



GABRIEL RODRIGUES MARQUES

**USO DE INDICADORES DE SENSORIAMENTO REMOTO NA
MODELAGEM DA BIOMASSA AÉREA EM MINAS GERAIS**

**LAVRAS – MG
2021**

GABRIEL RODRIGUES MARQUES

**USO DE INDICADORES DE SENSORIAMENTO REMOTO NA MODELAGEM DA
BIOMASSA AÉREA EM MINAS GERAIS**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

Prof. Dr. Fausto Weimar Acerbi Junior
Orientador

Ma. Jhuly Ely Santos Pereira
Coorientadora

**LAVRAS - MG
2021**

AGRADECIMENTOS

À universidade Federal de Lavras (UFLA) e ao Departamento de Ciências Florestais (DCF), pela oportunidade concedida para a realização da graduação.

Aos professores, técnicos administrativos, pós-graduandos e todos os funcionários do Departamento de Ciências Florestais da UFLA, pelos ensinamentos, conselhos e dedicação em seus trabalhos.

Ao professor Dr. Fausto Weimar Acerbi Júnior, pela orientação, oportunidade, amizade, dedicação, seus ensinamentos que foram de grande relevância para a realização deste trabalho e meu crescimento profissional e confiança nos últimos anos de graduação.

À Jhuly Ely Santos Pereira pela ajuda e companheirismo como coorientadora.

À Juliana Maria Ferreira de Souza Diniz e Gustavo Antomar Batista Gontijo por se disporem a participar como membros da banca examinadora.

À minha família, Maria de Lourdes, Aparecido, Bruno e Humberto pelo suporte, carinho e possibilitar a realização desta graduação.

Aos meus amigos feitos durante os anos de graduação pela companhia, conselhos, divertimentos e pelas alegrias compartilhadas.

RESUMO

Este estudo estimou a biomassa arbórea aérea para as fitofisionomias do estado de Minas Gerais, utilizando variáveis temporais de sensoriamento remoto extraídas do sensor MODIS combinadas com dados de campo extraídos do Inventário Florestal de Minas Gerais. O estudo foi realizado para o ano de 2007, utilizando imagens das estações do ano verão e inverno para coletar informações das fitofisionomias: Floresta Ombrófila, Floresta Estacional Semidecidual, Campo Cerrado, Cerradão, Cerrado Sensu Stricto e Floresta Estacional Decidual, assim como para a área total do estado. Os dados de sensoriamento remoto foram processados no software Google Earth Engine e as variáveis independentes selecionadas foram: NDVI, EVI, LAI, Fpar e GPP. A modelagem foi realizada através do algoritmo Random Forest utilizando o software RStudio. Foram selecionadas variáveis espectrais da modelagem que melhor representavam cada tipologia vegetal, que apresentaram uma interação de média a baixa proporcionando uma estimativa subestimada para as estações do ano e superestimada para o ano todo. Fatores ambientais e de sazonalidade afetaram a seleção e a quantidade das variáveis, assim como a quantidade de parcelas inventariadas de cada fitofisionomia. A distribuição espacial das tipologias vegetais não contribuiu muito para esta seleção.

Palavras-chaves: Índices Espectrais. Random Forest. Estimativa. Distribuição Espacial. MODIS.

ABSTRACT

This study estimated the aerial tree biomass for the phytophysiognomies of the state of Minas Gerais, using remote sensing temporal variables extracted from the MODIS sensor combined with field data extracted from the Minas Gerais Forest Inventory. The study was carried out for the year 2007, using images of the summer and winter seasons to collect information on the phytophysiognomies: Ombrophilous Forest, Semideciduous Seasonal Forest, Campo Cerrado, Cerradão, Cerrado Sensu Stricto and Seasonal Deciduous Forest, as well as for the area state total. Remote sensing data were processed in Google Earth Engine software and the selected independent variables were: NDVI, EVI, LAI, Fpar and GPP. Modeling was performed using the Random Forest algorithm using RStudio software. Spectral variables from the modeling were selected that best represented each plant typology, which presented a medium to low interaction, providing an underestimated estimate for the seasons and an overestimated estimate for the whole year. Environmental and seasonal factors affected the selection and quantity of variables, as well as the number of inventoried plots of each physiognomy. The spatial distribution of plant typologies did not contribute much to this selection.

Keywords: Spectral Indices. Random Forest. Estimated. Spatial distribution. MODIS.

LISTA DE ILUSTRAÇÕES

Figura 1 - (a) Localização do estado de Minas Gerais na região Sudeste do Brasil; (b) Distribuição dos biomas dentro do estado de Minas Gerais	18
Figura 2 - Localização das parcelas permanentes do Inventário Florestal de Minas Gerais	21
Figura 3 - Fluxograma das principais etapas para modelagem da biomassa arbórea acima do solo para o estado de Minas Gerais	26
Gráfico 1 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	32
Gráfico 2 - Análise de resíduos: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	33
Gráfico 3 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	36
Gráfico 4 - Análise de resíduos: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	37
Gráfico 5 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	39
Gráfico 6 - Análise de resíduos: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	40
Gráfico 7 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	43
Gráfico 8 - Análise de resíduos: (a) área total; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual	43
Gráfico 9 - Número de variáveis selecionadas para modelar o AGB em função da quantidade de parcelas inventariadas de cada tipo de vegetação	46
Gráfico 10 - Número de variáveis selecionadas para modelar AGB em função da sazonalidade de cada tipo de vegetação	47
Tabela 1 - Número de parcelas inventariadas em cada fitofisionomia	22
Tabela 2 - Índices de sensoriamento remoto usados para modelagem da biomassa arbórea acima do solo para o estado de Minas Gerais	23
Tabela 3 - Estimativa de AGB para cada fitofisionomia para cada época do ano, utilizando o RF.....	28
Tabela 4 - Variáveis selecionadas na modelagem de AGB para o ano de 2007 do estado de Minas Gerais	29
Tabela 5 - Variáveis selecionadas na modelagem de AGB para o inverno de 2007 do estado de Minas Gerais	33

