



**PREDIÇÃO DA BIOMASSA ACIMA DO SOLO NO CERRADO UTILIZANDO REDES
NEURAIS E SENSORIAMENTO REMOTO**

PAULA LOPES GERMANO DE OLIVEIRA

**DISSERTAÇÃO DE MESTRADO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS
DEPARTAMENTO DE ENGENHARIA FLORESTAL**



**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**



UNIVERSIDADE DE BRASÍLIA - UnB
FACULDADE DE TECNOLOGIA - FT
DEPARTAMENTO DE ENGENHARIA FLORESTAL - EFL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**PREDIÇÃO DA BIOMASSA ACIMA DO SOLO NO CERRADO UTILIZANDO REDES
NEURAIIS E SENSORIAMENTO REMOTO**

Paula Lopes Germano de Oliveira
Matrícula: 19/0005084

Orientador: Prof. Dr. Eraldo Aparecido Trondoli Matricardi

Dissertação de Mestrado em Ciências Florestais

Publicação: PPGEFL. DM-x/2022

Brasília/DF agosto de 2022.

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**PREDIÇÃO DA BIOMASSA ACIMA DO SOLO NO CERRADO UTILIZANDO
REDES NEURAI E SENSORIAMENTO REMOTO**

PAULA LOPES GERMANO DE OLIVEIRA

**DISSERTAÇÃO DE MESTRADO ACADÊMICO SUBMETIDA AO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS DA
UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIAS FLORESTAIS.**

APROVADA POR:

**Dr. Eraldo Aparecido Trondoli Matricardi (Departamento de Engenharia Florestal –
UnB) (Orientador)**

**Dr. Eder Pereira Miguel
(Examinador Interno – PPG CFL - UnB)**

**Dr. Ben Hur Marimon Júnior
(Examinador externo - UNEMAT- Nova Xavantina - MT)**

Brasília-DF, 30 de agosto de 2022.

FICHA CATALOGRÁFICA

L048p Lopes Germano de Oliveira, Paula
 Predição da biomassa acima do solo no Cerrado utilizando
 redes neurais e sensoriamento remoto / Paula Lopes Germano
 de Oliveira; orientador Eraldo Aparecido Trondoli
 Matricardi. -- Brasília, 2022.
 53 p.

 Dissertação (Mestrado em Ciências Florestais) --
 Universidade de Brasília, 2022.

 1. Cerrado. 2. Redes neurais artificiais. 3.
 Sensoriamento remoto. 4. Biomassa. I. Aparecido Trondoli
 Matricardi, Eraldo, orient. II. Título.

Oliveira, P.L.G. (2022). Predição da biomassa acima do solo no cerrado utilizando redes neurais e sensoriamento remoto. Dissertação de Mestrado em Ciências Florestais. Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 53p.

CESSÃO DE DIREITOS

AUTOR: Paula Lopes Germano de Oliveira.

TÍTULO: Predição da biomassa acima do solo no cerrado utilizando redes neurais e sensoriamento remoto.

GRAU: Mestre

ANO: 2022

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. A autora reserva outros direitos de publicação e nenhuma parte dessa tese de doutorado pode ser reproduzida sem autorização por escrito da autora.

Paula Lopes Germano de Oliveira
Departamento de Engenharia Florestal (EFL)-FT Universidade de Brasília (UnB)
Campus Darcy Ribeiro
CEP 70919-970 - Brasília - DF- Brasil

Dedico
Aos meus pais, Denise e Paulo e ao meu companheiro, Joaquim
Obrigada por sempre acreditarem em mim.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais pelo apoio incondicional e por proporcionarem tudo que estava ao alcance para que eu pudesse chegar aonde estou.

Ao meu namorado, por todos esses anos de companheirismo, pelos ensinamentos compartilhados, pela sua paciência e todo amor construído.

Ao meu professor e orientador Eraldo A. T. Matricardi, quem eu tenho grande admiração por sua sabedoria, carisma e paciência, e que teve e sempre terá um importante papel no meu desenvolvimento acadêmico e pessoal. Sem seu apoio nada disso seria possível.

Ao professor Eder, pelo apoio durante a pesquisa, pelos ensinamentos, pela sua disponibilidade e compreensão.

Aos meus amigos que me acompanham nessa louca aventura que é a vida, que me deram suporte para vencer todos os obstáculos e que me fazem amadurecer como pessoa todos os dias.

Ao Departamento de Engenharia Florestal, ao corpo docente e funcionários que sempre estiveram disponíveis e solícitos para toda e qualquer necessidade.

A banca examinadora pelo apoio e disposição em participar dessa importante etapa da minha jornada.

A UnB, por fazer parte dos melhores anos da minha vida.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de mestrado.

RESUMO

O Cerrado, segundo maior bioma brasileiro, apresenta papel fundamental para a qualidade ambiental, sendo responsável por funções indispensáveis à geração de serviços ambientais essenciais, dentre os quais destaca-se a capacidade de armazenar em sua biomassa expressivas quantidades de carbono. Apesar de sua importância, quase metade da vegetação nativa deste bioma já foi convertida em áreas urbanas, cultivos agrícolas e pastagens. As estimativas precisas de biomassa são informações essenciais para nortear ações conservacionistas em áreas com remanescentes de vegetação. Dados de sensoriamento remoto associados a redes neurais artificiais tem demonstrado eficácia na modelagem de variáveis florestais. A presente pesquisa inclui o desenvolvimento de modelo de predição da biomassa acima do solo no Cerrado no Distrito Federal usando índices de vegetação derivados de imagens de satélite e redes neurais artificiais. Foram utilizados dados de campo coletados no âmbito do Inventário Florestal Nacional e de parcelas permanentes na área de estudo. Foram calculados e testados cinco índices de vegetação derivados de cenas do satélite de alta resolução *RapidEye*, tendo como referência dados coletados em campo. Foram treinadas redes neurais artificiais com a ferramenta *Intelligent Problem Solver* do software Statistica 7 para estimar a biomassa acima do solo, permitindo a seleção dos índices e da rede neural mais adequada para a predição da biomassa na área de estudo, segundo critérios do erro média da estimativa, coeficiente de correlação e análises gráficas. A rede neural com melhor desempenho apresentou poder preditivo de 90% e erro quadrático (RMSE) inferior a 17%. A estrutura da rede foi composta por dois neurônios na camada de entrada, oito na camada oculta e um na camada de saída. Os resultados deste estudo indicam que índices de vegetação associados a redes neurais artificiais podem estimar com boa acurácia a biomassa acima do solo no bioma Cerrado.

Palavras-chave: Cerrado, redes neurais artificiais, sensoriamento remoto, biomassa.

ABSTRACT

Cerrado is the second largest biome in Brazil and plays a crucial role in environmental quality and it is responsible for ecosystem functions necessary for generation of environmental services, including the ability of storing significant carbon amounts. Despite of its environmental role, almost half of the native vegetation of Cerrado has been converted into urban areas, crop lands, and pastures. Accurate biomass estimates are essential information to support conservation measures in areas of remnants of native vegetation. Remote sensing data associated with artificial neural networks have proven effective in modeling forest variables and biomass. In this study, we aimed to model the aboveground biomass in a study case in the Cerrado biome using vegetation indices derived from remotely sensed data and artificial neural networks. Field data were provided by the National Forest Inventory collected within the Federal District territory and from permanent plots on the Água Limpa experimental farm of the University of Brasilia. Five vegetation indices were retrieved from high resolution RapidEye satellite scenes and calculated for each sample plot. Correlation testing was performed to identify the optimum index to be applied in aboveground biomass modeling. Artificial neural networks were trained to predict the aboveground biomass in the study area using the Intelligent Problem Solver tool of the Statistica 7 software, vegetation indices, and field data. The selection of the optimum neural network was made according to criteria of mean error of the estimate, correlation coefficient and graphical analysis. The best performing neural network showed predictive power of 90% and squared error (RMSE) less than 17%. The structure of the net was composed of two neurons in the input layer, eight in the hidden layer, and one in the output layer. This study results indicate that vegetation indices associated with artificial neural networks can estimate with good accuracy the aboveground biomass in the Cerrado biome.

Keywords: Brazilian savanna, Cerrado, artificial neural networks, remote sensing, biomass.

Sumário

1. INTRODUÇÃO.....	11
1.1. Contextualização	11
2. OBJETIVOS.....	14
2.1. Objetivo geral.....	14
2.2. Objetivos específicos.....	14
3. FUNDAMENTAÇÃO TEÓRICA	14
3.1. O Cerrado	14
3.2. Sensoriamento Remoto e a biomassa florestal	17
3.3. Redes neurais artificiais	20
4. MATERIAL E MÉTODOS.....	21
4.1. Localização e caracterização da área de estudo	21
4.2. Dados de campo	23
4.3. Estimativa de biomassa acima do solo.....	25
4.4. Processamento dados ópticos	25
4.5. Modelagem: Redes Neurais	27
6. RESULTADOS	30
6.1. Inventário Florestal	30
6.2. Modelagem.....	31
6.2.1. Seleção das variáveis independentes	31
6.2.2. Treinamento das redes neurais	32
6.3. Mapas de biomassa.....	34
6.3.1. Análise Estatística	37
7. DISCUSSÃO.....	38
7.1. Análise geral dos dados	38
7.2. Modelagem	39
7.2.1. Seleção das variáveis independentes	39
7.2.2. Redes neurais	40
7.3. Análise estatística	42
8. CONCLUSÃO.....	42
9. REFERÊNCIAS BIBLIOGRÁFICAS	43

LISTA DE TABELAS

Tabela 1: Intervalos espectrais utilizados pelos sensores remotos. Fonte: Meneses, Almeida (2012).....	18
Tabela 2 - Cenas do satélite RapidEye adquiridas através do Serviço Florestal Brasileiro utilizadas para processamento dos índices de vegetação.....	26
Tabela 3 - Índices de vegetação.....	27
Tabela 4 - Variáveis dendrométricas estimadas a partir do inventário florestal para as áreas de cerrado do DF.	30
Tabela 5 - Média das variáveis independentes do cerrado do DF.	31
Tabela 6 – Matriz de correlação segundo Spearman entre as variáveis estudadas.....	31
Tabela 7 - Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição da biomassa acima do solo do cerrado sensu stricto do DF.	32
Tabela 8 – Estimativa da biomassa acima do solo em Unidades de Conservação do DF.	35

LISTA DE FIGURAS

Figura 1 - Classificação das fitofisionomias do bioma Cerrado segundo Ribeiro e Walter (1998).....	15
Figura 2 - Comportamento espectral representativo de vegetação verde, vegetação seca e solo nas faixas espectrais do visível e do infravermelho próximo, com destaque para a banda do red-edge, colocada, pela primeira vez, em um sensor orbital e multiespectral, satélite alemão, RapidEye. Fonte: adaptado RapidEye (2022).	19
Figura 3 - Modelo de um neurônio artificial. Fonte: Haykin (2001).	20
Figura 4 - Mapa de localização da área de estudo.....	22
Figura 5 - Mapa de uso e cobertura da terra do Distrito Federal.....	23
Figura 6 - (a) e (b): Cerrado no Parque Nacional de Brasília (PNB). (c) Imagem aérea do Cerrado no PNB.	24
Figura 7 - Fluxograma para modelagem de biomassa.....	28
Figura 8 - Valores observados e preditos (A), distribuição de resíduos (B) e distribuição de classes de erro (C).....	33
Figura 9 - Arquitetura da RNA selecionada para predição da biomassa acima do solo no cerrado do DF.	34
Figura 10 - Mapa de biomassa acima do solo em áreas de cerrado no DF.	35
Figura 11 - Mapas de biomassa acima do solo do cerrado nas Unidades de Conservação do DF.	37

1. INTRODUÇÃO

1.1. Contextualização

Os ecossistemas florestais fornecem variados benefícios econômicos, ambientais e ecológicos a sociedade, como proteção do solo e da água, sequestro de carbono, produção de madeira, regulação do clima local e conservação da biodiversidade (GÜNLÜ et al., 2019). O desmatamento, principalmente nos trópicos, é uma importante fonte global de emissão de gases do efeito estufa (LE QUÉRÉ et al., 2015; NOOJIPADY et al., 2017). Quando as florestas são desmatadas, o carbono armazenado acima e abaixo do solo é liberado para a atmosfera (BACCINI et al., 2012), condição que ocorre mais rapidamente em vegetações tropicais.

O Cerrado é o segundo maior bioma brasileiro e a savana tropical mais diversa do mundo (KLINK; MACHADO, 2005). A história do uso e ocupação da terra no Cerrado revela hoje intensa pressão antrópica no bioma, onde o uso insustentável dos recursos ambientais trouxe elevado grau de perturbação, tornando este bioma um dos mais ameaçados do planeta (OLIVEIRA et al., 2019). As perdas de sua vegetação natural dificilmente são quantificadas com precisão, no entanto, estima-se que o remanescente de vegetação nativa do Cerrado brasileiro chega a pouco mais de um milhão de quilômetros quadrados, cerca de 52% de sua área total (Mapbiomas, 2021; FIP CERRADO, 2020; NETO, 2018). A principal causa para diminuição da área desse bioma pode ser atribuída à ocupação humana, devido, principalmente, ao aumento da população em centros urbanos, a implantação mecanizada de culturas agrícolas e ao cultivo de pastagens para criação de gado (ROQUETTE, 2018).

Devido a sua extensão, diversidade biológica e potencial hídrico, o Cerrado desempenha um papel fundamental para a qualidade ambiental regional, sendo responsável por funções indispensáveis à geração de serviços ambientais essenciais (BRASIL, 2011), dentre estes, destaca-se a capacidade de armazenar em sua biomassa expressivas quantidades de carbono, atuando como grande assimilador e acumulador do carbono atmosférico (OLIVEIRA et al., 2019).

As medições de biomassa são de particular importância para políticas relacionadas à Convenção-Quadro das Nações Unidas sobre a Mudança do Clima (UNFCCC), pois os países devem monitorar as emissões relacionadas a ganhos e perdas de biomassa, e devem apresentar relatórios regularmente (HEROLD; JOHNS, 2007; KUNTSCHIK, 2004).

Além disso, esses dados também são de extrema importância no âmbito nacional para apoiar a formulação de políticas públicas que visem o combate ao desmatamento (HEROLD et al., 2019) e de redução das emissões de gases de efeito estufa.

Devido ao aumento do interesse em monitorar as florestas, os dados espaciais tem sido amplamente utilizados para este fim (YU e SAATCHI, 2016; YANG *et al.*, 2018). Dados de sensoriamento remoto integrados com inventários florestais tornaram-se uma abordagem eficaz para estimar biomassa acima do solo, ainda que existam desafios tanto na coleta de dados de campo quanto nos dados de sensoriamento remoto (BARBOSA; BROADBENT; BITENCOURT, 2014). Embora a biomassa derivada de medições de campo seja mais precisa, esta abordagem dificilmente é utilizada em estudos de larga escala pois demandam muito tempo e recursos financeiros vultuosos, além da inviabilidade de coleta em locais de difícil acesso (KUMAR; MUTANGA, 2017). Portanto, são necessários métodos de estimativa que relacionem a biomassa à variáveis de menor custo de execução com alcance em maior escala e monitoramento de longo prazo (BARBOSA; BROADBENT; BITENCOURT, 2014; ROITMAN et al., 2018). Nesse caso, as vantagens do sensoriamento remoto são o fornecimento de grandes quantidades de dados de extensas áreas, com alta repetitividade e custo relativamente baixo (MENESES; ALMEIRDA; BAPTISTA, 2019), além dos diferentes tipos de dados disponíveis, tais como sensores ópticos, radar, LiDAR, drones, etc.

