Metodológicos e plano de desenvolvimento**. Monitoramento da cobertura florestal da Amazônia por satélites. São José dos Campos: INPE, 2008, p. 16.

JANS, L., POORTER, L., VAN ROMPAEY, R.S.A.R. & BONGERS, F. 1993. **Gaps and forest zones in Tropical Moist Forest in Ivory Coast**. *Biotropica* 25, 3: 258-269.

JARDIM FCS, SENA JRC & MIRANDA IS (2008). Dinâmica e estrutura da vegetação com DAP e” 5 cm em torno de clareiras da exploração florestal seletiva, em Moju Pará. **Revista de Ciências Agrárias**, 49:41-52.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 672 p.

KEEFE, K. et al. Enrichment planting as a silvicultural option in the eastern Amazon: Case study of fazenda Cauaxi. **Forest Ecology and Management**, v. 258, n. 9, p. 1950–1959, 2009.

- KRAUS, K.; PFEIFER, N. **Determination of terrain models in wooded areas with airborne laser scanner data.** ISPRS Journal of Photogrammetry and Remote Sensing, v. 53, n. 4, p.193-203, Aug 1998. ISSN 0924- 2716.
- KUHN, M. **CARET: Classification and Regression Training.** R package version 6.0-71. Disponível em: '<https://CRAN.R-project.org/package=caret>'. Acesso em 5 de dez. 2019.
- LANDIS, J.; KOCH, G. G. **The measurements of agreement for categorical data.** Biometrics, v.33, n.3, p.159-179, 1977. Disponível em: < <http://dx.doi.org/10.2307/2529310>>. doi: 10.2307/2529310
- LARY, D. J. et al. Geoscience Frontiers Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, 2016. v. 7, n. 1, p 1-18.
- LAURANCE WF, FERREIRA LV, MERONA JMR-D, LAURANCE SG. 2015. Rain Forest Fragmentation and the Dynamics of Amazonian Tree Communities. **Ecology** 1988;79: 2032–2040.
- LEFSKY, M. A.; COHEN, W. B.; PARKER, G. G.; HARDING, D. J. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. **BioScience**, v. 52, n. 1, p. 19–30, 2002. Disponível em: <<http://bioscience.oxfordjournals.org/content/52/1/19.short>>. Acesso em: 18 ago. 2019.
- LIAW, A. **Breiman and Cutler's Random Forests for Classification and Regression.** R package version 4.6-14. Disponível em: < <https://cran.r-project.org/web/packages/randomForest/randomForest.pdf>>. Acesso em 5 de dez. de 2019.
- LIMA, R. A. F. Gap size measurement: The proposal of a new field method. **Forest Ecology and Management**. v. 214, p. 413 – 419, 2005.
- LIMA, R.A.F. 2005a. **Estrutura e regeneração de clareiras em Florestas Pluviais Tropicais.** Revista Brasileira de Botânica 28, 4: 651-670
- LIN, Y., HULTING, M.L. & AUGSPURGER, C.K. 2004. **Causes of spatial patterns of dead trees in forest fragments in Illinois.** Plant Ecology 170: 15-27.
- LOPES, T. D.; GOEDTEL, A.; PALACIOS, R. H. C.; GODOY, W. F. **Aplicação do algoritmo Random Forest como classificador de padrões de falhas em rolamentos de motores de indução.** 2017. XIII Simpósio Brasileiro de Automação Inteligente. Porto Alegre, RS.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. d. **Uma Introdução às Support Vector Machines.** *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. ISSN 21752745. Disponível em: <http://www.seer.ufrgs.br/index.php/rita/article/view/rita_v14_n2_p43-67>.
- LU, D., LI, G., MORAN, E., & HETRICK, S. **Spatiotemporal analysis of land-use and land-cover change in the Brazilian Amazon.** *International journal of remote sensing*, v. 34, n. 16, p. 5953-5978, 2013.

MAPBIOMAS (2015). Projeto de mapeamento anual da cobertura e uso do solo no Brasil. **Projeto MapBiomass** – coleção 3.1 da série anual de mapas de cobertura e uso do solo do Brasil. Disponível em: <http://mapbiomas.org>. Acesso em 2020.