Tabela 6 - Variáveis selecionadas na modelagem de AGB para o verão de janeiro a março de 2007 do estado de Minas Gerais	38
Tabela 7 - Variáveis selecionadas na modelagem de AGB para o verão de outubro a dezembro de 2007 do estado de Minas Gerais	41
Tabela 8 - Biomassa total acima do solo para cada tipologia vegetal do estado de Minas Gerais	44

LISTA DE ABREVIATURAS

Acum	Valor acumulado
cap.	Capítulo
CampC	Campo Cerrado
Cdao	Cerradão
CH ₄	Metano
CO ₂	Dióxido de Carbono
CSS	Cerrado Senso Stricto
CV	Coefficiente de Variação
DP	Desvio Padrão
ed.	Edição
et al.	E outros
FED	Floresta Estacional Decidual
FES	Floresta Estacional Semidecidual
FOM	Floresta Ombrófila
HFCs	Hidrofluorcarbonos
Max	Valor máximo
Med	Valor médio
Min	Valor mínimo
n.	Número
N ₂ O	Óxido nitroso
p.	Página
PFCs	Perfluorcarbonos
SF ₆	Hexafluoreto de enxofre
v.	Volume

LISTA DE SIGLAS

AGB	Biomassa florestal acima do solo
DAP	Diâmetro à altura do peito
EVI	Índice de Vegetação Melhorada
FAO	Organização das Nações Unidas para Alimentação e Agricultura
Fpar	Fração de Radiação Fotossinteticamente Ativa
GEE	Google Earth Engine
GPP	Produtividade Primária Bruta
IEF	Instituto Estadual de Florestas
IFMG	Inventário Florestal de Minas Gerais
LAI	Índice de Área Foliar
MG	Minas Gerais
MODIS	Moderate Resolution Imaging Spectroradiometer
NDVI	Índice de Vegetação por Diferença Normalizada
UFLA	Universidade Federal de Lavras

LISTA DE SÍMBOLOS

ha	Hectares
k	Número de variáveis selecionadas
n	Número de observações
R^2	Coeficiente de determinação
R^2 ajustado	Coeficiente de determinação ajustado
SQR	Soma do quadrado dos erros residuais
SQt	Soma do quadrado dos erros totais
t	Toneladas

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Objetivo	12
1.1.1 Objetivo Geral	12
1.1.2 Objetivo Específico	12
2 REFERENCIAL TEÓRICO	13
2.1 Protocolo de Quioto	13
2.2 Biomassa	14
2.3 Ciclo do Carbono	15
2.4 Inventário Florestais	16
2.5 Sensoriamento Remoto	16
3 MATERIAIS E MÉTODOS	18
3.1 Área de Estudo	18
3.2 Base de Dados	20
3.2.1 Dados de Campo	20
3.2.2 Dados de Sensoriamento Remoto	22
3.2.3 Variáveis Preditoras	22
3.3 Random Forest	24
4 RESULTADOS E DISCUSSÃO	27
4.1 Resultados	27
4.2 Discussão	44
5 CONCLUSÃO	48
REFERÊNCIA	49

1 INTRODUÇÃO

A grande diversidade de fauna e flora dos ecossistemas florestais e suas interações com o meio abiótico proporcionam um papel essencial na manutenção dos bens e serviços dos ambientes terrestres (SONG, 2013). Estes ecossistemas afetam e são afetados diretamente pelas mudanças ambientais e climáticas de nosso planeta em escala global (LU et al., 2016; HALL et al., 2011), incluindo sua importância nos setores da ecologia, economia e política (GALLAUN et al., 2010). Apesar de toda sua importância, os ecossistemas florestais estão sujeitos continuamente a diversas ameaças como degradação, desmatamento (THURNER et al., 2014; LU, 2006), incêndios (BROWN, 2002), exploração madeireira (HOUGHTON et al., 2000) e a grande expansão demográfica provocando pressão sobre as áreas vegetadas por demanda de alimentos e produtos energéticos madeireiros (DRIGO et al., 2009). Diante destes cenários, torna-se imprescindível o desenvolvimento de técnicas para a estimativa da biomassa com o objetivo de se obter informações quanto a produtividade e o sequestro de carbono dos ecossistemas florestais.

Mapear e monitorar com precisão a biomassa florestal se tornou uma missão de extrema importância logo após o Protocolo de Quioto, criado em 1997, mas entrado em vigor em 2005, onde estabelecia metas para a redução de emissões de gases do efeito estufa que modificam o clima global (MINISTÉRIO DO MEIO AMBIENTE) e afetam a vida da humanidade. Como mencionado por Næset e Gobakken (2008), o protocolo tem levado a comunidade científica a realizar estudos e pesquisas, desde de sua assinatura, visando sempre métodos de baixo custo e com resultados confiáveis para a quantificação de carbono presente nas florestas e o sensoriamento remoto tem se mostrado uma tecnologia oportuna para auxiliar nestas estimativas.

A biomassa florestal acima do solo (AGB, do inglês *aboveground biomass*) compreende toda a massa viva biológica presente acima do solo, como árvores, arbustos, gramíneas, trepadeiras e raízes (HU et al., 2016; LU, 2016; HOUGHTON; HALL; GOETZ, 2009; HE et al., 2013) e sua estimativa proporciona uma indicação dos estoques de carbono presentes na superfície terrestre (MUUKKONEN; HEISKANEN, 2007; MATTSSON, 2016; POPESCU, 2007; HE et al., 2013). A quantificação da biomassa pode ser realizada com diferentes metodologias que variam de acordo com as quantidades de variáveis usadas para a estimação (GLEASON, 2012). Os Inventários Florestais Nacionais foram uma alternativa implementada pelo Brasil e diversos outros países para a medição da biomassa e estoque de carbono de seus recursos florestais (DAVID et al., 2017; MCROBERTS; TOMPPO, 2007). Os inventários

utilizam relações alométricas que correlacionam algumas variáveis como, diâmetro à altura do peito e altura total dos indivíduos amostrados para a estimativa de biomassa (GALLAUN et al., 2010). Porém, foi constatado a dificuldade de realizar tais inventários temporalmente devido ao alto custo de implementação, dificuldade de monitoramento das parcelas, grande consumo de tempo e áreas pouco representadas (YAN; WU; WANG, 2015; POPESCU, 2007; ASNER, 2013; THURNER et al., 2014).