As imagens ópticas são as mais amplamente utilizadas para mapeamento dos recursos naturais devido a disponibilidade gratuita de imagens globais, a repetitividade dos dados e a diversidade de sensores em órbita (MENDES, 2019). Os dados derivados de sensores remotos mais utilizados na estimativa da biomassa acima do solo da vegetação são a reflectância e os índices de vegetação (CASSOL; SALDANHA; KUPPLICH, 2014; FERRAZ et al., 2014; LU, 2006). A reflectância é a razão entre a quantidade de energia refletida pela vegetação pela quantidade incidente na área (MENESES; ALMEIDA, 2012). Já os índices de vegetação são combinações matemáticas de diferentes bandas espectrais que tem como principal objetivo aprimorar as informações contidas na reflectância dos alvos, extraindo a variabilidade causada pelas características vegetação e minimizando os efeitos do solo e da atmosfera (VIÑA et al., 2011). Nesse sentido, o sensoriamento remoto tem a capacidade de estimar a biomassa acima do solo por meio de correlações existentes entre a resposta espectral dos alvos e as

variáveis obtidas em campo (HEROLD et al., 2019; KUMAR et al., 2016; LU, 2006; MENDES, 2019).

A utilização de dados de sensores remotos na quantificação da biomassa acima do solo permite estimar a sua distribuição em escala espacial maior do que a possibilitada por dados de campo, resultando em uma extrapolação da superfície de distribuição da biomassa para uma região (CASSOL; SALDANHA; KUPLICH, 2014; ZHU; LIU, 2015). A análise de regressão é a abordagem de previsão de parâmetros mais comum ao relacionar dados de satélite com variáveis dendrométricas (GÜNLÜ et al., 2019; YU et al., 2019). No entanto, nos últimos anos, as redes neurais artificiais têm sido bastante utilizadas para predição de parâmetros florestais (GÜNLÜ et al., 2019), visto que fornecem uma melhor resolução para problemas complexos e não lineares devido ao seu atributo de estimativa universal (FOODY et al., 2001; PANDA; AMES; PANIGRAHI, 2010). As RNAs não necessariamente pressupõem que os dados tenham distribuição normal e relações lineares. Dessa forma, podem modelar diferentes fontes de dados, como imagens de satélite e medições em solo, incluindo diversas variáveis independentes (GÜNLÜ et al., 2019; LU et al., 2016).

De forma geral, uma RNA é um processador constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Para alcançarem um bom desempenho, as RNAs empregam uma interligação maciça de células computacionais, denominadas “neurônios” ou unidades de processamento (HAYKIN, 2001).

A técnica de RNA inclui estágios de treinamento, verificação e teste usando subconjuntos de dados, que são constituídos por valores de dados selecionados aleatoriamente do conjunto de dados (ERCANLI et al., 2018). Através do processo de aprendizagem, as RNAs têm o poder de aproximar qualquer relação não-linear que exista entre um conjunto de entradas e seu correspondente conjunto de saídas (PANDA; AMES; PANIGRAHI, 2010). Neste sentido, estudos vem evidenciando bons resultados na predição de parâmetros da floresta por meio da redes neurais artificiais e variáveis de sensoriamento remoto (CARRIJO et al., 2020; ERCANLI et al., 2018; FERRAZ et al., 2014; GÜNLÜ et al., 2019; MARTINS SILVA et al., 2019; MIGUEL, 2014).

Diante do exposto e dos avanços científicos e tecnológicos aplicados em pesquisas nos anos recentes, este estudo busca responder as seguintes questões: 1) existem

correlações entre variáveis de sensoriamento remoto e biomassa acima do solo estimada a partir de variáveis dendrométricas coletadas em campo? 2) RNAs associadas à dados de sensores remotos possuem capacidade de estimar com acurácia a biomassa acima do solo no cerrado do Distrito Federal?

2. OBJETIVOS

2.1. Objetivo geral

Desenvolver modelos de predição da biomassa acima do solo em áreas de vegetação de cerrado *sensu strictu* no Distrito Federal a partir de imagens de satélite com sensor óptico de alta resolução espacial.

2.2. Objetivos específicos

1. Analisar a correlação entre índices de vegetação derivados de imagens *RapidEye* e variáveis de inventário florestal no bioma Cerrado.
2. Predizer a biomassa florestal acima do solo do cerrado do Distrito Federal a partir de modelos baseados em redes neurais artificiais, dados do satélite *RapdiEye*, sensor *Multi-spectral push broom imager* e dados de campo.

3. FUNDAMENTAÇÃO TEÓRICA

3.1. O Cerrado

O Cerrado brasileiro é o segundo maior bioma brasileiro, se estendendo por mais de dois milhões de km² e ocupando quase um quarto do território nacional. É considerado um dos hotspot globais de biodiversidade em razão ao seu alto de grau de endemismo de espécies e de sua constante perda de habitat (MYERS et al., 2000). Apesar de ser considerado o segundo bioma mais importante da América do Sul, tem sofrido a conversão de terras mais rápida no Brasil, superando a das florestas tropicais (MMA 2019; FERREIRA et al., 2003; SANO; BARCELLOS; BEZERRA, 2000).

Segundo dados do projeto Terra Brasilis conduzido pelo Instituto de Pesquisas Espaciais (INPE), em 2019 foi perdida uma área de 631.902 hectares de cerrado. Nos anos posteriores o desmatamento continuou crescente, alcançando uma perda de 790.516 ha em 2020 e 853.144 ha no ano de 2021 (FERNANDO et al., 2019). É importante

ressaltar que cerca de 95% dos alertas de desmatamento nessas áreas não são licenciados para exploração, tratando-se, portanto, de atividades ilegais. Além disso, mais de 1400 ha de desmatamento foram encontrados em áreas de reserva legal de propriedades privadas (BISPO et al., 2020; METZGER et al., 2019), o que também é ilegal.

O bioma apresenta cerca 8,21% de sua área legalmente protegida, sendo que desse percentual, apenas 2,85% se refere a Unidades de Conservação de Proteção Integral (OLIVEIRA et al., 2020). Da cobertura original, cerca de 52% mantém-se preservada e 48% da cobertura do Cerrado foi desmatada ou sofreu algum tipo de degradação (BRITO et al., 2018). Portanto, trata-se de uma paisagem intensamente antropizadas, mas ainda com grande diversidade de fisionomias nativas, as quais estão vinculadas a fatores físicos e fisiográficos, como as características topográficas, do solo, do clima e do fogo (FELFILI E SILVA JÚNIOR, 2005; BERGAMASCHINE, 2017; ELIAS et al., 2019). Este bioma possui uma ampla gama de fisionomias vegetacionais, que incluem formações campestres, savânicas e florestais, com aproximadamente 44% de espécies endêmicas (MENDES et al., 2019; OLIVEIRA et al., 2020; SANO et al., 2010). As formações florestais são constituídas de Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão. Por sua vez, a formação dominante é de savana (Cerrado sentido restrito ou *sensu stricto*), com árvores e arbustos distribuídos em um estrato graminoso e sem um dossel contínuo, o qual pode ser dividido em Cerrado Denso, Cerrado Típico, Cerrado Ralo e Cerrado Rupestre, além de Vereda, Parque de Cerrado e Palmeiral. Por fim, as formações campestres correspondem a Campo Sujo, Campo Limpo e Campo Rupestre (Figura 1) (Ribeiro e Walter, 1998).

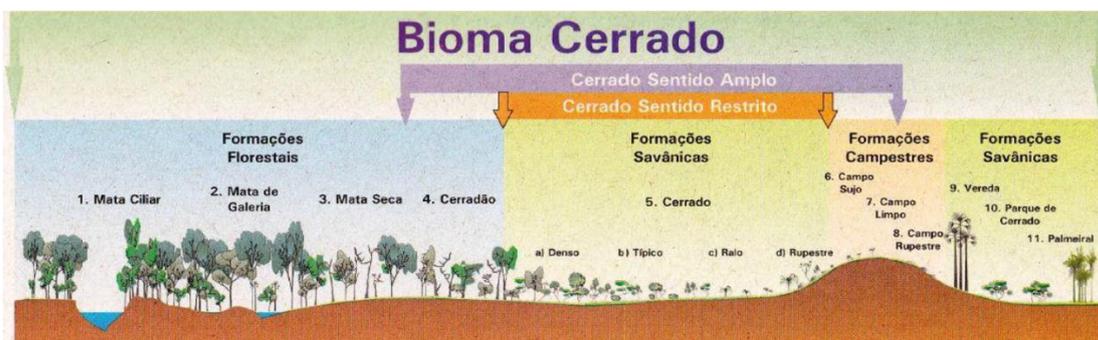


Figura 1 - Classificação das fitofisionomias do bioma Cerrado segundo Ribeiro e Walter (1998).

A vegetação dominante de cerrado *sensu stricto* (*ss*) consiste em uma camada herbácea contínua e outra lenhosa, com uma cobertura de dossel de 10 a 60%, com altura

média das árvores variando entre 3 e 5m de altura. As árvores são de baixo porte, tortuosas e com ramificações irregulares e retorcidas (ROQUETTE, 2018). Podem ser encontradas diferentes estruturas no cerrado *ss* que variam entre floresta densa e esparsa. (ROITMAN et al., 2018).

A biomassa acima do solo varia de acordo com a fisionomia do Cerrado e com a porcentagem de cobertura florestal (DE MIRANDA et al., 2014; OTTMAR et al., 2001; SAATCHI et al., 2011). Grandes estoques de carbono também são encontrados abaixo do solo pois a vegetação do Cerrado possui raízes profundas e aloca recursos substanciais para a produção de biomassa subterrânea (DE MIRANDA et al., 2014; NOOJIPADY et al., 2017).

Este bioma exerce importante papel sobre o ciclo do carbono, no entanto, as intensas mudanças no uso da terra nas últimas décadas comprometem não só essa função ecossistêmica como também provoca fragmentação de habitats, extinção da biodiversidade, invasão de espécies exóticas, erosão dos solos, alterações no ciclo hidrológico e no regime de queimadas e, conseqüentemente, modificações climáticas regionais (KLINK e MACHADO, 2005; BERGAMASCHINE, 2017).

Apesar da relativa redução das emissões de GEE nos últimos anos, atividades rurais, especialmente a agropecuária e a silvicultura, têm provocado significativas mudanças do uso da terra e florestas (LULUCF - Land use, Land-use Change and Forestry). Estas atividades continuam sendo uma fonte significativa das emissões nacionais, com 42% do total das emissões brasileiras, segundo o III Inventário Nacional de Gases de Efeito Estufa. Do total de emissões associadas a LULUCF, 22% ocorreu no bioma Amazônia e 8% no bioma Cerrado (MMA, 2016). De 2008 a 2012, as taxas anuais de desmatamento no Cerrado foram mais do que o dobro da Amazônia brasileira (LAMBIN et al., 2013; NOOJIPADY et al., 2017).

Devido ao seu alto grau de ameaça e a sua importância econômica e ambiental, projetos de monitoramento têm sido desenvolvidos no bioma Cerrado para estudar as alterações da cobertura e uso da terra, estimar as emissões de carbono e analisar o impacto do desmatamento na biodiversidade e em outros recursos naturais. Nesse sentido, os principais projetos governamentais de monitoramento da cobertura vegetal e uso da terra do Cerrado, destacam-se o PRODES Cerrado (FIP CERRADO, 2018), DETER Cerrado (FIP CERRADO, 2018) e TerraClass Cerrado (MMA, 2015) .

Os sistemas PRODES e DETER Cerrado estão sendo desenvolvidos no âmbito do projeto Desenvolvimento de Sistemas de Prevenção de Incêndios Florestais e Monitoramento da Cobertura Vegetal do Cerrado Brasileiro (FIP CERRADO, 2018), financiado pelo programa *Forest Investment Program* (FIP) do Banco Mundial (BIRD – *International Bank for Reconstruction and Development*). Em relação ao mapeamento do uso da terra, o projeto TerraClass Cerrado (MMA, 2015), fruto de uma parceria entre especialistas do Instituto Nacional de Pesquisas Espaciais (INPE), Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Universidade Federal de Uberlândia (UFU) e Universidade Federal de Goiás (UFG), realizou o mapeamento das formações florestais e não florestais (savânicas e campestres) do Cerrado, além das classes antrópicas, como agricultura, área urbana, pastagem, silvicultura e outras. (NETO, 2018)

O mapeamento de áreas tropicais heterogêneas, como o Cerrado, é um desafio devido os fatores biológicos naturais, climáticos e topográficos e as peculiaridades de suas fitofisionomias (SANO et al., 2010; GRECCHI et al., 2013). Embora a importância ecológica global do Cerrado seja reconhecida, estudos focados na quantificação do volume e da biomassa dessa formação florestal ao longo do tempo são escassos (RIBEIRO et al., 2011). Uma das razões para essa falta de estudos são as características específicas de crescimento das árvores do Cerrado brasileiro, como a tortuosidade e irregularidade dos caules da base ao dossel, o que dificulta a coleta de dados e estimativas de volume e biomassa (MARTINS SILVA et al., 2019; NUNES; GÖRGENS, 2016). No entanto, o monitoramento da dinâmica da vegetação, assim como os mapas de biomassa são informações essenciais para direcionar os esforços das políticas públicas conservacionistas.

3.2. Sensoriamento Remoto e a biomassa florestal

O sensoriamento remoto (SR) é definido como a ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e predição quantitativa das respostas das interações da radiação eletromagnética (REM) com os materiais terrestres (MENESES; ALMEIDA, 2012). A REM incidente sofre modificações ao entrar em contato com os alvos na superfície terrestre e como resultado dessas interações a energia pode ser absorvida, refletida ou transmitida, seja total ou

parcialmente (KUNTSCHIK, 2004). A reflectância é conhecida como o resultado da interação entre o espectro eletromagnético e os alvos na superfície terrestre (MENESES; ALMEIDA, 2012). Em relação a vegetação, a reflectância é resultante da interação da luz com o dossel florestal, ou seja, da diferença entre a radiação emitida e a fração absorvida pelas plantas (PONZONI, 2001).

A REM de cada comprimento de onda interage de formas distintas e com intensidades diferentes com os alvos terrestres. Cada sensor possui características que definem os comprimentos de ondas das imagens que o sensor irá adquirir (Tabela 1) (JENSEN, 2014; MENESES; ALMEIDA, 2012).

Tabela 1: Intervalos espectrais utilizados pelos sensores remotos. Fonte: Meneses, Almeida (2012).

Visível	Infravermelho próximo	Infravermelho de ondas curtas (SWIR)	Infravermelho médio (NIR)	Infravermelho termal	microondas
0,45 – 0,76 μm	0,76-1,2 μm	1,2 – 3,0 μm	3,0 – 5,0 μm	5,0 μm – 1mm	1mm – 100 cm
Toda faixa	0,76 – 0,91 1,00 – 1,12	1,19 – 1,34 1,55 – 1,75 2,05 – 2,40	3,5 – 4,2 4,5 – 5,0	8,0 – 9,2 10,2 – 12,5	3,0 – 100

Além das variadas propriedades da vegetação que podem ser preditas através de informações de diferentes sensores espaciais (HEROLD et al., 2019), o SR ainda apresenta vantagens como a repetitividade e agilidade na coleta dos dados, o processamento rápido de grandes quantidades de dados e a obtenção de informações de áreas de difícil acesso e/ou grandes extensões (LU, 2006).