MARTÍNEZ-RAMOS, M., ALVAREZ-BUYLLA, E., SARUKHÁN, J. & PIÑERO, D. 1988. **Treefall age determination and gap dynamics in a tropical forest**. *Journal of Ecology* 76: 700-716.

MARTINS, S. V.; RODRIGUES, R. R. Gap-phase regeneration in a semideciduous mesophytic forest, South-eastern Brazil. **Plant Ecology**. v. 00, p. 1 -12. 2002.

MCCARTHY, J. Gap dynamics of forest trees: with particular attention to boreal forests. **Environmental Reviews**. n.9, p.1–59. 2001.

MCCULLOCH, W. S.; PITTS, W. H. A Logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 1943. v. 5, p. 155-133. Disponível em: <<http://www.cse.chalmers.se/~coquand/AUTOMATA/mcp.pdf> >. Acesso em: 20 out. 2019.

MCGAUGHEY, R. J. FUSION/LDV: **Software for LIDAR Data Analysis and Visualization**. Washington D. C: USDA Forest Service. 2016.

MEER, P.J. van der; Bongers, F.; CHATROU, L.; RIÉRA, B. **Defining Canopy gaps in a tropical rain forest: effects on gap size and turnover time**. *Acta Oecologica*, Paris, v.15, n 6, p. 701-714,1994.

MENDONÇA, M. J.; LOUREIRO, P. R.; SACHSIDA. **The dynamics of land-use in Brazilian Amazon**. *Ecological Economics*, v. 84, p. 23-36, 2012.

MENDONÇA, M.; FIONOCCHIO, M. A. F.; GUSMÃO, R. V.; CHRUN, I. R. **Artificial Neural Networks Applied In Image Extraction For Autonomous Classification Of Weld Beads**. 2016. *Revista Científica On-line Tecnologia*. Faculdade de Tecnologia de Guaratinguetá. Revista v.6, n.2 – novembro, 2016

MENESES, P. R. 2001. **Fundamentos de Radiometria Óptica Espectral**. In: MENESES, P. R.; NETTO, J. S. M. *Sensoriamento Remoto: Reflectância dos alvos naturais*. Brasília, DF: UnB; Planaltina: Embrapa Cerrados.

MOLIN, JP, AMARAL LR, COLAÇO AF (2015). **Agricultura de precisão**. Oficina de Textos: São Paulo, p. 119-153.

MORAES, E. C. **Fundamento de sensoriamento remoto**. Instituto Nacional de Pesquisas Espaciais- INPE. São Jose dos Campos, 2002.

MOREIRA, M.A. (2011) **Fundamentos de sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa: UFV, 422p.

MUNDT, J. T.; STREUTKER, D. R.; GLENN, N. F. Mapping sagebrush distribution using fusion of hyperspectral and lidar classifications. **Photogrammetric Engineering Remote Sensing**, v. 72, n. 1, p. 47–54, 2006.

NÆSSET, E.; GOBAKKEN, T. Estimating forest growth using canopy metrics derived from airborne laser scanner data. **Remote Sensing of Environment**, New York, v. 96, p. 453-465, 2005.

NETO, I.A. **Uso de ferramentas de sig e sensoriamento remoto para o monitoramento do desmatamento em unidades de conservação: estudo de caso da Floresta Nacional do Bom Futuro – RO**. Dissertação (Mestrado em Geografia) – Universidade Federal de Rondônia, Porto Velho, 2009.

NOBRE, C. A.; SAMPAIO, G.; SALAZAR, L. Mudanças climáticas e Amazônia. **Ciência e Cultura**. v. 59, p. 22–27. 2007.

NOVO, E. M. L. de M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010. 387 p.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Blucher, 2008.

OLI VEIRA, L. T. **Aplicações do LiDAR no inventario de florestas plantadas**. 2011. 118 p. Tese. Universidade Federal de Lavras, Lavras, 2011.