Nas últimas décadas uma ferramenta muito promissora para auxiliar a quantificação da biomassa aérea, na tentativa de reduzir custos operacionais e otimizar tempo, tem sido a utilização de dados coletados remotamente através de sensores espaciais ou aéreos (DENG et al., 2014), uma vez que as imagens podem contribuir na estimativa de estoque de carbono, biomassa, volume, mudança de uso da terra e detecção de áreas queimadas (SCOLFORO et al., 2016). De acordo com Fayad et al. (2016), existem três principais técnicas para tais estimativas utilizando dados a partir de sensoriamento remoto: imagens ópticas (sensores ópticos passivos), LiDAR e RADAR (sensores ópticos ativos).

1.1 Objetivo

1.1.1 Objetivo Geral

Estimar a biomassa aérea da vegetação para as fitofisionomias de Minas Gerais, utilizando variáveis temporais de sensoriamento remoto.

1.1.2 Objetivo Específico

- a) Selecionar variáveis de sensoriamento remoto ao longo do tempo, que explicam a variabilidade espacial da biomassa das fitofisionomias de Minas Gerais;
- b) Gerar modelos individuais para estimativa de biomassa para cada fitofisionomia de Minas Gerais;
- c) Estimar e analisar a biomassa para as estações do ano de verão e inverno das fitofisionomias de Minas Gerais.

Este trabalho é composto por mais cinco seções além desta introdução. Na seção seguinte apresenta-se as frentes teóricas sobre a importância da estimativa da biomassa aérea e suas principais formas de estimativas. A metodologia utilizada para atingir os objetivos propostos são apresentados na terceira seção. Em seguida, é apresentada a análise e discussão dos resultados, contemplando o uso de sensoriamento remoto na estimativa de biomassa aérea para o estado de Minas Gerais. Nas duas seções finais, são apresentadas as considerações finais assim como as referências utilizadas para o desenvolvimento do estudo.

2 REFERENCIAL TEÓRICO

As principais frentes teóricas que embasam esta pesquisa são apresentadas a seguir. Primeiramente, define-se a criação do Protocolo de Quioto, os principais gases e setores responsáveis pelo aceleração do efeito estufa e formas de mitigação. Em seguida, discorre-se sobre a biomassa e sua influência em diferentes áreas, principalmente no ciclo de carbono e relação com as mudanças climáticas. O próximo tópico é referente ao ciclo global de carbono enfatizando sua concentração atual e a importância de realizar políticas de redução de suas emissões. Posteriormente são apresentadas as principais formas de quantificação de biomassa, apresentados nos tópicos de inventários e sensoriamento remoto.

2.1 Protocolo de Quioto

O Protocolo de Quioto foi um tratado internacional sancionado após a Convenção-Quadro das Nações Unidas sobre Mudança do Clima que definia metas de redução de gases do efeito estufa na atmosfera para os países industrializados, além de apoiar um desenvolvimento de menor impacto para países em desenvolvimento. O documento foi assinado em dezembro de 1997, na cidade de Quioto no Japão e entrou em vigor em fevereiro de 2005, após precisar ser ratificado por pelo menos 55 Partes da Convenção e que fossem responsáveis por, pelo menos, 55% do total das emissões de dióxido de carbono em relação a 1990.

O primeiro período para a redução das emissões de gases poluentes ocorreu entre os anos de 2008 à 2012, onde os países-membros se comprometeram a reduzir em média 5% das emissões em relação ao ano de 1990. No segundo período a redução era de pelo menos 18% entre os anos de 2013 à 2020 em relação ao ano de 1990.

Os principais Gases de efeito estufa são: Dióxido de carbono (CO₂), Metano (CH₄), Óxido nitroso (N₂O), Hidrofluorcarbonos (HFCs), Perfluorcarbonos (PFCs) e Hexafluoreto de enxofre (SF₆) e os principais setores responsáveis por essas emissões são: energia, processos industriais, uso de solventes e outros produtos, agricultura e resíduos.

Uma das estratégias do acordo para conseguir esta redução é a venda de crédito de carbono, onde países que conseguirem reduzir suas emissões poderiam vender o sequestro de carbono excedente no mercado internacional para países que não conseguiram chegar à meta (GIBBS et al., 2007). O Protocolo estabeleceu uma necessidade de se obter estimativas precisas e monitoramentos da biomassa, na tentativa de auxiliar a quantificação do carbono liberado na atmosfera e debates ambientais e econômicos (ZHAO; POPESCU; NELSON, 2009).

2.2 Biomassa

A quantidade total de biomassa presente em um ecossistema é representada pela biomassa acima do solo (como árvores, galhos, arbustos, raízes aéreas, trepadeiras) e a biomassa abaixo do solo (raízes vivas e mortas e lixo grosso associado ao solo) (LU et al., 2016). Para Houghton, Hall e Goetz (2009), a biomassa acima do solo está sujeita a vários distúrbios, naturais e antropogênicos, como, incêndios, extração de madeira, pragas, doenças, desmatamento, o que pode ocasionar a emissão do estoque de carbono presentes nas florestas para a atmosfera.

Nas últimas décadas, a quantificação de biomassa tem ganhado muito espaço, seja pelo seu potencial em estimar a produtividade nas indústrias florestais, ou pelo seu valor ambiental e interesse nas mudanças climáticas (FERNÁNDEZ-MANSO; FERNÁNDEZ-MANSO; QUINTANO, 2014). Houghton, Hall, Goetz (2009), ressaltam a importância da biomassa em diferentes áreas, como na alimentícia, indústria energética, determinação da biodiversidade, influência no manejo do solo, fogo e água e principalmente no ciclo do carbono, onde a concentração de biomassa avalia a quantidade de carbono liberado na atmosfera. He et al. (2012), complementa que o ciclo de carbono pode ser melhor entendido com a estimativa e o mapeamento da biomassa florestal.