Os sensores ópticos medem diferentes comprimentos de onda da radiação solar refletida pelos alvos terrestres, fornecendo informações bidimensionais que podem ser indiretamente ligadas às propriedades biofísicas da vegetação (ROSETTE et al., 2012; SHUGART et al., 2010). Os sensores são mais sensíveis às propriedades ópticas e à umidade (ZOLKOS et al., 2013), onde a energia refletida de volta ao sensor depende da estrutura da vegetação, onde a radiação eletromagnética interage com os pigmentos dos cloroplastos das folhas, seu conteúdo de água e sua estrutura foliar (PONZONI, 2002).

Com o intuito de remover a variabilidade causada pela geometria do dossel,

ângulo de incidência solar e condições atmosféricas, foram desenvolvidos índices de vegetação utilizados para medir propriedades biofísicas das florestas (KUMAR et al., 2016; LU, 2006). Os índices de vegetação são algoritmos baseados na transformação de valores de reflectância de determinadas imagens, gerando uma nova imagem com valores do índice em cada pixel (KUNTSCHIK, 2004).

Em relação às bandas espectrais, o infravermelho próximo, o red-edge e o infravermelho médio são bastante utilizados por serem faixas do espectro que capturam diferenças na estrutura do dossel devido às mudanças no índice de área foliar, conteúdo de água e clorofila, além das contribuições de materiais não fotossinteticamente ativos, especialmente aqueles observados na estação seca e na vegetação herbácea (Figura X) (TONIOL et al., 2017). A vegetação fotossinteticamente ativa tem uma intensa absorção no vermelho visível e reflexão no infravermelho próximo devido ao dossel (OLIVEIRA et al., 2007). Este recurso permite que os índices de vegetação determinem parâmetros como estágio de crescimento, atividade fotossintética, porcentagem de cobertura vegetal e outras características biofísicas da vegetação (MENDES, 2019).

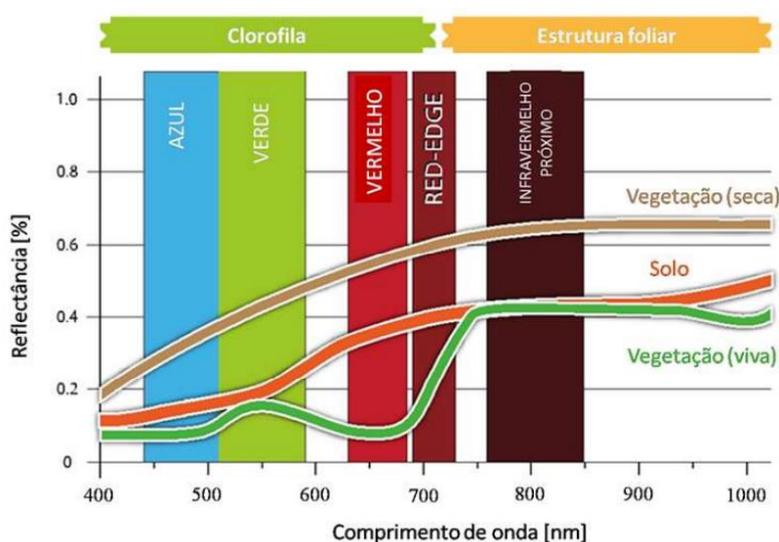


Figura 2 - Comportamento espectral representativo de vegetação verde, vegetação seca e solo nas faixas espectrais do visível e do infravermelho próximo, com destaque para a banda do red-edge, colocada, pela primeira vez, em um sensor orbital e multiespectral, satélite alemão, *RapidEye*. Fonte: adaptado *RapidEye* (2022).

Estudos científicos têm demonstrado a eficiência dos dados de SR na estimativa de biomassa da vegetação, como JACON *et al.* (2021) e ZIMBRES *et al.* (2021). Os

autores alcançaram resultados satisfatórios utilizando IVs e outras métricas derivadas de imagens de satélite na previsão de BAS no cerrado.

3.3. Redes neurais artificiais

As análises estatísticas usadas para entender as relações entre dados espectrais e atributos florestais devem abranger a possibilidade de que essas relações podem ser não lineares e complexas. Os modelos de RNA estão se tornando uma ferramenta de estimativa muito popular, visto que não necessitam de suposições sobre as relações entre as variáveis utilizadas no ajuste (BINOTI et al., 2014; ZHU; LIU, 2015).

De forma geral, uma rede neural é uma máquina projetada para modelar a maneira como o cérebro humano realiza uma tarefa particular ou função de interesse. Ela se assemelha ao cérebro em dois aspectos: (1) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem e (2) forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (HAYKIN, 2001).

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada até que a rede alcance estabilidade, quando não há mais alterações significativas dos pesos sinápticos (Figura 3) (HAYKIN, 2001). O sistema aprende interativamente por meio da previsão da camada de saída e da camada de entrada usando um conjunto de dados de treinamento (ZHU; LIU, 2015). Após o treinamento da rede, ela passa por um processo de validação, também chamado de generalização. Dessa forma, verifica-se a acurácia dos dados estimados pela rede (BINOTI; BINOTI; LEITE, 2014)

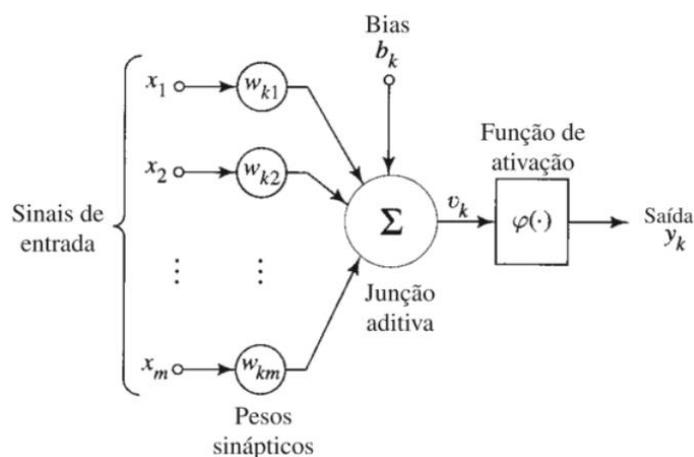


Figura 3 - Modelo de um neurônio artificial. Fonte: Haykin (2001).

Vários modelos de redes são encontrados na literatura, no entanto, o modelo de Perceptron Multicamada (*Multilayer Perceptron* - MLP) é o mais utilizado em estudos de aproximação de funções (MARTINS SILVA et al., 2019; SHIBLEE; CHANDRA; KALRA, 2010). Esse tipo de RNA é composta por uma camada de entrada, onde as variáveis são apresentadas à rede, por camadas ocultas ou intermediárias, onde é feito o processamento e por uma camada de saída, onde é apresentado o resultado. A camada oculta é responsável por identificar os padrões não lineares dos dados através do uso de funções de ativação (BRAGA, 2007; MARTINS SILVA et al., 2019)

A função de agregação do MLP calcula a média aritmética ponderada do sinal de entrada N.

$$\text{Média aritmética ponderada} = \frac{1}{N} \sum_{i=1}^N w_i * x_i$$

Essa técnica vem se mostrando cada vez mais promissora nas ciências florestais devido a sua alta acurácia na estimativa de variáveis da floresta, e muitas vezes mais eficaz que os modelos de regressão tradicionais (FERRAZ et al., 2014; MIGUEL et al., 2015; ÖZÇELİK et al., 2017; VAHEDI, 2016; ZHU; LIU, 2015). As RNAs tem sido utilizadas na previsão de diversos parâmetros florestais como, volume de madeira e biomassa em uma área de cerradão no Tocantins (MIGUEL et al., 2015); diâmetro e alturas de floresta plantada de eucaliptos em Minas Gerais (VIEIRA et al., 2018); altura da vegetação em áreas de floresta nativa no Arizona (SHAH; MANZOOR; BAIS, 2020); volume, área basal e biomassa em uma floresta de pinus na Turquia (GÜNLÜ et al., 2019); volume e biomassa no cerrado brasileiro (MARTINS SILVA et al., 2019); densidade do caule e área basal em florestas tropicais e litorâneas no sudeste de Madagascar (INGRAM; DAWSON; WHITTAKER, 2005).

4. MATERIAL E MÉTODOS

4.1. Localização e caracterização da área de estudo

O estudo foi conduzido no Distrito Federal - DF, localizado no Planalto Central entre as coordenadas 15°50'S - 48°10'W e 15°50'S – 47°30'W. O DF ocupa cerca de 578.919 hectares e encontra-se inserido no bioma Cerrado, um dos mais ricos em biodiversidade do planeta (SFB, 2016).

O bioma ocorre sobre diferentes tipos de solo, sendo dominante os Latossolos, que ocupam 46% da área, seguido pelos neossolos quartzarênicos, que cobrem 15% de sua extensão. Em geral, no Cerrado predominam os solos profundos, bem drenados, ácidos, pobres em nutrientes e saturados em alumínio (EMBRAPA, 2018).

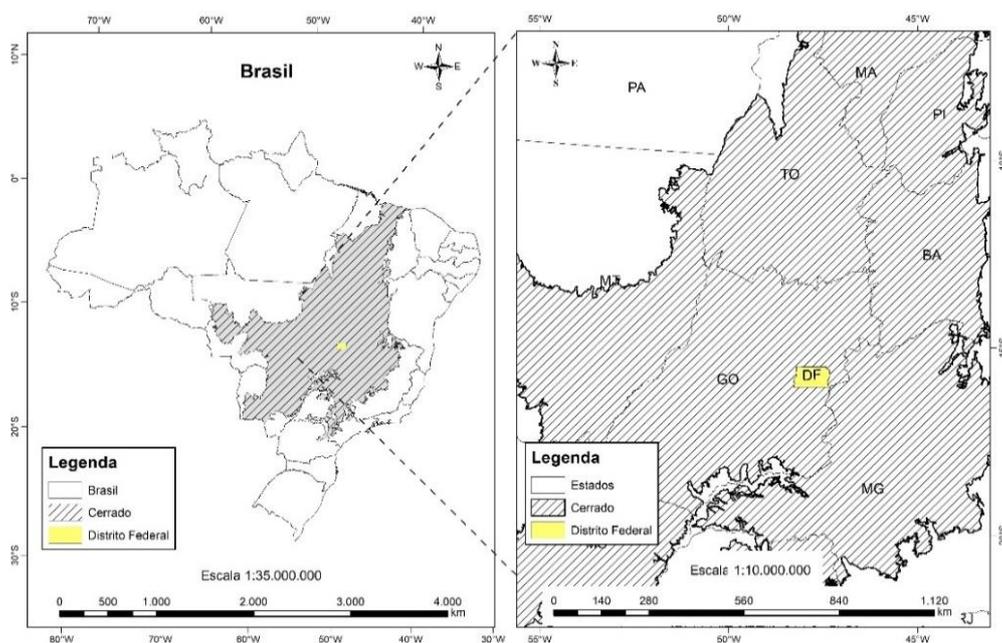


Figura 4 - Localização da área de estudo.

O clima da região é tropical do tipo Aw de Köppen, com duas estações bem definidas, seca e chuvosa, (FERREIRA et al., 2003). O período seco se estende de abril a setembro e o chuvoso de outubro a março com uma precipitação média anual de 1500mm (SILVA; ASSAD; EVANGELISTA, 2008).

No Planalto Central encontram-se as nascentes de três das maiores bacias hidrográficas da América do Sul: Prata, Araguaia-Tocantins e São Francisco, as quais desempenham papel fundamental no processo de distribuição dos recursos hídricos pelo país (SFB, 2016).

O Cerrado *sensu stricto* ocupa aproximadamente 70% do bioma Cerrado, e é caracterizado por um estrato herbáceo dominado por gramíneas, com cobertura de árvores e arbustos variando entre 10 e 60% (COELHO et al., 2020).

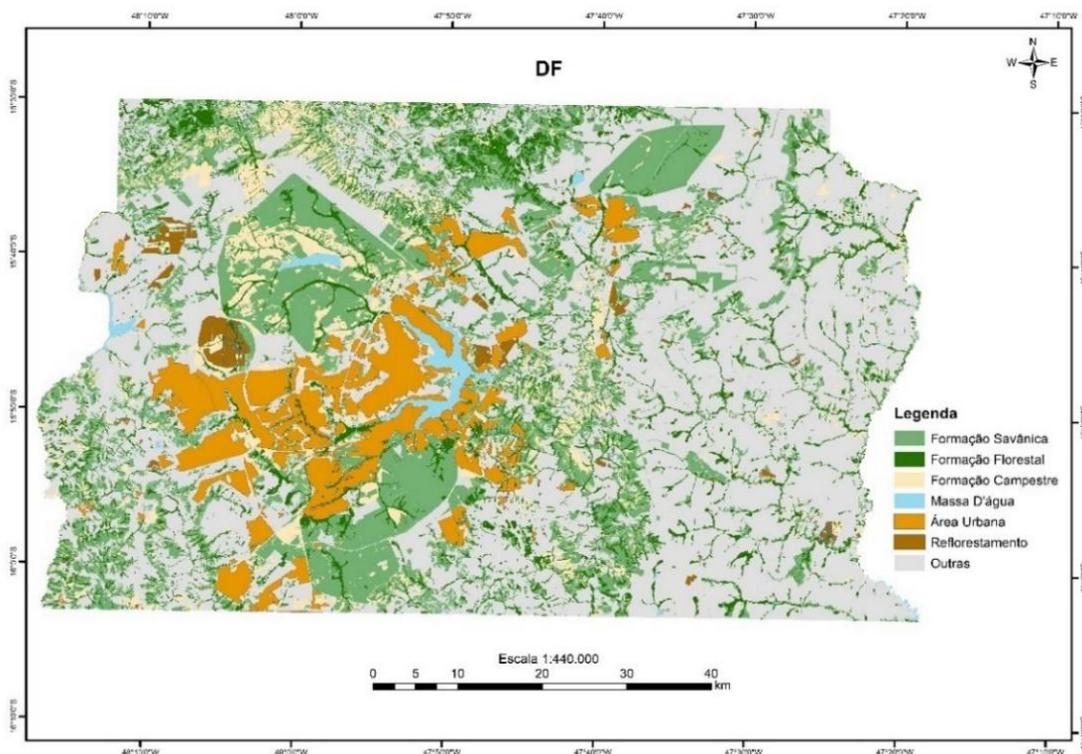


Figura 5 - Mapa de uso e cobertura da terra do Distrito Federal.

No DF, mais da metade (54%) das áreas de vegetação são ocupadas pelo Cerrado *sensu stricto* (75.002 ha), seguido pelas Matas de Galeria (44.453 – 33%). As demais formações florestais naturais – Matas Secas, Cerradão, Vereda, Parque de Cerrado e Palmeiral – ocupam juntas cerca de 11% (14.692 ha) (SFB, 2016).

4.2.Dados de campo

A coleta de dados foi realizada em 2011 pela equipe do Inventário Florestal Nacional (IFN), que foi um dos principais levantamentos realizados pelo governo federal para produzir informações sobre os recursos florestais brasileiros (SFB, 2016). O processo de coleta de dados do IFN se dá por amostragem sistemática sobre uma grade nacional de unidades amostrais. A partir dessa amostragem sistemática são estabelecidas as localizações de coletas de dados em cada estado (SFB, 2016). Dentro da área de abrangência do DF foram utilizados dados biofísicos da vegetação de 42 parcelas.