PALMIOTTO, P.A., VOGT, K.A., ASHTON, P.M.S., ASHTON, P.S., VOGT, D.J., LAFRANKIE, J.V., SEMUI, H. & LEE, H.S. 2004. **Linking Canopy gaps, topographic position, and edaphic variation in a tropical rainforest: Implications for species diversity**. In: **Tropical forest diversity and dynamics: findings from a large-scale plot network**. (Orgs.). Losos, E. C.; Leigh Jr, E. G. The University of Chicago Press, Chicago, pp. 195-220.

PEREIRA JR., R. et al. Forest canopy damage and recovery in reduced impact and conventional selective logging Eastern Pará, Brazil. **Forest Ecology and Management**, v. 168, p. 77–89, 2002.

PEREIRA, D. A. **Fatos Florestais da Amazônia**. IMAZON – Belém, PA. 2010

PESSOA, M.; MELO, R.; RODRIGUES, A.; CLEGER, S.; CAVALCANTI, J. M.; FREITAS R. de. **Deteção de áreas de clareira na Floresta Amazônica através de monitoramento via satélite e aprendizagem de máquina**. PPGI/Instituto de Computação – Universidade Federal do Amazonas. Manaus, AM. 2019.

PIMENTEL, G. M. **Monitoramento das paisagens de Paragominas: uma abordagem geossistêmica**. 2016. 110 f. Dissertação. Pós-Graduação em Gestão de Recursos Naturais e Desenvolvimento Local na Amazônia. Universidade Federal do Pará. Belém/PA, 2016.

PINTO et al. 2009. **Diagnostico Socioeconômico e Federal do Município de Paragominas**. Relatório Técnico. Belém/PA: Instituto do Homem e Meio Ambiente da Amazonia – Imazon 65p. Disponível em: <<https://imazon.org.br/PDFimazon/Portugues/outros/iagnostico-socioeconomico-e-florstal-do.pdf>>. Acesso em: 13 ago. 2019.

POPESCU, S. C.; ZHAO, K.; NEUENSCHWANDER, A.; LIN, C. Satellite lidar vs. small footprint airborne lidar: Comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**, v. 115, n. 11, p. 2786 – 2797, 2011. ISSN 0034-4257. {DESDynI} VEG-3D Special Issue. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0034425711001325>>. Acesso em: 18 ago. 2019.

R CORE TEAM. **R: The Project for Statistical Computing**. Disponível em: <<http://www.r-project.org/>>. Acesso em: 15 dez. 2019.

RAGHAVENDRA, S. J.; DEKA, P. C. **Support vector machine applications in the field of hydrology: a review**. *Applied Soft Computing*, v. 19, p. 372-386, 2014.

RAY D, NEPSTAD D, MOUTINHO P. Micrometeorological and canopy controls of fire susceptibility in a forested Amazon landscape. **Ecol Appl** 2005;15: 1664–1678.

RODRIGUES, T. E. et al. **Caracterização e Classificação dos Solos do Município de Paragominas, Estado do Pará**. 1 ed. Belém: Embrapa Amazônia Oriental, 2003, 51 p.

RSTUDIOTEAM. RStudio: Integrated Development Environment for R. 2016. RStudio, inc. Disponível em: <<http://www.rstudio.com/>>.

RUIZ, L. F. C.; ten CATEN, A.; DALMOLIN, R. S. D. **Árvore de decisão e a densidade mínima de amostras no mapeamento da cobertura da terra**. *Ciência Rural*, Santa Maria, v.44, n.6, p.1001-1007, 2014. SAUSEN, T. M.; LACRUZ, M. S. P. **Sensoriamento Remoto para Desastres**. São Paulo: Oficina de Textos, 2015. 285 p.

RUNKLE, J. R. **Gap regeneration in some old-growth forests of the eastern United States**. *Ecology*. Washington, v 62, n. 4, 1041-1051, 1981.

RUSSEL, S. J.; NORVIG, P. **Artificial intelligence: A Modern Approach**. 2º Edição. Prentice-Hall, 2002. ISBN – 10:0137903952.