O conhecimento da dinâmica da biomassa florestal, principalmente da alta densidade de biomassa presente nas regiões tropicais, é fundamental para o aprimoramento da predição de biomassa (BACCINI et al., 2008). A maior concentração de carbono das florestas tropicais

estão presentes na biomassa aérea, que pode sofrer distúrbios provocados pelo desmatamento e degradação (GIBBS et al., 2007).

Portanto, segundo Liao, He e Quan (2020), o entendimento do armazenamento do carbono, alterações ambientais, como mudanças climáticas e os gastos com carbono em escala global, é suprida pela contabilização eficiente da biomassa aérea.

2.3 Ciclo do Carbono

O carbono está presente em todas as estruturas de moléculas orgânicas presentes em nosso planeta. O ciclo do carbono pode ser subdividido em dois ciclos diferentes: o ciclo geológico do carbono e o ciclo biológico do carbono. A movimentação do carbono pelo ciclo geológico se dá através de processos físicos e químicos entre agentes abióticos, como por exemplo, a formação de chuva ácida, o intemperismo de rochas e sedimentos e erupções vulcânicas.

O ciclo biológico do carbono envolve seres vivos e processos bioquímicos, como a fotossíntese e a respiração. Organismos fotossintetizantes absorvem gás carbônico e água do meio, e no processo de fotossíntese, produzem carboidratos e liberam oxigênio, e a liberação de gás carbônico para a atmosfera ocorre através do processo de respiração com a oxidação de carboidratos (GOWER, 2003).

Os ecossistemas florestais desempenham um papel fundamental no ciclo de carbono e conseqüentemente como retardador das mudanças climáticas, visto que as florestas são grandes reservatórios de carbono e podem, ao serem desmatadas ou degradadas, liberar este estoque de carbono para a atmosfera (FUCHS et al., 2009; GIBBS et al., 2007; MUUKKONEN; HEISKANEN, 2007), aumentando sua concentração de dióxido de carbono, que é considerado um dos maiores responsáveis pelo efeito estufa (VAN PHAM et al., 2019).

De acordo com relatório lançado pela Organização das Nações Unidas para Alimentação e Agricultura em 2020 (FAO 2020 – sigla em inglês) a maior parte do carbono presentes nas florestas está ligado a biomassa viva (44%) e na matéria orgânica do solo (45%), com o restante em madeira morta e lixo. O relatório indica também que o estoque total de carbono reduziu de 1990 para o ano atual, de 668 gigatoneladas para 662 gigatoneladas, além da densidade de carbono ter sofrido um acréscimo de 159 toneladas para 163 toneladas por hectares nos respectivos anos.

A gestão adequada das florestas pode colaborar na redução de liberação do gás de dióxido de carbono na atmosfera (ZHENG et al., 2011). Liu et al. (2015) afirmam que para se estabelecer estratégias de redução destas emissões é preciso realizar um monitoramento adequado do estoque de carbono temporalmente para determinar atividades adequadas para cada tipo de fitofisionomia e observar atividades que provoquem mudanças nos fluxos de carbono.

2.4 Inventário Florestais

A importância das florestas para o desenvolvimento do homem proporcionou a necessidade de se quantificar seus recursos de forma mais eficiente possível. O inventário florestal é uma atividade que visa quantificar e qualificar uma determinada característica da floresta, assim como outros atributos sobre as áreas em que as árvores estão se desenvolvendo (HUSH et al. 1993).

Para Soares et al. (2011) várias informações podem ser geradas por um inventário florestal completo, como, estimativa de área; descrição da topografia; mapeamento da propriedade; descrição de acessos; facilidade de transporte da madeira; estimativa da quantidade e qualidade de diferentes recursos florestais e estimativa de crescimento (com inventário contínuo). Os autores também ressaltam que informações adicionais sobre fauna, recursos hídricos, entre outras, podem ser coletadas, quando necessárias.

A princípio o inventário era utilizado para estimativa de volume das toras, árvores e cálculo de incremento e de produtividade, mas recentemente o seu uso tem se difundido para outras áreas do conhecimento, como o manejo de bacias hidrográficas, trabalho com fauna selvagem, qualidade de plantio e controle de pragas e doenças (HYYPÄ, et al., 2008).

2.5 Sensoriamento Remoto

Com a evolução da ciência e da tecnologia, muitas ferramentas foram desenvolvidas para avaliar e monitorar a superfície terrestre, facilitando e aperfeiçoando o trabalho da humanidade, dentre eles podemos citar o sensoriamento remoto.

Segundo Meneses e Almeida (2012, p. 03), “Sensoriamento Remoto é uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e

medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres”.

Como explicado por Xie, Sha e Yo (2008), o sensoriamento remoto é uma tecnologia que visa a obtenção de imagens de um determinado objeto remotamente, onde cada objeto pode ser identificado através do sensor pelo seu comportamento espectral exclusivo, que são as regiões de reflectância, como por exemplo, a identificação de vegetações através de bandas vermelhos e infravermelhos.

Devido a sua capacidade de obter várias imagens de um mesmo local em diferentes épocas do ano, esta tecnologia se mostrou uma excelente ferramenta para desenvolver estudos e pesquisas em escala temporal, obtendo informações atuais e podendo projetar e obter imagens de décadas anteriores (XIE; SHA; YU, 2008; FOODY; BOYD; CUTLER, 2003).

O sensoriamento remoto tem sido amplamente utilizado para projetos voltados para a indústria florestal e estudos climáticos, como a de modelagem, mapeamento e conhecimento dos recursos naturais (LEFSKY et al., 2002). Seu uso é dividido em duas categorias: (i) sensores ópticos passivos, que medem a radiação refletida de objetos presentes na superfície terrestre, (ii) sensores ativos, que liberam fluxos de energia e obtém informações da energia retornada no sensor (ZOLKOS; GOETZ; DUBAYAH, 2013), como podemos citar o Lidar e o RADAR.