A metodologia utilizada no IFN foi a amostragem por conglomerados, compostos por 4 subunidades amostrais de 0,1 ha (20m x 50m). As subunidades amostrais foram divididas em outras 10 subparcelas de 10m x 10m, e, dentro de cada uma dessas

subparcelas, foram coletados dados de diâmetro e altura dos indivíduos que atenderem ao critério de inclusão, diâmetro à altura da base (Db) - 30 cm do solo) superior a 10 cm nas tipologias de cerrado. Ainda em cada subunidade, uma subparcela (10m x 10m) foi destinada à medição de arbustos e árvores com diâmetro entre 5 e 10 cm.

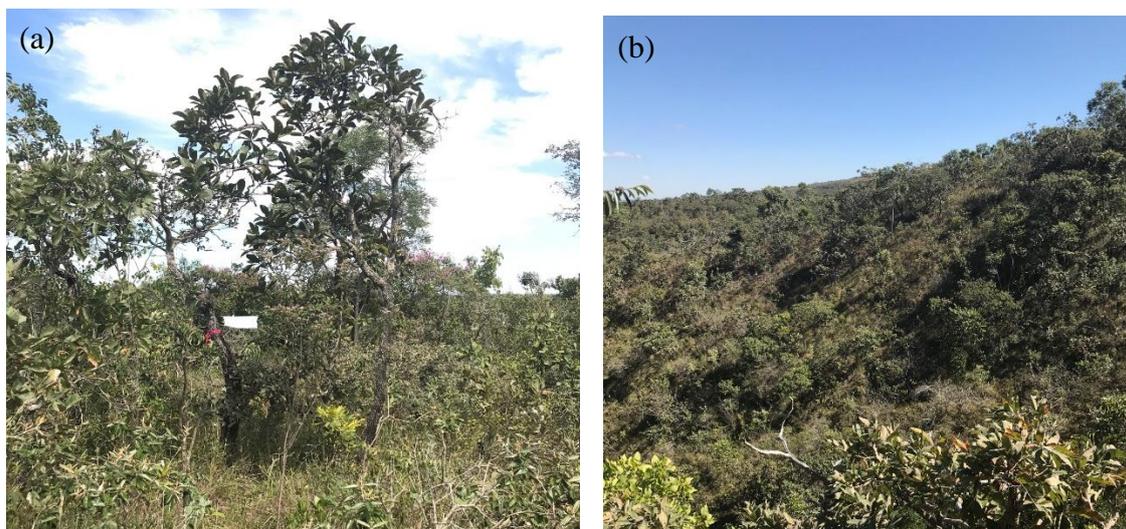


Figura 6 - (a) e (b): Cerrado no Parque Nacional de Brasília (PNB).

Além de dados do IFN, também foram utilizados dados de inventário coletados na Fazenda Água Limpa (FAL), da Universidade de Brasília. A FAL, situada a uma altitude de 1100m, entre as coordenadas 15°56'S - 47°58'W e 15°59'S - 47°58'W, é uma Fazenda Experimental e Estação Ecológica da Universidade de Brasília que, juntamente com a Reserva Ecológica do Instituto Brasileiro de Geografia e Estatística e o Jardim Botânico de Brasília, totalizam 9.000 ha de Cerrado inseridos na Área de Proteção Ambiental (APA) Gama Cabeça de Veado (FELFILI; DA SILVA, 1993). A fazenda ocupa uma área de aproximadamente 4.000 ha, sua vegetação predominante é o cerrado sentido restrito, mas também são encontradas outras fitofisionomias que variam desde campo limpo até matas de galerias (LIBANO; FELFILI, 2006; REZENDE et al., 2006).

Os dados da FAL utilizados nesta pesquisa foram coletados em 2005 em 18 parcelas permanentes de 0,1ha (50mx20m) que estão alocadas em uma área experimental. As parcelas foram divididas em outras 10 subparcelas de 10m x 10m, e, dentro de cada uma das subparcelas, foram coletados dados de diâmetro e altura dos indivíduos com Db (diâmetro da base medido a 30cm) igual ou superior a 5cm.

4.3. Estimativa de biomassa acima do solo

O desenvolvimento de metodologias para avaliação da biomassa acima do solo requer estimativas de biomassa *in situ* para calibração e validação de algoritmos de recuperação de biomassa. A partir dos dados coletados em campo foram estimadas outras variáveis dendrométricas, como a área basal e a biomassa.

A área basal (G_i) foi obtida segundo a equação $G_i = \sum g_{ji} (x)$

Onde g_{ij} é a área seccional da árvore j na parcela i (m^2), obtida a partir da equação

$$g = (\pi * DAB^2)/40.000$$

Onde π é uma constante igual a 3,14159 e DAB (cm) é o diâmetro à base da árvore (30 cm acima do solo).

A biomassa acima do solo (BAS) foi estimada para todos os indivíduos com o Db ≥ 5 cm a partir de uma equação alométrica ajustada para o cerrado *sensu stricto* (REZENDE et al., 2006).

$$BAS = 0,4913 + 0,0291 * DAB^2 * Ht$$

$$R^2 = 98,28\% \text{ e } Syx = 25,79\%$$

Onde DAB (cm) é o diâmetro à base da árvore e Ht é a altura em metros.

Os valores de biomassa produzidos usando as equações alométricas e todas as variáveis específicas da árvore foram somados e normalizados para produzir estimativas de BAS lenhoso em $Mg \cdot ha^{-1}$.

4.4. Processamento dados ópticos

Foram utilizadas cenas do satélite *RapidEye* adquiridas através do Serviço Florestal Brasileiro cobrindo toda a área de estudo (Tabela 3). As imagens *RapidEye* foram escolhidas em razão da sua resolução espacial (5m) e da banda *red edge*. Composto por uma constelação de cinco satélites, o sistema *RapidEye* fornece imagens em áreas relativamente grandes (faixas de 77km) com uma resolução espacial de 5m e uma resolução temporal de 1 dia (KROSS et al., 2015). Em relação a resolução espectral, o *RapidEye* apresenta bandas do visível, do infravermelho próximo e também a banda *red edge*, o que pode contribuir para avaliação de aspectos da vegetação. A banda *red edge* (690-730 μm) está localizada entre as bandas do vermelho (630-685 μm) e do infravermelho próximo (760-850 μm).

Tabela 2 - Cenas do satélite *RapidEye* adquiridas através do Serviço Florestal Brasileiro utilizadas para processamento dos índices de vegetação.

Cenas <i>RapidEye</i>	Data
2231727_2011-09-01T142332_RE5_3A-NAC_9878530_139445_0_2	01/09/2011
2231827_2011-06-20T143004_RE3_3A-NAC_9787921_138758_0_11	20/06/2011
2231828_2011-09-01T142328_RE5_3A-NAC_9828364_139008_13	01/09/2011
2331702_2011-09-01T142331_RE5_3A-NAC_9878542_139445_0_8	01/09/2011
2331803_2011-09-20T142153_RE5_3A-NAC_9837818_139076_0_0	20/09/2011
2331903_2011-09-20T142149_RE5_3A-NAC_9837824_139076_0_7	20/09/2011
2231927_2011-09-01T142325_RE5_3A-NAC_11809590_154387_0_1	01/09/2011
2231928_2011-09-01T142325_RE5_3A-NAC_9879244_139445_4	01/09/2011
2331701_2011-09-01T142332_RE5_3A-NAC_9878508_139445_4	01/09/2011
2331703_2011-06-22T143244_RE5_3A-NAC_9833172_139013_10	22/06/2011
2331704_2011-09-20T142156_RE5_3A-NAC_10911877_148037_0_1	20/09/2011
2331802_2011-09-01T142328_RE5_3A-NAC_9878512_139445_0_15	01/09/2011
2331804_2011-09-20T142152_RE5_3A-NAC_9837860_139076_0_0	20/09/2011
2331902_2011-09-01T142324_RE5_3A-NAC_9878562_139445_0_5	01/09/2011
2331904_2011-10-09T141949_RE5_3A-NAC_9789181_138761_0_9	09/10/2011

Dados de reflectância foram obtidos através do software *ERDAS IMAGINE* 2011 para as bandas 2, 3, 4 e 5, correspondentes as bandas do verde, vermelho, vermelho de borda e infravermelho próximo. A partir dos dados de reflectância foram calculados índices de vegetação (Tabela 3).

A reflectância da vegetação está relacionada aos pigmentos da planta que são responsáveis pela absorção, reflexão e transmissão da radiação eletromagnética incidente (NETO, 2018). Os IVs são utilizados para realçar a reflectância da vegetação por meio da combinação de determinadas regiões do espectro eletromagnético (HUETE et al., 2002).

Tabela 3 - Índices de vegetação.

Índice	Sigla	Fórmula	Referência
<i>Normalized Difference Vegetation Index</i>	NDVI	$\frac{\rho NIR - \rho R}{\rho NIR + \rho R}$	ROUSE <i>et al.</i> (1974)
<i>Normalized Difference Red Edge Index</i>	NDRE	$\frac{\rho NIR - \rho RE}{\rho NIR + \rho RE}$	FITZGERALD <i>et al.</i> (2010)
<i>Green Normalized Difference Index</i>	GNDVI	$\frac{\rho NIR - \rho G}{\rho NIR + \rho G}$	GITELSON; MERZLYAK (1996)
<i>Red Edge Chlorophyll Index</i>	CI _{rededge}	$\frac{\rho NIR}{\rho RE} - 1$	GITELSON <i>et al.</i> (2005)
<i>Green Chlorophyll Index</i>	CI _{Green}	$\frac{\rho NIR}{\rho G} - 1$	GITELSON <i>et al.</i> (2005)

O NDVI (*Normalized Difference Vegetation Index*) é apontado como um dos índices pioneiros em estudos da vegetação (BANNARI *et al.*, 1995). O NDVI é altamente correlacionado com o verde da vegetação e é o índice mais utilizado em pesquisas relacionadas à dinâmica da cobertura vegetal (LI, Fei *et al.*, 2016; GHOSH; BEHERA, 2018; GUERINI FILHO *et al.*, 2019). O NDRE e o GNDVI são considerados variações do NDVI. No NDRE há a inclusão da banda *red edge* com o intuito de aumentar a sensibilidade à clorofila (CARRIJO *et al.*, 2020; GITELSON; MERZLYAK, 1996), já o GNDVI utiliza a banda verde.

O índice CI_{green} apresenta alta correlação com o teor de clorofila e índice de área foliar. Por sua vez, o CI_{rededge}, é uma variação CI_{green} com a inclusão da banda *red edge*. A seleção dos índices de vegetação foi feita por meio da análise de correlação entre os cinco índices calculados e a biomassa, sendo essa análise precedida pelo teste de normalidade de Shappiro-Wilk (SHAPIRO; WILK, 1965) para definir a metodologia de correlação a ser aplicada (paramétrica ou não-paramétrica) através do software RStudio 1.0.143 (RStudio, 2016). A correlação entre variáveis explicativas (multicolinearidade) foi avaliada pelo teste com o fator de inflação da variância (*Variance Inflation Factor* - VIF).

4.5. Modelagem: Redes Neurais

Os principais passos metodológicos para predição de biomassa são mostrados no fluxograma a seguir (Figura 7). As etapas são detalhadas nas próximas subseções.

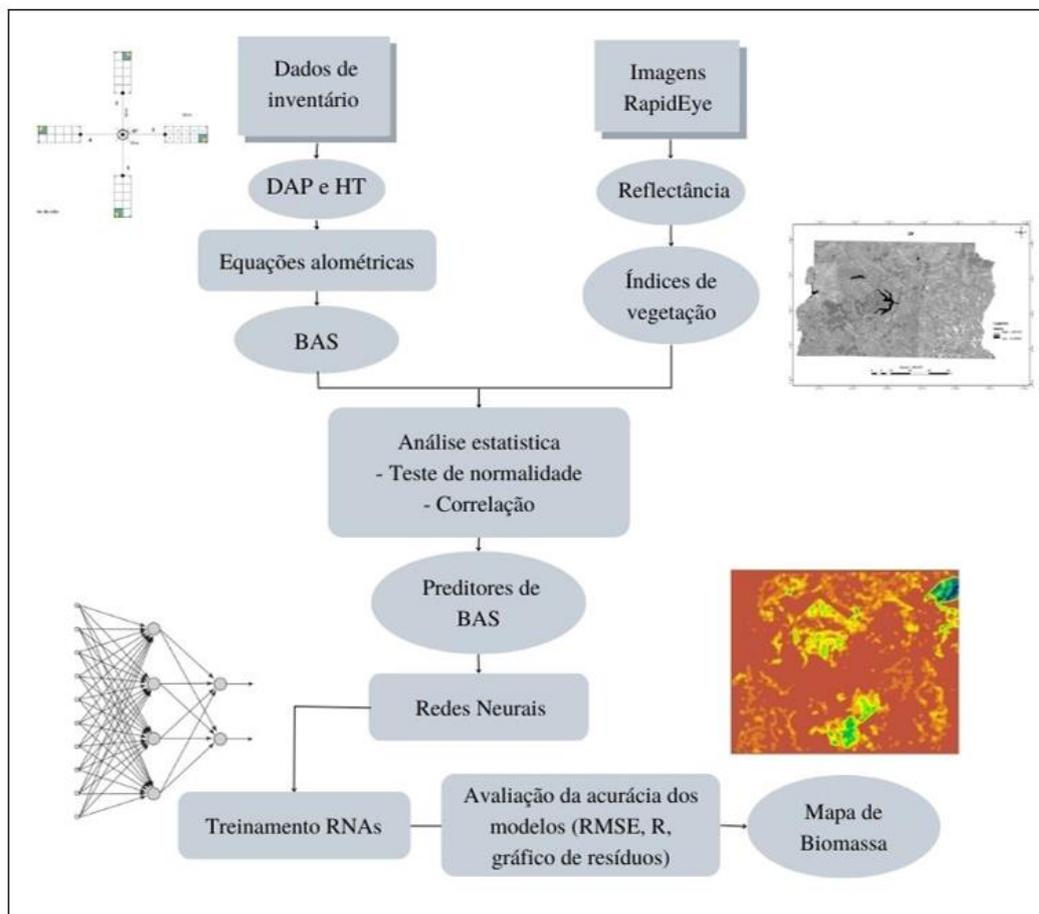


Figura 7 - Fluxograma para modelagem de biomassa.

Foi aplicado um treinamento supervisionado de 500 redes neurais utilizando a ferramenta *Intelligent Problem Solver* (IPS) disponível no software Statistica 7 (STATSOFT, 2007), isto é, as variáveis de entrada e de saída foram indicadas para a rede por meio da ferramenta IPS (CARRIJO et al., 2020). Essa ferramenta padroniza os dados entre 0-1 e testa diversas arquiteturas, o que permite a otimização da arquitetura da RNA, definindo o melhor número de neurônios na camada oculta e as melhores funções de ativação das camadas ocultas e de saída (BINOTI et al., 2015; VALE et al., 2017), visando atingir a menor taxa de erro nas previsões (MIGUEL et al., 2018). O algoritmo utilizado pelo IPS para o processamento das redes neurais foi o algoritmo quase-Newton de Broyden-Fletcher-Goldfarb-Shanno (BFGS) (BROYDEN, 1970; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970). O método quasi-Newton, além de ser mais popular, possui grande poder de resolução para problemas de otimização e previsões (GUERROUT et al., 2018).