SALVADOR-VAN EYSENRODE, D., BOGAERT, J. & IMPENS, I. 1999. **Canopy gap morphology determinants in an Amazonian rain forest**. *Selbyana* 20, 2: 339-344.

SANTOS, E. M. dos. **Teoria e aplicação de Support Vector Machines a aprendizagem e reconhecimento de objetos baseado na aparência**. 2002. 121 f. Dissertação. Pós-Graduação em Informática. Universidade Federal da Paraíba. Campina Grande, Paraíba. 2002.

SANTOS, K. N. DOS. **Utilização de técnicas de Aprendizado de Máquina para Predição de Crises Epiléticas**. 2016. 73 f. Dissertação. Pós-Graduação em Sistemas e Computação. Universidade Federal do Rio Grande do Norte. Natal, RN, 2016.

SANTOS, M. B. dos. **Dinâmica da regeneração de clareiras naturais na Floresta de Restinga na Ilha do Cardoso, Cananéia/SP**. 2007. 87 f. Dissertação. Escola superior de Agricultura Luiz de Queiroz, Piracicaba, SP, 2007.

SARAIVA, M. B. **Transição florestal no bioma Amazônia : dinâmica e condicionantes socioeconômicos**. 2017. 93 f. Tese. Pós-Graduação em Economia Aplicada. Universidade Federal de Viçosa. Viçosa, MG, 2017.

SATO, L. Y. **Tecnologia LiDAR para quantificação dos impactos de incêndios na estrutura florestal no sudoeste da Amazônia**. 2017. 128 p. Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

SCHIKOWSKI, A. B. **Estimativa do volume e da forma do fuste utilizando técnicas de aprendizado de máquina**. 2016. 71 f. Dissertação. Universidade Federal do Paraná. Curitiba, PR, 2016.

SEYEDHOSSEINI, M.; TASHDIZEN, T. Disjunctive normal random forests. **Pattern Recognition**, v. 48, n. 3, p. 976-983, 2015.

SILVA F. M. da. **Florística, dinâmica e estrutura e da regeneração natural em floresta explorada na FLONA do Tapajós-PA**. 2015. 133 f. Dissertação. Pós-Graduação em Ciências de Florestas Tropicais. Instituto Nacional de Pesquisas da Amazônia - INPA, Manaus, AM, 2015.

SILVA, C. A., PINAGÉ, E. R., MOHAN, M., ALMEIDA, D., BROADBENT, E., JAAFAR, W., KLAUBERG, C. (2019). **ForestGapR: An R package for airborne laser scanning-derived tropical forest gaps analysis**. R Package Version, 2.

SILVA, I. N. D.; SPATTI, H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo, 2010.

SILVEIRA, H. F. da. **Uso de dados do sensor MSI/Sentinel-2 e de LiDAR aerotransportado para mapeamento de fitofisionomias de Caatinga e estudo das relações com atributos físico-químicos dos solos**. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

SILVEIRA, H. F. DA. **Uso de dados do sensor MSI/Sentinel-2 e de LiDAR aerotransportado para mapeamento de fitofisionomias de Caatinga e estudo das relações com atributos físico-químicos dos solos**. Dissertação Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

SMOLA, A. J.; BARTLETT, P. L.; SCHÖLKOPF, B.; SCHUURMANS, D. **Introduction to large margin classifiers**. Advances in large margin classifiers. 2000.

SNIF. Sistema Nacional de informações Florestais. **Os Biomas e suas florestas**. 2018. Disponível em: <<http://snif.floresta.gov.br/pt-br/os-biomas-e-suas-florestas>>. Acesso em: 15 ago. 2019.

SOTHE, C. et al. **Evaluating Sentinel-2 and Landsat-8 Data to Map Successional Forest Stages in a Subtropical Forest in Southern Brazil**. Remote Sensing, v. 9, p. 838. 2017a.

SOUZA DR, SOUZA AL, LEITE HG & YARED JAG (2006). Análise Estrutural em floresta ombrófila densa de terra firme não explorada, Amazônia Oriental. **Revista Árvore**, 30:75-87.