3 MATERIAIS E MÉTODOS

3.1 Área de Estudo

O estado de Minas Gerais (MG) está localizado na região sudeste do Brasil com uma área de 586.521 Km² (Figura 1), sendo o quarto maior estado do país, com uma população estimada em cerca de 21 milhões de habitantes e uma densidade demográfica de 33,41 hab/Km² (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2010, 2019).

O estado apresenta treze grupos de classificação de solos do Sistema Brasileiro de Classificação de Solos (DE SOUZA et al., 2015). Sua temperatura média anual varia entre 10 a 26 °C e sua chuva anual varia entre 700 a 1900 mm (ALVARES et al., 2013). A elevação do terreno no estado pode variar entre 30 a 2.824 m, onde a maior elevação se encontra na região leste e possui uma grande variedade de clima no estado (SILVEIRA et al., 2019), onde segundo a classificação de Koppen, o estado apresenta quatro climas: Aw (clima de savana com inverno seco), Cfa (clima subtropical) e Cwa e Cwb (clima tropical) (DAVID, et al., 2017).

Figura 1 - (a) Localização do estado de Minas Gerais na região Sudeste do Brasil; (b) Distribuição dos biomas dentro do estado de Minas Gerais.



Fonte: Do autor (2021).

Três dos principais biomas presentes do Brasil fazem parte do estado de Minas Gerais, Cerrado, Mata Atlântica e Caatinga, que representam 57%, 41% e 2% de seu território no estado mineiro, respectivamente (MORAIS et al., 2020; SCOLFORO et al., 2015). Segundo Silveira et al. (2019), o Cerrado ocorre nas regiões ao norte do estado, descendo para a parte central e indo até o oeste do estado; a Mata Atlântica se concentra na região centro-sul indo até o leste do estado com uma composição de florestas semidecíduas e ombrófilas; a Caatinga é composta por florestas decíduas situadas no extremo norte do estado. Estes biomas são alvo de grandes estudos e pesquisas pelos seus altos valores ambientais e por serem considerados grandes áreas de biodiversidade como a Caatinga (RYLANDS; BRANDON, 2005) e hotspots da biodiversidade do planeta como o Cerrado e a Mata Atlântica (MYERS et al., 2000).

A Mata Atlântica é considerada a segunda maior floresta tropical úmida da América do Sul, logo atrás da Floresta Amazônica, e seus recursos foram amplamente explorados e degradados devido a sua localização estar próximo aos maiores centros urbanos do Brasil onde ocorreram as primeiras chegadas de imigrantes europeus (OLIVEIRA-FILHO; FONTES, 2000). Apesar de toda fragmentada e seu território original extremamente reduzido, estima-se que a biodiversidade da Mata Atlântica gira em torno de 1 a 8% do total de espécies no mundo da fauna e flora (DA SILVA; CASTELETTI, 2003). O bioma é composto por duas fitofisionomias principais, Floresta Estacional Semidecidual e Floresta Tropical (também conhecida como Floresta Ombrófila) (SCOLFORO, et al., 2015; SCOLFORO et al., 2016)

Ribeiro et al. (2009) relatam que originalmente, o bioma da Mata Atlântica contava com cerca de 150 milhões de hectares, e em seu estudo avaliando todos os fragmentos da floresta restantes, constataram que a formação apresenta 11,73% de sua área original, ou seja, 16.377.472 ha. Os autores relataram também que o bioma apresenta 245.173 fragmentos florestais espalhados por 17 estados brasileiros que fazem divisa com outros biomas, onde o maior remanescente está presente na Serra do Mar e os pequenos fragmentos (menores que 50 ha) são a maioria dos fragmentos, totalizando 83,4% de fragmentos entre 0-50 ha que compreende um total de 20,2 % da área total.

O Cerrado cobre cerca de 22% do território brasileiro e se localiza predominantemente nas regiões centrais do Brasil, apresentando uma vegetação de savana com estratos densamente arborizados, arbustos espalhados, campos secos e espécies lenhosas com grande revestimento de cortiça, e sofreu nos últimos 50 anos perda de seu território original sendo convertidos principalmente em agricultura e pecuária (SALATINO et al., 2020). A savana brasileira faz

fronteira com quatro biomas brasileiros: Amazônia, Caatinga, Mata Atlântica e Pantanal (SANO, et al., 2019) e é considerado um hotspot de biodiversidade do mundo e um grande reservatório de carbono no solo (MORAIS et al., 2020). O bioma apresenta 30% da biodiversidade brasileira e apesar de sua riqueza, apenas cerca de 8% do hotspot do Cerrado está protegido em áreas de preservação (FRANÇOSO et al., 2015).

A vegetação típica da Caatinga é representada por floresta estacional decídua, onde apresentam indivíduos arbóreos lenhosos de copa descontínua, arbustivos, com formação espinhosa, e cactos, onde as árvores podem medir entre 3 a 9 metros de altura e apresentam características de xerofília e microfilia e a camada superficial do solo é diversa entre bromélias, geófitos e ervas (PRADO, 2003; SCOLFORO et al., 2015; BARBOSA et al., 2019). Comparado com outros biomas florestais tropicais, a Caatinga apresenta uma menor biodiversidade, suas chuvas são irregulares, com baixa precipitação e longos períodos de seca (JARED et al., 2019). Sua vegetação é muito explorada economicamente pelas indústrias farmacêuticas, cosméticas, alimentícias e como matéria prima para produtos medicinais da população brasileira (PEREIRA et al., 2020; MAGALHÃES et al., 2019).

3.2 Base de Dados

Para a predição da biomassa aérea acima do solo foram utilizados dois conjuntos de dados: dados de campo advindos do Inventário Florestal de Minas Gerais e Índices de Sensoriamento Remoto extraídos de produtos do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*).