Foram selecionadas aleatoriamente 42 das 60 parcelas amostrais (correspondendo 70% do total) coletadas no contexto do Inventário Florestal Nacional (IFN) e das amostras permanentes da Fazenda Água Limpa para o treinamento das redes neurais. As 18 parcelas restantes foram utilizadas para a validação dos resultados (ZUCCHINI, 2000).

As redes treinadas possuem arquitetura do tipo Perceptron de Múltiplas Camadas (*Multilayer Perceptron – MLP*), em que a camada de entrada foi constituída pelos índices de vegetação, uma camada oculta constituída por n neurônios e uma camada de saída constituída por um neurônio para estimar a biomassa acima do solo (BAS) (CARRIJO et al., 2020; GONÇALVES et al., 2021). A arquitetura MLP se distingue pela presença de uma ou mais camadas ocultas, onde a função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede uma maneira útil. Adicionando-se uma ou mais camadas ocultas, tornamos a rede capaz de extrair estatísticas de ordem elevada. (HAYKIN, 2001).

O neurônio é o elemento fundamental da estrutura da RNA visto que é responsável pelo processamento de dados e informações ao receber os valores de entrada (IVs) até que o resultado de interesse (BAS) seja alcançado na saída dos dados. A funcionalidade dos neurônios das RNAs é estimada pela combinação e reprodução de informações baseadas em conexões entre os n possíveis *inputs* (variáveis de entrada) x_1, x_2, \dots, x_n e o *output* (variável de saída) y . Para cada entrada é definido um peso w que representa as sinapses onde as redes MLP armazenam o conhecimento, fazendo com que processo de aprendizado/treinamento alcancem estimativas dos valores ótimos desse parâmetro (CARRIJO et al., 2020; GONÇALVES et al., 2021; GORUNESCU; BELCIUG, 2016). O neurônio artificial é dado matematicamente, por:

$$Y_k = \varphi (V_k)$$

Onde Y_k é o output do neurônio artificial; φ é a função de ativação; e V_k é o combinador do output, dado por:

$$V_k = \sum X_m W_m$$

Onde V_k é o combinador linear; X_m é o input m ; e W_m é o peso sináptico m .

Primeiramente, os pesos de todas as redes foram gerados aleatoriamente. Em seguida, o valor de atualização individual evolui durante o processo de aprendizado com base na função de erro (MIGUEL et al., 2018). O treinamento da rede continuou até que a taxa de erro fosse reduzida a um intervalo aceitável entre os valores previstos e os valores reais fornecidos à rede, conhecido como regra delta, ou até que o número máximo

de ciclos fosse atingido (MIGUEL et al., 2018; SHIBLEE; CHANDRA; KALRA, 2010).

A performance dos modelos foi analisada estatisticamente através do erro quadrático médio em percentual (RMSE%), da correlação entre os valores estimados e observados (R) e da análise gráfica de resíduos (CHEN et al., 2019). Estes indicadores são frequentemente utilizados para medir o desempenho modelos de biomassa (YU et al., 2019).

$$RMSE\% = \frac{100}{\bar{Y}} * \sqrt{\frac{\sum(Y_i - \hat{Y}_i)^2}{n}}$$

Onde \bar{Y} é a média dos valores observados de BSAS; Y_i é o valor observado de BSAS na parcela i; e \hat{Y}_i é o valor estimado de BSAS pela RNA na parcela i.

Em geral, um valor de R mais próximo de 1 e baixos valores de RMSE% indicam uma melhor estimativa do desempenho do modelo (LI et al., 2019).

A RNA que apresentou os melhores resultados foi submetida ao processo de validação utilizando o teste t de *Student*, e posteriormente foi analisada a diferença agregada em percentual (DA%), que indica estatisticamente se houve uma sub ou superestimação (CARRIJO et al., 2020; GONÇALVES et al., 2021; MIGUEL et al., 2015; VALE et al., 2017). Essas análises foram realizadas por meio do software *Microsoft Excel 2016*®.

5. RESULTADOS

5.1. Inventário Florestal

A partir dos dados coletados em campo foram gerados os primeiros resultados estatísticos das áreas de cerrado do DF (Tabela 4).

Tabela 4 - Variáveis dendrométricas estimadas a partir de inventário florestal para as áreas de cerrado do DF. DAP = diâmetro à altura do peito (cm), Ht = altura total (m), G = área basal (m².ha¹), BAS = biomassa acima do solo (Mg.ha¹).

	DAP	Ht	G	BAS
Mínimo	7,72	2,26	2,63	5,12
Máximo	22,64	8,87	19,95	39,46
Média	11,57	3,52	10,32	16,55
Variância	9,70	1,79	12,85	73,76
Desvio	3,11	1,34	3,58	8,59
CV%	26,91	37,94	34,75	51,89

5.2. Modelagem

5.2.1. Seleção das variáveis independentes

Na Tabela 5 estão os valores médios obtidos para cada um dos índices de vegetação testados. A partir do teste de Shappiro-Wilk ficou demonstrado que as variáveis não apresentavam normalidade e, em função deste resultado, foi utilizada a matriz de correlação de Spearman para dados não-paramétricos.

Tabela 5 - Média das variáveis independentes do cerrado do DF. NDVI = índice de vegetação da diferença normalizada; NDRE = índice de vegetação da diferença normalizada com a banda red edge; GNDVI = índice de vegetação da diferença normalizada com a banda verde; $CI_{red\ edge}$ = índice de clorofila com a banda red edge; CI_{green} = índice de clorofila com a banda verde

	NDVI	NDRE	GNDVI	$CI_{red\ edge}$	CI_{green}
Média	0,1516	0,1062	0,0780	0,2428	0,1766

A matriz de correlação demonstra a ocorrência de dependência entre as variáveis. A matriz de correlação de Spearman (Tabela 6), apresentou valores moderados para os índices GNDVI ($r = 0,77$) e CI_{green} ($r = 0,77$).

Tabela 6 – Matriz de correlação segundo Spearman entre as variáveis estudadas.

	BAS	G	NDVI	NDRE	GNDVI	$CI_{red\ edge}$	CI_{green}
BAS	1						
G	0,76**	1					
NDVI	0,71**	0,56**	1				
NDRE	0,67**	0,53**	0,97**	1			
GNDVI	0,77**	0,58**	0,82**	0,76**	1		
$CI_{red\ edge}$	0,67**	0,52**	0,97**	1,00**	0,76**	1	
CI_{green}	0,77**	0,57**	0,82**	0,75**	1,00**	0,76**	1

**Significante a 99% probabilidade ($\alpha = 0,01$). Em que BAS = biomassa acima do solo ($Mg \cdot ha^{-1}$). G = área basal (m^2); NDVI = índice de vegetação de diferença normalizada; NDRE = índice de vegetação de diferença normalizada com a banda red edge; GNDVI = índice de vegetação de diferença normalizada com a banda verde; CI_{green} = índice de clorofila com a banda verde; $CI_{red\ edge}$ = índice de clorofila com a banda red edge.

A partir do fator de inflação da variância (VIF), foi constatado que há multicolinearidade entre os índices GNDVI e CI_{green} . A multicolinearidade demonstra que duas ou mais variáveis explanatórias possuem uma relação linear exata. Dessa forma, uma variável não causa efeito de complementaridade sobre outra. No caso de variáveis

de sensores remotos, isso pode ter acontecido devido aos dois índices utilizarem as mesmas bandas em seu cálculo.

Foram realizados testes baseado em regressões *stepwise* para escolha dos melhores índices para estimativa de BAS no cerrado, considerando o menor valor possível de p. A partir destes testes, os índices GNDVI e NDRE foram retidos para modelagem.

5.2.2. Treinamento das redes neurais

As cinco redes de melhor desempenho inicial dentre as 500 RNAs treinadas apresentaram estatísticas de ajuste e precisão satisfatórias para o cerrado *sensu stricto* do DF. As redes 2, 3 e 4 apresentaram os melhores resultados, com valores de coeficiente de correlação (r) superiores a 0,84 e erros de estimativa abaixo de 18%. Entretanto, a rede neural 2 foi a que demonstrou melhor capacidade preditiva (Tabela 7).

Tabela 7 - Características e estatísticas de precisão das redes neurais artificiais selecionadas para predição da biomassa acima do solo do cerrado *sensu stricto* do DF.

RNA	Arquitetura	Função de ativação		Ajuste		Validação	
		Camada oculta	Camada de saída	Qmre (%)	R	Qmre (%)	R
1	MLP 2-9-1	Logística	Tangencial	18,85	0,839	18,07	0,884
2	MLP 2-8-1	Tangencial	Tangencial	16,52	0,908	13,36	0,914
3	MLP 2-8-1	Logística	Logística	18,15	0,856	13,76	0,916
4	MLP 2-6-1	Logística	Identity	17,49	0,844	15,02	0,902
5	MLP 2-9-1	Tangencial	Logística	19,05	0,828	20,38	0,861

RNA = redes neurais artificiais; MLP = *Multilayer perceptron* (Perceptron multi camadas); RMSE = *Root mean-Square Error* (Raiz do erro quadrático médio); r = correlação entre os valores observados e estimados.

Com base nos resultados da análise de desempenho das cinco redes, a rede dois (RNA 2) foi escolhida por apresentar um padrão aceitável para distribuição de resíduos e acurácia nas predições de biomassa acima do solo ($\text{Mg}\cdot\text{ha}^{-1}$). O histograma referente a classe de erros apresentou maior concentração de resíduos nas classes centrais do gráfico, evidenciando a baixa de grandes níveis de sub ou superestimativa (Figura 8).

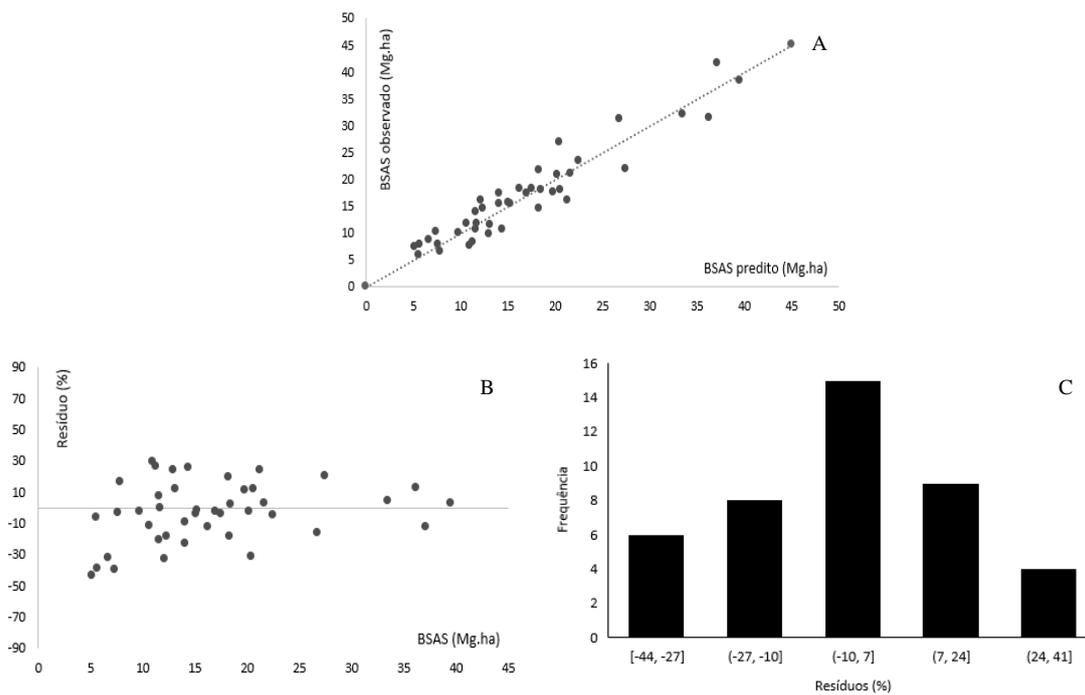


Figura 8 - Valores observados e preditos (A), distribuição de resíduos (B) e distribuição de classes de erro (C).

A arquitetura da rede foi composta por três camadas, sendo elas: camada de entrada, constituída por dois neurônios, determinada pelas variáveis predictoras (GNDVI e NDRE): uma camada oculta, a qual é responsável pelo processamento dos dados e ativada por meio de uma função tangencial e uma camada de saída, constituída pela variável de interesse (BAS) e ativada por meio de uma função tangencial (Figura 8). A camada oculta foi constituída por oito neurônios determinados pela ferramenta *Intelligent Problem Solver* (IPS) (MIGUEL et al., 2018).

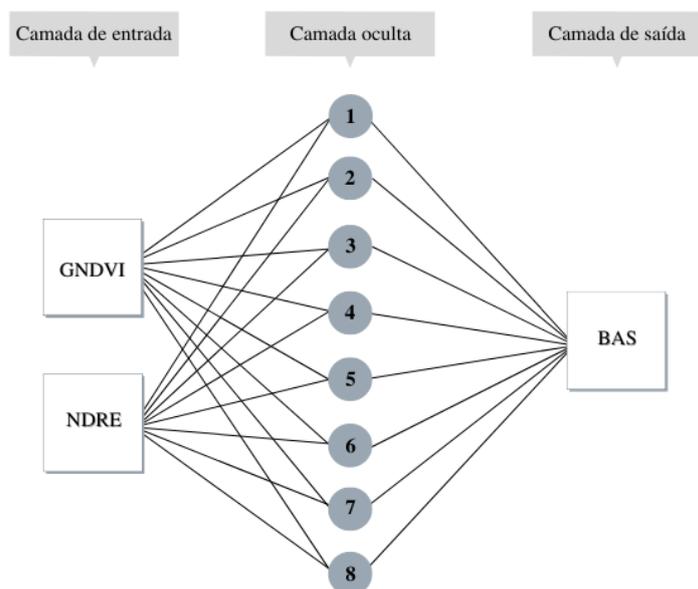


Figura 9 - Arquitetura da RNA selecionada para predição da biomassa acima do solo no cerrado do DF.

5.3. Mapas de biomassa

A partir do treinamento das redes neurais foi possível expandir as estimativas de BAS para toda área coberta por formação savânica no Distrito Federal. Registramos que as áreas com maior quantidade de BAS são áreas de preservação como o Parque Nacional de Brasília, a Estação Ecológica de Águas Emendadas, a Estação Ecológica da Universidade de Brasília (Fazenda Água Limpa) e a Estação Ecológica do IBGE, o que reforça a importância dessas áreas destinadas a conservação dos recursos naturais (Figura 11).