SOUZA, C. G. et al. Algoritmos de aprendizagem de máquina e variáveis de sensoriamento remoto para o mapeamento da cafeicultura. **Boletim de Ciências Geodésicas**, v. 22, n. 4, p. 751-773, 2016.

SPANDRI, R. **Introdução a redes neurais. Controle & Instrumentação**, São Paulo: Editora Técnica Comercial Ltda, n. 43, p. 68-73, fev. 2000.

STANGE, R. L. **Adaptatividade em aprendizagem de máquina: conceitos e estudo de caso**. 2011. 98 f. Dissertação. Universidade de São Paulo. São Paulo, SP, 2011.

- SUNG, A. H.; MUKKAMALA, S. **Identifying important features for intrusion detection using support vector machines and neural networks**. Applications and the Internet, 2003. Proceedings. 2003 Symposium on, p. 209–216.
- THARWAT, A. **Classification assessment methods**. Applied Computing and Informatics, v. 21, 2018.
- USGS. **United States Geological Survey**. Disponível em: <<https://eros.usgs.gov/sentinel-2>>. Acesso em: 24 ago. 2019.
- VALBUENA, R., MALTAMO, M., MEHTÄTALO, L., & PACKALEN, P. (2017). **Key structural features of boreal forests may be detected directly using L-moments from airborne lidar data**. Remote Sensing of Environment, 194, 437–446. <https://doi.org/10.1016/j.rse.2016.10.024>.
- VAPNIK, V. N. **The nature of statistical learning theory**. New York, NY, USA: Springer Verlag New York, Inc., 1995. ISBN 0387945598. Disponível em: <<http://portal.acm.org/citation-.cfm?id=211359>>. Acesso em: 02 out. 2019.
- VASCONCELOS, P. G. A. (2015). **Determinantes do desmatamento na Amazônia Brasileira**. Dissertação de mestrado em Ciências Florestais. Publicação PPGEFL.DM-249/2015. Departamento de Engenharia Florestal, Universidade de Brasília - UnB, Brasília/DF. 2015. 60p.
- VIERLING, L. A.; XU, Y.; EITEL, J. U. H.; OLDOW, J. S. Shrub characterization using terrestrial laser scanning and implications for airborne lidar assessment. **Canadian Journal of Remote Sensing**, v. 38, n. 6, p. 709–722, 2012.
- VOSSelman, G.; MAAS, H. –G. **Airborne and Terrestrial LASER Scanning**. Scotland, UK. Whittles Publishing. 342 p, 2010.
- WAGNER, W.; ULLRICH, A.; MELZER, T.; BRIESE, C.; KRAUS, K. From single-pulse to full-waveform airborne laser scanners: potential and practical challenge. **International Archives of Photogrammetry and Remote Sensing**, v. 35, n. Part B, p. 201–206, 2004.
- WASKE, B.; FAUVEL, M.; BENEDIKTSSON, J. A.; CHANUSSOT, J. **Machine learning techniques in remote sensing data analysis**. In: CAMPS-VALLS, G.; BRUZZONE, L. (Orgs.). Kernel methods for remote sensing data analysis. New York: : John Wiley & Sons, 2009. p.1-24.
- WEHR, A.; LOHR, U. Airborne laser scanning-an introduction and overview. **{ISPRS} Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 68 – 82, 1999. ISSN 0924-2716.
- WHITE, E. P., ENQUIST, B. J., & GREEN, J. L. (2008). **On estimating the exponent of power law frequency distributions**. Ecology, 89, 905–912. <https://doi.org/10.1890/07-1288.1>.
- YAMAMOTO, S.I. 1992. **The gap theory in forest dynamics**. The Botanical Magazine 105: 375-383.

ZANDONÁ, M. F. **Potencial uso de dados Laser Scanner aerotransportado para estimativa de variáveis dendrométricas.** 2006. 92 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal do Paraná, Curitiba, 2006.

ZHANG, S.; LIU, H-X.; GAO, D-T; WANG, W. **Surveying the methods of improving ANN generalization capability.** In Machine Learning and Cybernetics, 2003, International Conference on, v.2, p.1259-1263, 2-5, nov. 2003.