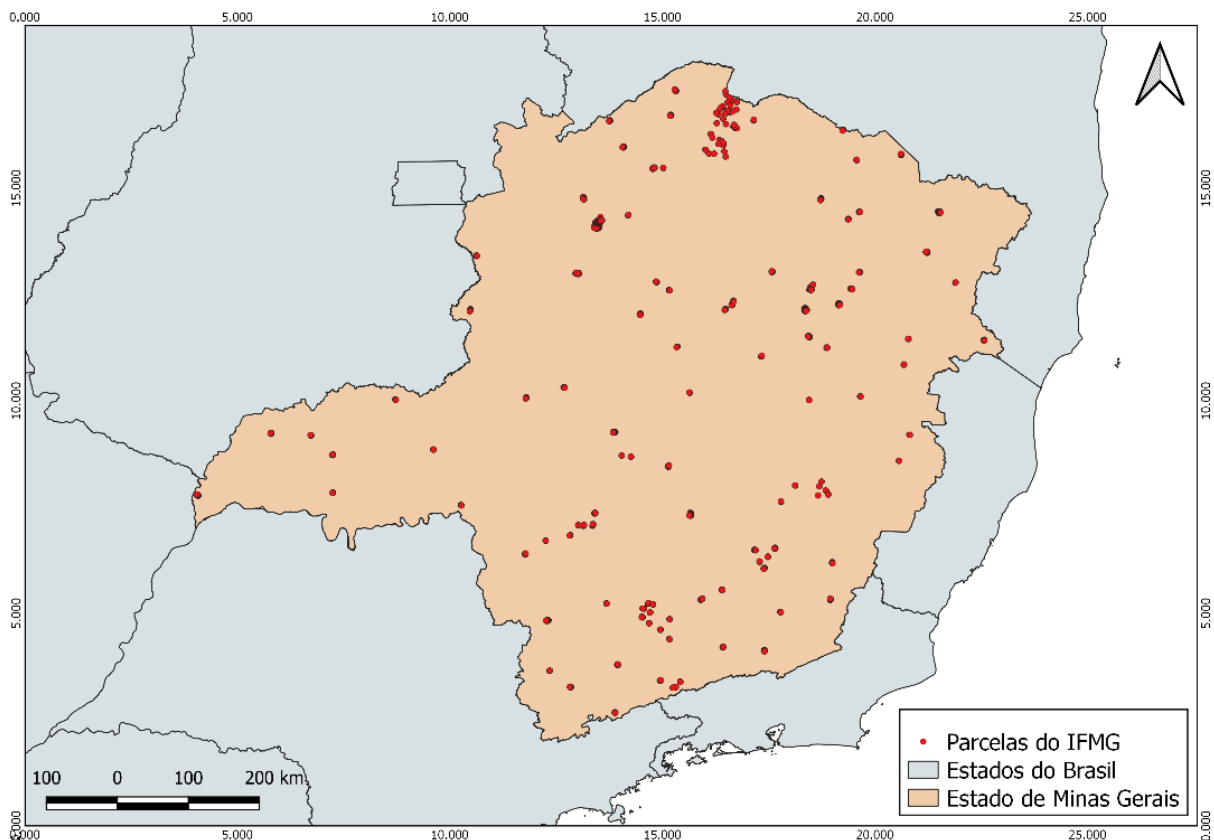
3.2.1 Dados de Campo

A biomassa acima do solo foi obtida a partir do “Inventário Florestal de Minas Gerais” (IFMG), projeto realizado durante o período de 2005 a 2008 através de uma parceria entre o Instituto Estadual de Florestas (IEF) com a Universidade Federal de Lavras (UFLA) que possibilitou extrair informações a respeito de remanescentes florestais, quantificação de estoque de carbono e o monitoramento do desenvolvimento florestal do estado através das parcelas permanentes instaladas e distribuídas proporcionalmente à área de cada domínio florestal do estado (CARVALHO; SCOLFORO, 2008).

As parcelas de campo apresentavam uma área de 1.000 m² (10 x 100 m) e foram georreferenciadas com procedimentos de amostragem sistemático separados em diferentes estágios (Figura 3). Todos os indivíduos com diâmetro à altura do peito (DAP) igual ou maior que 5 cm foram mensurados sendo medidos a 1,30 m acima do solo, marcados e identificados taxonomicamente.

Para a obtenção da biomassa foi realizado a amostragem destrutiva dos indivíduos arbóreos, medindo-se primeiro o DAP, altura total e altura do fuste antes do abate, posteriormente sendo georreferenciada, cortada e medida por fita métrica e cubada através do método de Huber, separando amostras de discos de madeira para a determinação do peso seco. A determinação da biomassa foi realizada representando cada fitofisionomia divididas em diferentes classes de diâmetro e altura (SCOLFORO, 2008).

Figura 2 - Localização das parcelas permanentes do Inventário Florestal de Minas Gerais.



Fonte: Do autor (2021).

A base de dados presente nesta pesquisa continha 2.742 parcelas distribuídas em todo o território do estado de Minas Gerais, das quais 1.462 parcelas representavam o bioma da Mata

Atlântica, 846 parcelas referentes ao bioma do Cerrado e 434 parcelas correspondentes à Caatinga. A amostragem realizada para cada fitofisionomia está representada na tabela X.

Tabela 1 - Número de parcelas inventariadas em cada fitofisionomia.

BIOMA	FITOFISIONOMIA	PARCELAS
Mata Atlântica	Floresta Ombrófila	103
	Floresta Estacional Semidecidual	1.359
Cerrado	Cerradão	52
	Campo Cerrado	229
	Cerrado Sensu Stricto	565
Caatinga	Floresta Estacional Decidual	434
Total		2.742

Fonte: Do autor (2021).