Fragmentos de Cerrado pequenos e mais próximos às áreas urbanas tendem a apresentar BAS mais baixa, na faixa de 6 a 13 Mg.ha⁻¹. Além da heterogeneidade inerente da vegetação, uma possível causa dos valores mais baixos de BAS nas menores áreas é a fragmentação de habitats. A divisão de áreas contínuas de cobertura vegetal em fragmentos isolados resulta na separação de populações, redução da qualidade de habitats e aumento da área de borda. O aumento na proporção de borda em relação a área torna os fragmentos mais susceptíveis às perturbações antrópicas, como fogo, caça, animais domésticos, exploração madeireira e espécies invasoras (COELHO et al., 2020; GAMARRA et al., 2021)

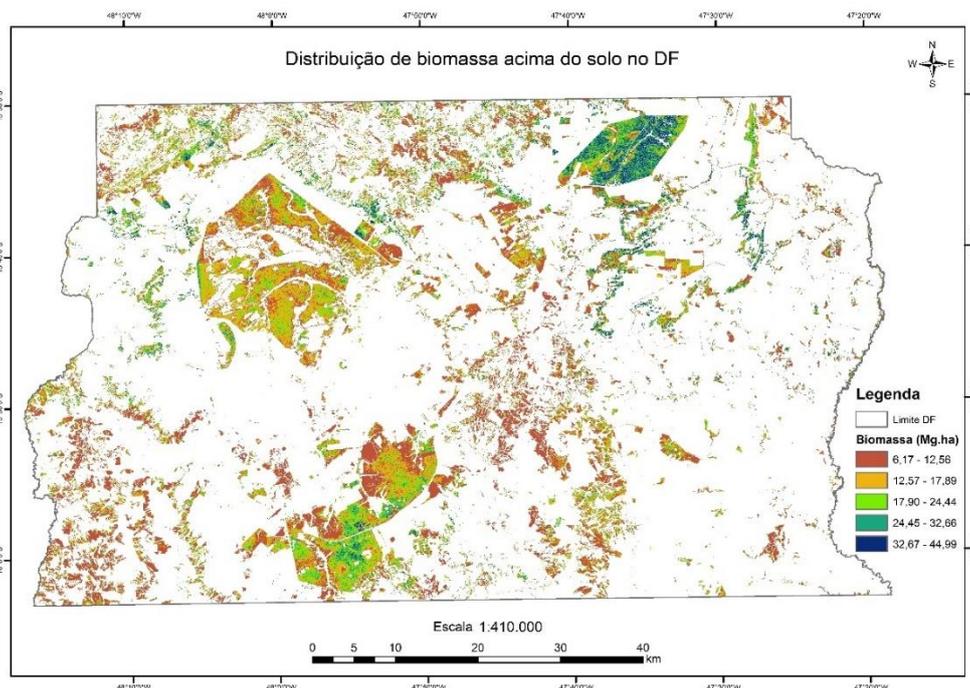


Figura 10 - Mapa de biomassa acima do solo em áreas de cerrado no DF.

As Unidades de Conservação localizadas no Distrito Federal prestam importantes serviços ambientais como a regulação climática, captura de carbono atmosférico, fornecimento de água e proteção da biodiversidade. Do ponto de vista de manutenção de carbono, as médias de BAS em vegetação do cerrado estimada nas maiores UC's do DF estão apresentadas na Tabela 8.

Tabela 8 – Estimativa da biomassa acima do solo em Unidades de Conservação do DF.

UCs	Média	Desvio Padrão
Estação Ecológica Águas Emendadas	26,94	8,41
Estação Ecológica da UnB	17,15	6,98
Estação Ecológica do IBGE	19,37	7,08
Estação Ecológica do Jardim Botânico	15,26	4,74
Parque Nacional de Brasília	15,25	4,64

A Estação Ecológica de Águas Emendadas apresentou o maior valor médio de BAS, com $26,94 \pm 8,41 \text{ Mg}\cdot\text{ha}^{-1}$. Jacón et al. (2021) encontraram uma média de biomassa similar em áreas de cerrado ($34,5 \pm 2,7 \text{ Mg}\cdot\text{ha}^{-1}$) utilizando diferentes métricas hiperespectrais e modelos de aprendizado de máquina (*machine learning*). A maior média de biomassa em Águas Emendadas pode ser explicada devido as áreas de cerrado denso,

com árvores pouco esparsas e mais de 50% de cobertura vegetal. Além disso, o arquivo vetorial utilizado para delimitação das áreas de vegetação cerrado no presente estudo apresentou inacurácias nos limites da vegetação, especialmente em áreas de transição, que levaram a incorporação de tipologias vegetais diferentes, incluindo partes de áreas de mata ciliares com vegetação florestal.

Biomassa acima do solo (Mg.ha) do Cerrado nas UC's do DF

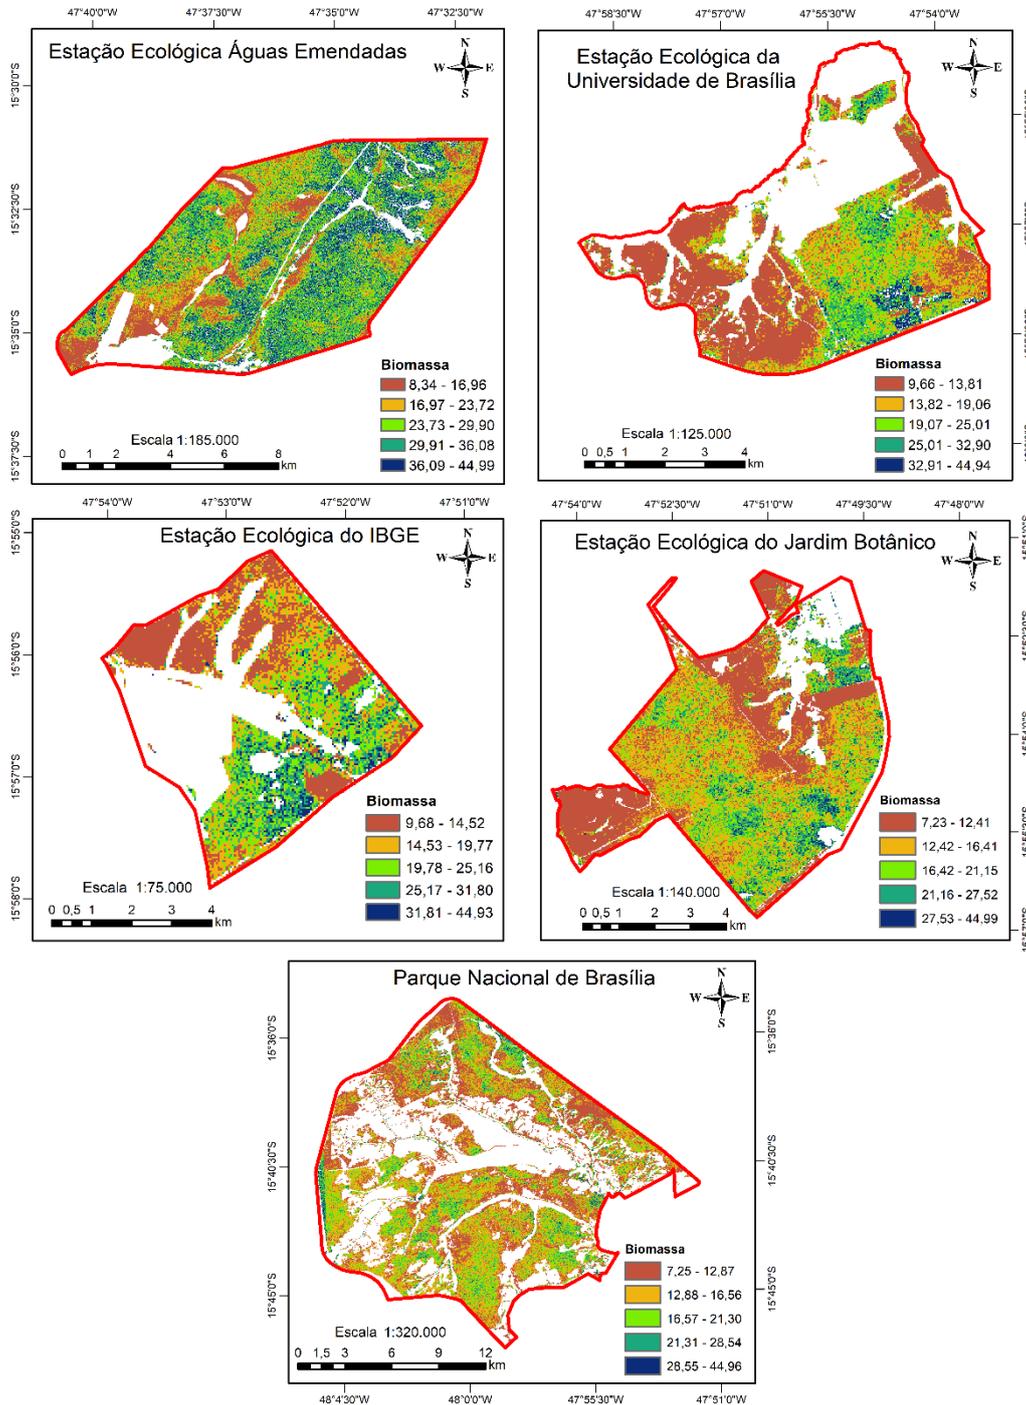


Figura 11 - Mapas de biomassa acima do solo do cerrado nas Unidades de Conservação do DF.

5.3.1. Análise Estatística

O teste t de *Student* demonstrou que as RNAs selecionadas apresentaram valor de p maior que $\alpha = 0,05$ ($p = 0,893$), indicando que não existem diferenças estatísticas

significativas entre os valores preditos pelas redes neurais e os valores do inventário florestal nas parcelas de validação. A diferença agregada demonstrou leve viés de superestimação da RNA para predição da biomassa (DA% = -0,65 %), corroborando os resultados de precisão encontrados para o treinamento das RNA.

6. DISCUSSÃO

6.1. Análise geral dos dados

O valor médio de biomassa acima do solo (BAS) encontrado no presente estudo ($16,55 \pm 8,5 \text{ Mg}\cdot\text{ha}^{-1}$) para áreas de vegetação de cerrado estão próximos aos resultados encontrados por BISPO *et al.* (2020) na bacia hidrográfica do Rio Vermelho em Goiás e por COSTA *et al.* (2021) em áreas de preservação do bioma Cerrado (Parque Nacional da Serra do Cipó, Parque Nacional da Chapada dos Veadeiros, Floresta Nacional de Paraopeba e Floresta da Universidade de São João Del-Rei). BISPO *et al.* (2020) e COSTA *et al.* (2021) encontraram distribuições médias de $18,66 \text{ Mg ha}^{-1}$ e $19,72 \text{ Mg}\cdot\text{ha}^{-1}$, respectivamente.

Morandi *et al.* (2020) calcularam os valores BAS para a área central do bioma Cerrado utilizando dados de parcelas de campo alocadas em unidades de conservação e áreas de reserva legal de propriedades privadas, estimando uma média de $20,4 \pm 6,0 \text{ Mg ha}^{-1}$. Vale e Felfili (2005) encontraram uma média de biomassa aérea sendo igual a $12,4 \text{ Mg}\cdot\text{ha}^{-1}$ em áreas de cerrado da Fazenda Água Limpa da Universidade de Brasília. Oliveira *et al.* (2019) encontraram uma média de $10,9 \text{ Mg}\cdot\text{ha}^{-1}$ em uma área de Cerrado no município de Jaborandi no oeste baiano. Estes valores indicam que a variação do estoque de BAS estimada entre as parcelas utilizadas neste estudo e dos outros estudos similares no cerrado representa a heterogeneidade estrutural da vegetação. Variações espaciais da biomassa ocorrem principalmente em função de diferenças físicas do ambiente, como luminosidade, relevo e condições dos solos (LU *et al.*, 2016, Elias *et al.* 2019), ou regime de perturbações, como incêndios e desmatamento (ROITMAN *et al.*, 2018). A heterogeneidade fisiográfica se reflete no porte dos indivíduos arbóreos e, conseqüentemente, na capacidade de armazenagem de carbono, visto que os troncos apresentam a maior capacidade de armazenagem de biomassa acima do solo (ROQUETTE, 2018; VALE; FELFILI, 2005). A diversidade estrutural da vegetação pode ser notada nos valores de DAP que variam de 7,7 a 22,7 cm. Esta diversidade de formas

é uma característica típica da vegetação de cerrado e ocorre tanto entre espécies como dentro de uma mesma espécie (REZENDE et al., 2006).

Devido às dificuldades nas medições de campo em vegetações naturais, normalmente heterogêneas e com grande diversidade florística, fisionômica e fenológica, a quantificação de biomassa se torna uma tarefa complexa, uma vez que há pouca disponibilidade de dados quantitativos (FERRAZ et al., 2014; SCHOENINGER et al., 2008). Nesse sentido, essas limitações são minimizadas através do monitoramento regular do cerrado por vias aéreas, imagens de satélites e compreensão dos processos ecológicos (ROITMAN et al., 2018).

6.2. Modelagem

6.2.1. Seleção das variáveis independentes

Os índices que apresentaram maior correlação com a biomassa foram o GNDVI e o CI_{green} . O GNDVI é calculado de forma semelhante ao NDVI, porém é utilizada a banda espectral verde, e está diretamente relacionado com a proporção de radiação fotossinteticamente ativa absorvida, índice de área foliar (LAI) e com a biomassa (CANDIAGO et al., 2015). O CI_{green} é um índice desenvolvido por Gitelson et al. (2005) que evidencia o teor de clorofila do dossel e o índice de área foliar.

A correlação encontrada entre os índices de vegetação e a biomassa no presente estudo foi moderada, indicando um desempenho também moderado, similar ao observado em diversas pesquisas que envolvem índices de vegetação agregados a variáveis relacionadas com a comunidade arbórea, como biomassa, volume de madeira e circunferência de tronco (MACHADO et al., 2017; MIGUEL et al., 2015, 2018; PANDA; AMES; PANIGRAHI, 2010; ZHU; LIU, 2015). Os prováveis motivos para o comportamento moderado da correlação entre os IVs e a biomassa estão relacionados aos efeitos da atmosfera, fontes de radiação e efeitos do solo, além dos aspectos inerentes à própria vegetação, como as desuniformidades das copas e do dossel e a arquitetura heterogênea da vegetação na reflectância da radiação solar detectada pelos sensores (CARRIJO et al., 2020; GONÇALVES et al., 2021; MIGUEL et al., 2015; PONZONI, 2001).

Em florestas e savanas nativas, o crescimento e a conformação das copas são irregulares e desuniformes, resultando em uma interferência das grandes copas na

reflectância das árvores menores e, conseqüentemente, nos valores das correlações (MACHADO et al., 2017). A estrutura do dossel, a área foliar das copas e a reflexão do fundo do dossel são fatores condicionantes das mudanças de reflectância da vegetação nas imagens de sensoriamento remoto, sendo características específicas de cada fitofisionomia em cada região de ocorrência (LI et al., 2014). Além de heterogeneidade dos indivíduos arbóreos, outra característica importante que influencia a qualidade das correlações são aspectos topográficos da paisagem, como relevo e altitude. Estudos evidenciam baixa correlação entre variáveis dendrométricas e índices de vegetação em locais com grandes variações espaciais nos atributos edáficos (CANAVESI; PONZONI; VALERIANO, 2010; CASTILLO et al., 2017).

Os valores significativos e positivos de correlações encontrados entre os IVs e a biomassa podem ser explicados pela relação positiva que os IVs têm com o crescimento radial do fuste e área foliar (ALMEIDA et al., 2015; BABST et al., 2014a, 2014b; VICENTE-SERRANO et al., 2016). Estes parâmetros tem relação direta com o acúmulo de biomassa, captura de carbono e, conseqüentemente, teor de carbono da madeira (VICENTE-SERRANO et al., 2016). Os índices de vegetação não podem estimar diretamente a biomassa (HEROLD et al., 2019). No entanto, pode ser relacionado diretamente com a quantidade de material fotossintético e a produtividade florestal (MENDES, 2019).