3.2.2 Dados de Sensoriamento Remoto

Para o cálculo da biomassa acima do solo foram extraídos 5 produtos de vegetação da versão 6 do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) através da plataforma Google Earth Engine (GEE). Os produtos analisados foram: o Índice de Vegetação por Diferença Normalizada (NDVI, do inglês *Normalized Difference Vegetation Index*, MOD13Q1); Índice de Vegetação Melhorada (EVI, *Enhanced Vegetation Index*, MOD13Q1) ambos com resolução espacial de 250 metros; Fração de Radiação Fotossinteticamente Ativa (Fpar, do inglês *Fraction of Photosynthetically Active Radiation*, MOD15A2H); Índice de Área Foliar (LAI, do inglês *Leaf Area Index*, MOD15A2H) e Produtividade Primária Bruta (GPP, do inglês *Gross Primary Productivity*, MOD17A2H), estes com resolução espacial de 500 metros sendo uma resolução adequada para avaliações terrestres e considerado uma precisão moderada. Os rasters correspondentes às métricas extraídas dos diferentes produtos MODIS, com resoluções espaciais variadas, foram padronizados por reamostragem dos pixels para 100 x 100 metros (um hectare).

3.2.3 Variáveis Preditoras

Os dados do MODIS foram extraídos de uma coleção de imagens para o ano de 2007, sendo necessários 4 tiles do sensor para abranger toda a área de trabalho delimitado pelo limite do estado de Minas Gerais. Ao todo foram coletados dados de 23 imagens para as variáveis

NDVI e EVI (ambas apresentam resolução temporal de 16 dias) e 46 imagens para os índices Fpar, Lai e GPP (apresentando resolução temporal de 8 dias).

Antes do cálculo da biomassa utilizou-se a Avaliação de Qualidade (QA, do inglês *Quality Assessment*) para cada produto, identificando os pixels que deveriam ser excluídos da base de dados, removendo assim ruídos causados por nuvens ou neblinas e valorizando pixels terrestres.

Após a validação da qualidade dos pixels, foram calculados por parcela o Desvio Padrão (DP), Valor Acumulado (Acum), Valor Mínimo (Min), Valor Máximo (Max), Média (Med) e o Coeficiente de Variação (CV) através do GEE para cada um dos 5 índices de sensoriamento remoto, totalizando 30 variáveis para a predição de biomassa. Posteriormente, os resultados foram extraídos do GEE para futura modelagem da biomassa arbórea acima do solo. O procedimento foi realizado para o ano inteiro de 2007 para o estado de Minas Gerais assim como também pra as estações do ano de verão e inverno. Para o inverno foi realizado um filtro na seleção das imagens do sensor MODIS entre os meses de abril a outubro de 2007, para o verão foram obtidas imagens de janeiro a março de 2007 e de outubro a dezembro de 2007.

Tabela 2 - Índices de sensoriamento remoto usados para modelagem da biomassa arbórea acima do solo para o estado de Minas Gerais.

SENSOR MODIS	RESOLUÇÃO ESPACIAL	RESOLUÇÃO TEMPORAL	VARIÁVEIS	SIGLA
MOD13Q1	250 m	16 dias	NDVI Desvio Padrão	NDVI DP
			NDVI Média	NDVI Med
			NDVI Acumulado	NDVI Acum
			NDVI Mínimo	NDVI Min
			NDVI Máximo	NDVI Max
			NDVI Coeficiente de Variação	NDVI CV
			EVI Desvio Padrão	EVI DP
			EVI Média	EVI Med
			EVI Acumulado	EVI Acum
			EVI Mínimo	EVI Min
			EVI Máximo	EVI Max
MOD15A2H	500 m	8 dias	EVI Coeficiente de Variação	EVI CV
			Fpar Desvio Padrão	Fpar DV
			Fpar Média	Fpar Med
			Fpar Acumulado	Fpar Acum
			Fpar Mínimo	Fpar Min
			Fpar Máximo	Fpar Max
			Fpar Coeficiente de Variação	Fpar CV

Tabela 2 – conclusão.

SENSOR MODIS	RESOLUÇÃO ESPACIAL	RESOLUÇÃO TEMPORAL	VARIÁVEIS	SIGLA
MOD15A2H	500 m	8 dias	Lai Desvio Padrão	Lai DP
			Lai Média	Lai Med
			Lai Acumulado	Lai Acum
			Lai Mínimo	Lai Min
			Lai Máximo	Lai Max
			Lai Coeficiente de Variação	Lai CV
MOD17A2H	500 m	8 dias	GPP Desvio Padrão	GPP DV
			GPP Média	GPP Med
			GPP Acumulado	GPP Acum
			GPP Mínimo	GPP Min
			GPP Máximo	GPP Max
			GPP Coeficiente de Variação	GPP CV

Fonte: Do autor (2021).

3.3 Random Forest

Para a predição da AGB foi utilizado o algoritmo Random Forest (RF) (BREIMAN, 2001), que trabalha otimizando conjuntos de árvores de classificação e regressão. Os modelos de RF são compostos por nós que apresentam uma amostra de valores de entrada sendo dividido em subconjuntos selecionando aleatoriamente as variáveis preditoras. Foi utilizado o pacote `randomForest` presente no software RStudio.

De toda a base de dados coletada, 70% foi selecionado e usado aleatoriamente para o ajuste do modelo. Os outros 30% restantes foram utilizados como teste e validação do modelo. O número de árvores de decisão (`Ntree`) foi definido como 1.000. O número de variáveis preditoras amostradas aleatoriamente a cada divisão da árvore (`mtry`) foi definido como 30. O software selecionou a sequência que apresentou a menor iteração de erro.

O procedimento foi realizado para a AGB total para estado de Minas Gerais, assim como para cada uma de suas fitofisionomias. Para melhorar o desempenho preditivo da AGB utilizou-se o erro OOb (out of bag) como critério de minimização. Identificou-se o menor número de variáveis com o menor erro quadrático médio (MSE), eliminando assim as variáveis menos importantes retornadas pelo RF. Primeiramente as variáveis de importância do Random Forest foram utilizadas para obter uma classificação inicial das variáveis e posteriormente realizou-se a eliminação das variáveis menos importantes pela sua iteração na predição, iniciando uma nova rodagem no Random Forest com os dados restantes.

Para avaliar o desempenho da predição foi calculado o coeficiente de determinação (R^2 , Equação 1) que é a porcentagem da variação da variável resposta que é explicada por um modelo linear e o coeficiente de determinação ajustado (R^2 ajust, em %, Equação 2) que relaciona a parte da variabilidade observada que é explicada pelo modelo e ajusta o número de termos em um modelo.