6.2.2. Redes neurais

O treinamento das redes neurais determinou que o índice GNDVI em complementaridade com o índice NDRE predizem a BAS no cerrado com melhor acurácia. Os dois índices são derivados do NDVI, que tem sido um índice bastante utilizado em análises da vegetação (BAYMA; SANO, 2015; ZHU; LIU, 2015). O GNDVI associa a banda verde com a banda do infravermelho, o que pode melhorar a visualização de sanidades do dossel e da quantidade de clorofila contida nas folhas (GITELSON; MERZLYAK, 1996). O NDRE utiliza a banda *red edge* onde a radiação é fortemente absorvida pelos pigmentos de clorofila, enquanto a radiação na banda NIR é refletida com base na estrutura da folha (KANKE et al., 2016)

Tradicionalmente, a precisão das estimativas de biomassa florestal é avaliada pelo cálculo do erro quadrático médio (RMSE) e do coeficiente de correlação de Pearson dos valores estimados e observados. Este método é responsável diretamente pela qualidade

das estimativas (CONGALTON, 2001; LU et al., 2016). As RNAs treinadas proporcionaram estatísticas de ajuste e precisão satisfatórias, fornecendo coeficientes de correlação em torno de $R \geq 0,90$ e erros de estimativa (RMSE) entre 13 e 20%. A rede com o melhor resultado no presente trabalho apresentou $R=0,91$ e $RMSE=13,36$, o que demonstra resultados consistentes, tendo em vista a complexidade das variáveis estudadas e a variabilidade vegetacional encontrada nas áreas de Cerrado (REZENDE et al., 2006; SYDOW et al., 2017). É provável que uma maior intensidade de amostragem poderia melhorar a relação entre os IVs e a BAS. No entanto, erros ainda existiriam devido a variabilidade inerente da vegetação (REZENDE et al., 2006).

A heterogeneidade na estrutura da vegetação dificulta as estimativas de BAS a partir de dados de sensoriamento remoto, que podem ser pouco sensíveis a certas mudanças. Além disso, a saturação dos sinais espectrais captados pelos sensores ópticos, a contribuição da vegetação de sub-bosque e a ocorrência de sombra faz com que os modelos às vezes subestimem ou superestimem a biomassa (KUMAR et al., 2015; LU et al., 2017).

O poder preditivo é demonstrado pela relação entre os valores observados e os valores preditos (Figura 9A), onde o resultado obtido no presente trabalho indica boa acurácia da rede neural escolhida para estimar a biomassa acima do solo no cerrado. A análise gráfica dos resíduos é fundamental para corroborar os resultados das estatísticas de precisão, uma vez que erros de tendência podem não ser detectados por essas estatísticas (DRAPER; SMITH, 1998). No nosso caso, o gráfico de dispersão de resíduos (Figura 9B) apresentou uma distribuição adequada dos erros, sem tendências visíveis, com pontos compactos e bem distribuídos ao longo da linha de regressão. Em relação a frequência de erros, a maior parte dos valores ficou concentrada entre -10% e 7% no treinamento das redes. A análise dos resíduos em histogramas auxilia e minimiza os erros de interpretação devido à ocorrência de pontos sobrepostos (CAMPOS; LEITE, 2017).

O resultado encontrado nesta pesquisa demonstra a eficiência das redes neurais na predição de BAS e corrobora com outros estudos encontrados na literatura, como Silva et al. (2019), que encontraram RMSE variando entre 12% e 17% na estimativa de volume e BAS em uma área de cerrado em Montes Claros - MG. Em trabalhos com florestas no Irã, Vahedi (2016) obteve RMSE variando entre 8% e 15% na predição de BAS e Miguel et al. (2015) apontou um erro padrão da estimativa de 8% para estimativa de biomassa

em uma área de cerrado no Município de Palmas – TO.

Os valores do presente trabalho, semelhantes aos diversos encontrados na literatura em outras regiões do bioma Cerrado, indicam que as técnicas de inteligência artificial (IA) empregadas neste estudo podem ser bons indicadores estatísticos na estimativa de biomassa no cerrado brasileiro. Este resultado pode ser atribuído à capacidade das técnicas de IA em capturar a não linearidade presente nos dados, pois podem aproximar funções complexas (SILVA et al., 2019), sendo essa uma característica importante para a modelagem de parâmetros florestais, visto que estes geralmente não apresentam comportamento linear (VIEIRA et al., 2018).

6.3. Análise estatística

A RNA que apresentou os melhores resultados foi submetida ao teste t de *Student* para validação. O resultado do teste t retornou um valor de $p > 0,05$, logo aceitou-se a hipótese nula de igualdade entre os valores observados e preditos pela rede, demonstrando a acurácia das estimativas. Segundo Serpen e Gao (2014), as RNAs tem grande capacidade de aprender e extrair padrões de um conjunto de dados para, posteriormente, generalizar e aplicar sem perder a acurácia. A eficácia e acurácia das RNA's selecionadas também foi confirmada pela diferença agregada (DA%), que apresentou um valor percentual pequeno (-0,65%) de superestimação na estimativa de BAS no Cerrado do Distrito Federal.

As RNAs se mostraram como um método eficaz e preciso na estimativa de BAS no cerrado por meio de índices de vegetação. Este conhecimento é, portanto, importante para o mapeamento da biomassa florestal e para a definição de políticas de redução de emissões de gases de efeito estufa e mitigação das mudanças climáticas ambientais. A metodologia desenvolvida no presente estudo, pode ser utilizada para o monitoramento dos recursos florestais, assim como, nortear e respaldar as tomadas de decisão.

7. CONCLUSÃO

Os modelos derivados das redes neurais artificiais associados a dados de sensoriamento remoto do satélite *Rapid Eye* apresentaram resultados satisfatórios, sendo eficazes na estimativa de BAS em áreas do bioma Cerrado. O índice de diferença normalizada com a banda verde (GNDVI) juntamente com índice de diferença

normalizada com a banda *red edge* (NDRE) proporcionaram os melhores ajustes do modelo para predição de BAS.

Redes neurais artificiais do tipo *Multilayer Perceptron*, utilizando funções de ativação tangenciais e o algoritmo de treino BFGS, foram acuradas e eficientes em associar índices de vegetação na estimativa de BAS no Cerrado.

Grande parte da escassez de estudos atuais relacionados à predição de biomassa no Cerrado se deve ao fato da dificuldade nas coletas de dados de inventário florestal para a calibração dos modelos baseados em sensoriamento remoto. Nesse sentido, os resultados dessa pesquisa se mostram promissores, diante dos dados disponíveis à sociedade civil, podendo impactar de forma positiva o direcionamento de planos estratégicos para conservação de áreas com grande estoque de biomassa e também áreas ameaçadas do bioma Cerrado.

8. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. Q. et al. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens TM - Landsat 5. **Floresta e Ambiente**, v. 22, n. 3, p. 368–376, 2015.

BABST, F. et al. Toward consistent measurements of carbon accumulation: A multi-site assessment of biomass and basal area increment across Europe. **Dendrochronologia**, v. 32, n. 2, p. 153–161, 1 jan. 2014a.

BABST, F. et al. Above-ground woody carbon sequestration measured from tree rings is coherent with net ecosystem productivity at five eddy-covariance sites. **New Phytologist**, v. 201, n. 4, p. 1289–1303, 1 mar. 2014b.

BACCINI, A. et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, p. 29, 2012.

BANNARI, A. et al. A review of vegetation indices. **Remote Sensing Reviews**, v. 13, n. 1–2, p. 95–120, 1995.

BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote Sensing of Aboveground Biomass in Tropical Secondary Forests: A Review. 2014.

BAYMA, A. P.; SANO, E. E. Séries temporais de índices de vegetação (NDVI e EVI) do sensor Modis para detecção de desmatamentos no bioma Cerrado. **Boletim de Ciências Geodésicas**, v. 21, n. 4, p. 797–813, 2015.

BERGAMASCHINE, L. C. **Políticas públicas e as contribuições potenciais do Cerrado para o cumprimento das metas brasileiras de redução das emissões de gases do efeito estufa**. [s.l.] Universidade de Brasília, Brasília - DF, 2017.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de Redes Neurais Artificiais para Estimação do Volume de Árvores. **Revista Ciência da Madeira - RCM**, v. 5, n. 1, p. 58–67, 2014.

BINOTI, M. L. M. DA S. et al. Redes neurais artificiais para estimação do volume de árvores. **Revista Arvore**, v. 38, n. 2, p. 283–288, 2014.

BINOTI, M. L. M. DA S. et al. Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais. **Cerne**, v. 21, n. 1, p. 97–105, 2015.

BISPO, P. DA C. et al. Woody Aboveground Biomass Mapping of the Brazilian Savanna with a Multi-Sensor and Machine Learning Approach. **Remote Sensing 2020**, Vol. 12, Page 2685, v. 12, n. 17, p. 2685, 19 ago. 2020.

BRAGA, A. DE P. **Redes Neurais Artificiais. Teoria e Aplicações**. Rio de Janeiro: [s.n.].

BRASIL. **Plano de ação para prevenção e controle do desmatamento e das queimadas: cerrado**. Brasília: [s.n.].

BRITO, A. et al. Metodologia da detecção do desmatamento no bioma Cerrado. In: **Mapeamento de Áreas Antropizadas Com Imagens de Média Resolução Espacial**. São José dos Campos, Brasil: Instituto de Pesquisas Espaciais - INPE, 2018. p. 18.

BROYDEN, C. G. The convergence of a class of double-rank minimization algorithms 1. General Considerations. **IMA Journal of Applied Mathematics**, v. 3, n. 1, p. 76–90, 1970.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: pergunta e respostas**. 5. ed. Viçosa, Brasil: [s.n.].

CANAVESI, V.; PONZONI, F. J.; VALERIANO, M. M. Stand volumes estimate Eucalyptus spp. plantations in forests using hyperspectral and topographic data. **Revista Arvore**, v. 34, n. 3, p. 539–549, 2010.

CANDIAGO, S. et al. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. **Remote Sensing 2015**, Vol. 7, Pages 4026-4047, v. 7, n. 4, p. 4026–4047, 2 abr. 2015.

CARRIJO, J. V. N. et al. Artificial intelligence associated with satellite data in predicting energy potential in the Brazilian savanna woodland area. **iForest - Biogeosciences and Forestry**, v. 13, n. 1, p. 48, 2020.

CASSOL, H. L. G.; SALDANHA, D. L.; KUPPLICH, T. M. Inventário de carbono em fragmento de Floresta Ombrófila Mista por detecção remota. **Floresta**, v. 44, n. 4, p. 697, 2014.

CASTILLO, J. A. A. et al. Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 134, p. 70–85,

1 dez. 2017.

CERRADO, F. **Projeto de desenvolvimento de sistemas de prevenção de incêndios florestais e monitoramento da cobertura vegetal no Cerrado brasileiro**. [s.l: s.n.].

Disponível em:

<<http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/cerrado/increments>>.

CHEN, L. et al. Optimal Combination of Predictors and Algorithms for Forest Above-Ground Biomass Mapping from Sentinel and SRTM Data. **Remote Sensing 2019, Vol. 11, Page 414**, v. 11, n. 4, p. 414, 18 fev. 2019.

COELHO, A. J. P. et al. Effects of anthropogenic disturbances on biodiversity and biomass stock of Cerrado, the Brazilian savanna. **Biodiversity and Conservation**, v. 29, n. 11–12, p. 3151–3168, 1 out. 2020.

CONGALTON, R. G. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal of Wildland Fire**, v. 10, n. 4, p. 321–328, 2001.

COSTA, M. B. T. DA et al. Beyond trees: Mapping total aboveground biomass density in the Brazilian savanna using high-density UAV-lidar data. **Forest Ecology and Management**, v. 491, p. 119155, 1 jul. 2021.

DE MIRANDA, S. DO C. et al. Regional Variations in Biomass Distribution in Brazilian Savanna Woodland. **Biotropica**, v. 46, n. 2, p. 125–138, 1 mar. 2014.

DRAPER, N. R.; SMITH, H. **Applied Regression Analysis**. 3. ed. New York: John Wiley & Sons: [s.n.].

ELIAS, F. et al. Soil and topographic variation as a key factor driving the distribution of tree flora in the Amazonia/Cerrado transition. **Acta Oecologica**, v. 100, p. 103467, 1 out. 2019.

EMBRAPA. **Sistema de Classificação de Solos**. 5. ed. Brasília: [s.n.].

ERCANLI, İ. et al. Artificial neural network models predicting the leaf area index: A case study in pure even-aged crimean pine forests from Turkey. **Forest Ecosystems**, v. 5, n. 1, p. 1–12, 1 dez. 2018.

FELFILI, J. M.; DA SILVA, M. C. A comparative study of cerrado (sensu stricto) vegetation in Central Brazil. **Journal of Tropical Ecology**, v. 9, n. 3, p. 277–289, 1993.

FERNANDO, L. et al. TerraBrasilis: A Spatial Data Analytics Infrastructure for Large-Scale Thematic Mapping. **ISPRS International Journal of Geo-Information 2019, Vol. 8, Page 513**, v. 8, n. 11, p. 513, 12 nov. 2019.

FERRAZ, A. S. et al. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**, v. 21, n. 3, p. 286–296, 2014.

FERREIRA, L. G. et al. Seasonal landscape and spectral vegetation index dynamics in the Brazilian Cerrado: An analysis within the Large-Scale Biosphere–Atmosphere Experiment in Amazônia (LBA). **Remote Sensing of Environment**, v. 87, n. 4, p. 534–550, 15 nov. 2003.

FITZGERALD, G.; RODRIGUEZ, D.; O’LEARY, G. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). **Field Crops Research**, v. 116, n. 3, p. 318–324, 3 abr. 2010.

FLETCHER, R. A new approach to variable metric algorithms. **The computer Journal**, v. 13, n. 3, p. 317–322, 1970.

FOODY, G. M. et al. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology and Biogeography**, v. 10, n. 4, p. 379–387, 1 jul. 2001.

GAMARRA, R. M. et al. Fragmentation of vegetation in protected area in the cerrado region. **Research, Society and Development**, v. 10, n. 7, p. 12, 2021.

GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, p. 29–40, 1 jul. 2018.

GITELSON, A. A. et al. Remote estimation of canopy chlorophyll content in crops. **Geophysical Research Letters**, v. 32, n. 8, p. 1–4, 1 abr. 2005.

GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, v. 148, n. 3–4, p. 494–500, 1 jan. 1996.

GOLDFARB, D. A family of variable-metric methods derived by variational means. **Mathematics of Computation**, v. 24, n. 109, p. 23, 1970.

GONÇALVES, F. C. et al. Artificial intelligence associated with Sentinel-2 data in predicting commercial volume in Brazilian Amazon Forest. <https://doi.org/10.1117/1.JRS.15.044511>, v. 15, n. 4, p. 044511, 10 nov. 2021.

GORUNESCU, F.; BELCIUG, S. Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis. **Journal of Biomedical Informatics**, v. 63, p. 74–81, 1 out. 2016.

GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F. D. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. **International Journal of Remote Sensing**, v. 41, n. 8, p. 2861–2876, 17 abr. 2019.

GUERROUT, E. H. et al. Hidden Markov random field model and Broyden–Fletcher–Goldfarb–Shanno algorithm for brain image segmentation. **Journal of Experimental and Theoretical Artificial Intelligence**, v. 30, n. 3, p. 415–427, 4 maio 2018.

GÜNLÜ, A. et al. Estimation of some stand parameters from textural features from

WorldView-2 satellite image using the artificial neural network and multiple regression methods: a case study from Turkey. **Geocarto International**, v. 36, n. 8, p. 918–935, 2019.

HAYKIN, S. **Redes Neurais: Princípios e Prática [Neural Networks: principle and practice] (2nd edn)**. 2ª edição ed. Porto Alegre, Brasil: Bookman, 2001.

HEROLD, M. et al. The Role and Need for Space-Based Forest Biomass-Related Measurements in Environmental Management and Policy. **Surveys in Geophysics**, v. 40, n. 4, p. 757–778, 2019.

HEROLD, M.; JOHNS, T. Linking requirements with capabilities for deforestation monitoring in the context of the UNFCCC-REDD process. **Environmental Research Letters**, 2007.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 1 nov. 2002.

INGRAM, J. C.; DAWSON, T. P.; WHITTAKER, R. J. Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. **Remote Sensing of Environment**, v. 94, n. 4, p. 491–507, 28 fev. 2005.

JACON, A. D. et al. Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1. <https://doi.org/10.1080/15481603.2021.1969630>, v. 58, n. 7, p. 1112–1129, 2021.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective second edition**. Harlow, England: [s.n.]. v. 1

KANKE, Y. et al. Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. **Precision Agriculture**, v. 17, n. 5, p. 507–530, 1 out. 2016.

KLINK, C. A.; MACHADO, R. B. **A conservação do Cerrado brasileiro**. [s.l.: s.n.].

KROSS, A. et al. Assessment of RapidEye vegetation indices for estimation of leaf area index and biomass in corn and soybean crops. **International Journal of Applied Earth Observation and Geoinformation**, v. 34, n. 1, p. 235–248, 1 fev. 2015.

KUMAR, K. K. et al. Above Ground Biomass Assessment from Combined Optical and SAR Remote Sensing Data in Surat Thani Province, Thailand. **Journal of Geographic Information System**, v. 8, p. 506–516, 2016.

KUMAR, L. et al. Review of the use of remote sensing for biomass estimation to support renewable energy generation. <https://doi.org/10.1117/1.JRS.9.097696>, v. 9, n. 1, p. 097696, 16 jun. 2015.

KUMAR, L.; MUTANGA, O. Remote sensing of above-ground biomass. **Remote Sensing**, v. 9, n. 9, p. 1–8, 2017.

- KUNTSCHIK, G. Estimativa de biomassa vegetal lenhosa em cerrado por meio de sensoriamento remoto óptico e de radar. p. 154, 2004.
- LAMBIN, E. F. et al. Estimating the world's potentially available cropland using a bottom-up approach. **Global Environmental Change**, v. 23, n. 5, p. 892–901, 2013.
- LE QUÉRÉ, C. et al. Global carbon budget 2014. **Earth System Science Data**, v. 7, n. 1, p. 47–85, 2015.
- LI, D. et al. Estimating the age of deciduous forests in northeast China with Enhanced Thematic Mapper Plus data acquired in different phenological seasons. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 083670, 6 mar. 2014.
- LI, F. et al. Modeling grassland aboveground biomass using a pure vegetation index. **Ecological Indicators**, v. 62, p. 279–288, 2016.
- LI, Y. et al. Influence of Variable Selection and Forest Type on Forest Aboveground Biomass Estimation Using Machine Learning Algorithms. **Forests 2019, Vol. 10, Page 1073**, v. 10, n. 12, p. 1073, 25 nov. 2019.
- LIBANO, A. M.; FELFILI, J. M. Mudanças temporais na composição florística e na diversidade de um cerrado sensu stricto do Brasil Central em um período de 18 anos (1985-2003). **Acta Botanica Brasilica**, v. 20, n. 4, p. 927–936, out. 2006.
- LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 2006.
- LU, D. et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016.
- LU, X. et al. Combining Multi-Source Remotely Sensed Data and a Process-Based Model for Forest Aboveground Biomass Updating. **Sensors**, v. 17, n. 9, 2017.
- MACHADO, I. E. S. et al. Modelos para estimativa de variáveis florestais com a utilização de imagens multiespectrais. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 171–181, 30 jun. 2017.
- MARTINS SILVA, J. P. et al. Computational techniques applied to volume and biomass estimation of trees in Brazilian savanna. **Journal of Environmental Management**, v. 249, p. 109368, 1 nov. 2019.
- MENDES, F. DE S. **Monitoring forest fragmentation and carbon storage in the Cerrado biome of Mato Grosso using optical and SAR satellite images.** [s.l.] George-August University School of Science (GAUSS), 2019.
- MENDES, F. DE S. et al. Optical and SAR Remote Sensing Synergism for Mapping Vegetation Types in the Endangered Cerrado/ Amazon Ecotone of Nova. **Remote Sensing**, p. 25, 2019.

- MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília, DF: [s.n.].
- MENESES, P. R.; ALMEIRDA, T. DE; BAPTISTA, G. M. DE M. **Reflectância dos materiais terrestres - Análise e Interpretação**. Brasília: Oficina de textos, 2019.
- METZGER, J. P. et al. Why Brazil needs its Legal Reserves. **Perspectives in Ecology and Conservation**, v. 17, n. 3, p. 91–103, 1 jul. 2019.
- MIGUEL, E. P. CARACTERIZAÇÃO DA FLORA E DA PRODUÇÃO EM VOLUME, BIOMASSA E CARBONO DA VEGETAÇÃO ARBÓREA EM ÁREA DE CERRADÃO NO ESTADO DO TOCANTINS. **Departamento De Engenharia Florestal**, p. 96, 2014.
- MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829–839, 2015.
- MIGUEL, E. P. et al. Using artificial neural networks in estimating wood resistance. **Maderas. Ciencia y tecnología**, v. 20, n. 4, p. 531–543, 1 out. 2018.
- MMA. **Submissão brasileira de Nível de Referência de Emissões Florestais para redução das emissões provenientes do desmatamento do bioma Cerrado para fins de pagamentos por resultados de REDD+ sob a Convenção-Quadro das Nações Unidas sobre Mudança do Clima**. Brasília - DF: [s.n.].
- MMA, M. D. M. A. Mapeamento do uso e cobertura da terra do cerrado. **Projeto TerrasClass Cerrado 2013**, 2015.
- MORANDI, P. S. et al. Tree diversity and above-ground biomass in the South America Cerrado biome and their conservation implications. **Biodiversity and Conservation**, v. 29, n. 5, p. 1519–1536, 1 abr. 2020.
- MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. February, p. 853–858, 2000.
- NETO, C. D. G. **Identificação de fitofisionomias de Cerrado no Parque Nacional de Brasília utilizando Random Forest aplicado a imagens de alta e média resoluções espaciais**. [s.l.] Instituto Nacional de Pesquisas Espaciais, 2018.
- NOOJIPADY, P. et al. Forest carbon emissions from cropland expansion in the Brazilian Cerrado biome. **Environmental Research Letters**, v. 12, n. 2, 2017.
- NUNES, M. H.; GÖRGENS, E. B. Artificial Intelligence Procedures for Tree Taper Estimation within a Complex Vegetation Mosaic in Brazil. **PLOS ONE**, v. 11, n. 5, p. e0154738, 1 maio 2016.
- OLIVEIRA, C. P. DE et al. Comparação de modelos estatísticos para estimativa da biomassa de árvores, e estimativa do estoque de carbono acima do solo em Cerrado. **Ciência Florestal**, v. 29, n. 1, p. 255, 2019.

- OLIVEIRA, L. G. DE et al. **Estudo da variabilidade de índices de vegetação através de imagens do ETM+/LANDSAT 7** *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis: [s.n.]. Disponível em: <<http://mar.tecid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.13.17.35/doc/5755-5762.pdf>>.
- OLIVEIRA, M. T. DE et al. Mapeamento da Vegetação do Cerrado – Uma Revisão das Iniciativas de Sensoriamento Remoto. **Revista Brasileira de Cartografia**, p. 1250–1274, 2020.
- OTTMAR, R. D. et al. Stereo photo series for quantifying cerrado fuels in Central Brazil - volume I. [Brochure]. **Portland, OR: U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station.**, 2001.
- ÖZÇELİK, R. et al. Artificial Neural Network Models: An Alternative Approach for Reliable Aboveground Pine Tree Biomass Prediction. **Forest Science**, v. 63, n. 3, p. 291–302, 2 jun. 2017.
- PANDA, S. S.; AMES, D. P.; PANIGRAHI, S. Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques. **Remote Sensing 2010, Vol. 2, Pages 673-696**, v. 2, n. 3, p. 673–696, 1 mar. 2010.
- PEREIRA MIGUEL, E. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite Artificial neural networks for modeling wood volume and aboveground biomass of tall Cerrado using satellite data. **Pesquisa Agropecuária Brasileira**, n. 9, p. 829–839, 2015.
- PONZONI, F. J. Comportamento espectral da vegetação. In: **Sensoriamento remoto: refletância dos alvos naturais**. Brasília: Universidade de Brasília, 2001. p. 157–199.
- PONZONI, F. J. Sensoriamento Remoto no Estudo da Vegetação: Diagnosticando a Mata Atlântica. **Instituto de Pesquisas e Espaciais - INPE**, p. 27, 2002.
- RAPIDEYE. **The RapidEye Red Edge Band**. [s.l: s.n.]. Disponível em: <https://apollomapping.com/wp-content/user_uploads/2012/07/RapidEye-Red-Edge-White-Paper.pdf>. Acesso em: 1 ago. 2022.
- REZENDE, A. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, p. 65–76, 2006.
- RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do Bioma Cerrado. In: **SANO, S. M. et al. (Ed) Cerrado: Ecologia e Flora.**, v. 1, p. 151–212, 1998.
- RIBEIRO, S. C. et al. Above- and belowground biomass in a Brazilian Cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 1 ago. 2011.
- ROITMAN, I. et al. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: Re-evaluating allometric equations and environmental influences. **PLOS ONE**, v. 13, n. 8, p. e0196742, 1 ago. 2018.

- ROQUETTE, J. G. Distribuição da biomassa no cerrado e a importância na armazenagem do carbono. **Revista Ciência Florestal**, v. 28, p. 121, 2018.
- ROSETTE, J. et al. **Lidar remote sensing for biomass assessment. In: Remote Sensing of Biomass: Principles and Applications**. 2012
- ROUSE, J. W. et al. Monitoring the vernal advancement and retrogradation (greenwave effect of natural vegetation). **Remote Sensing Center**, 1974.
- SAATCHI, S. S. et al. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences of the United States of America**, v. 108, n. 24, p. 9899–9904, 14 jun. 2011.
- SANO, E. E. et al. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, n. 1–4, p. 113–124, 6 jul. 2010.
- SANO, E. E.; BARCELLOS, A. O.; BEZERRA, H. S. Assessing the spatial distribution of cultivated pastures in the Brazilian savanna. **Pasturas Tropicales**, p. 2–15, 2000.
- SCHOENINGER, E. R. et al. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529–549, 1 set. 2008.
- SERPEN, G.; GAO, Z. Complexity Analysis of Multilayer Perceptron Neural Network Embedded into a Wireless Sensor Network. **Procedia Computer Science**, v. 36, n. C, p. 192–197, 1 jan. 2014.
- SFB, S. F. B. Inventário Florestal Nacional: principais resultados Distrito Federal. **Brasília: SFB (Série Relatório Técnico)**, p. 66, 2016.
- SHAH, S. A. A.; MANZOOR, M. A.; BAIS, A. Canopy Height Estimation at Landsat Resolution Using Convolutional Neural Networks. **Machine Learning and Knowledge Extraction**, v. 2, n. 1, p. 23–36, 9 fev. 2020.
- SHANNO, D. F. Conditioning of quasi-Newton methods for function minimization. **Mathematics of Computation**, v. 24, n. 111, p. 647, 1970.
- SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, v. 52, n. 3/4, p. 591, dez. 1965.
- SHIBLEE, M.; CHANDRA, B.; KALRA, P. K. Learning of geometric mean neuron model using resilient propagation algorithm. **Expert Systems with Applications**, v. 37, n. 12, p. 7449–7455, 1 dez. 2010.
- SHUGART, H. H.; SAATCHI, S.; HALL, F. G. Importance of structure and its measurement in quantifying function of forest ecosystems. **Journal of Geophysical Research: Biogeosciences**, v. 115, n. 4, p. 1–16, 2010.
- SILVA, F. A. M.; ASSAD, E. D.; EVANGELISTA, B. A. Caracterização climática do bioma Cerrado. In: **Cerrado: Ecologia e Flora**. Brasília: Embrapa Cerrados, 2008. p.

71–88.

SILVA, J. P. M. et al. Computational techniques applied to volume and biomass estimation of trees in Brazilian savanna. **Journal of Environmental Management**, v. 249, 1 nov. 2019.

STATSOFT, I. **Statistica: Data analysis software system**. [s.l.: s.n.].

SYDOW, J. D. et al. COMPARAÇÃO DE MÉTODOS E PROCESSOS DE AMOSTRAGEM PARA INVENTÁRIO EM FLORESTA OMBRÓFILA MISTA. **BIOFIX Scientific Journal**, v. 2, n. 1, p. 60–68, 15 maio 2017.

TEAM, R. **RStudio: Integrated Development for R 1.0.143**. [s.l.] Boston RStudio Inc, 2016.

TONIOL, A. C. et al. Potential of hyperspectral metrics and classifiers for mapping Brazilian savannas in the rainy and dry seasons. **Remote Sensing Applications: Society and Environment**, v. 8, p. 20–29, 1 nov. 2017.

VAHEDI, A. A. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, v. 88, p. 66–76, 1 maio 2016.

VALE, A. T. DO et al. Artificial neural networks in predicting energy density of *Bambusa vulgaris* in Brazil. **African Journal of Agricultural Research**, v. 12, n. 10, p. 856–862, 9 mar. 2017.

VALE, A. T. DO; FELFILI, J. M. Dry biomass distribution in a cerrado sensu stricto site in Brazil central. **Revista Árvore**, v. 29, n. 5, p. 661–669, 2005.

VICENTE-SERRANO, S. M. et al. Diverse relationships between forest growth and the Normalized Difference Vegetation Index at a global scale. **Remote Sensing of Environment**, v. 187, p. 14–29, 15 dez. 2016.

VIEIRA, G. C. et al. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of The Total Environment**, v. 619–620, p. 1473–1481, 1 abr. 2018.

VIÑA, A. et al. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. **Remote Sensing of Environment**, v. 115, n. 12, p. 3468–3478, 15 dez. 2011.

YANG, S. et al. Modeling grassland above-ground biomass based on artificial neural network and remote sensing in the Three-River Headwaters Region. **Remote Sensing of Environment**, v. 204, p. 448–455, 1 jan. 2018.

YU, X. et al. Comparative Study on Variable Selection Approaches in Establishment of Remote Sensing Model for Forest Biomass Estimation. **Remote Sensing 2019, Vol. 11, Page 1437**, v. 11, n. 12, p. 1437, 17 jun. 2019.

YU, Y.; SAATCHI, S. Sensitivity of L-Band SAR Backscatter to Aboveground Biomass of Global Forests. **Remote Sensing**, v. 8, n. 6, p. 522, 22 jun. 2016.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 222–231, 1 abr. 2015.

ZIMBRES, B. et al. Mapping the stock and spatial distribution of aboveground woody biomass in the native vegetation of the Brazilian Cerrado biome. **Forest Ecology and Management**, v. 499, p. 119615, 1 nov. 2021.

ZOLKOS, S. G.; GOETZ, S. J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289–298, 2013.

ZUCCHINI, W. An Introduction to Model Selection. **Journal of Mathematical Psychology**, v. 44, n. 1, p. 41–61, 1 mar. 2000.