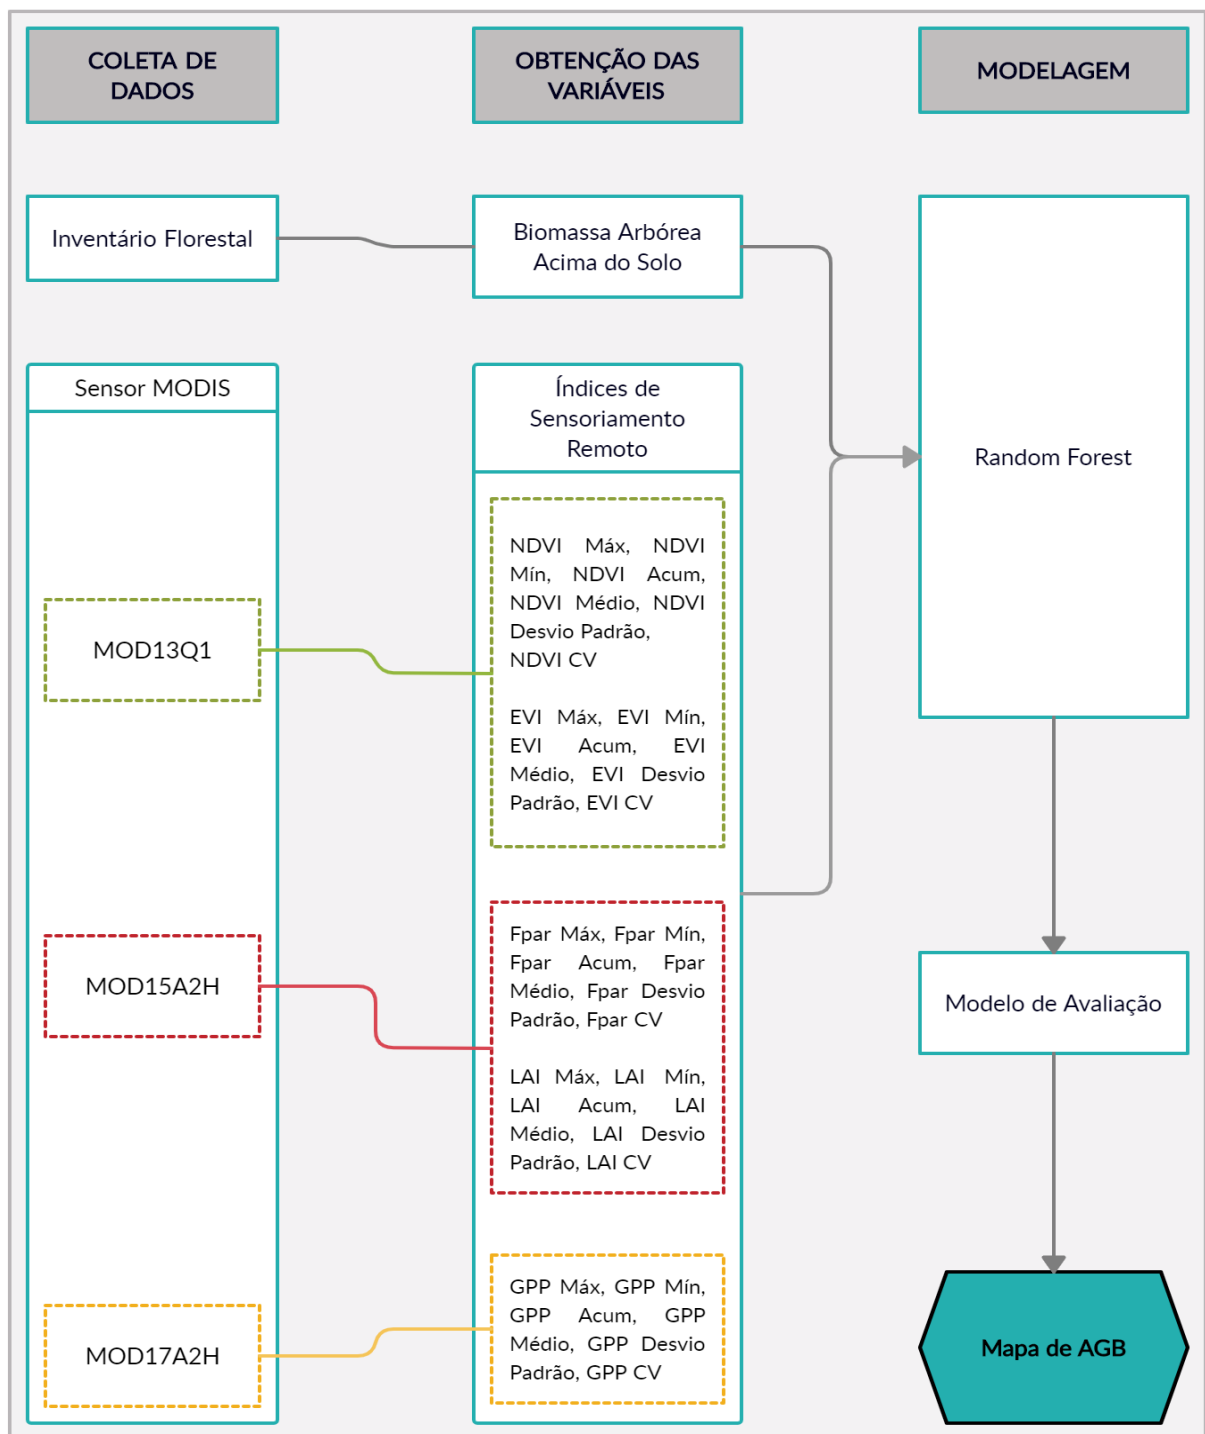
$$R^2 = \frac{SQt - SQr}{SQt} \quad (1)$$

$$R^2_{ajus} = 1 - \frac{(n-1) \cdot (1-R^2)}{(n-1) - k} \quad (2)$$

Em que: SQt é a soma do quadrado dos erros totais; SQr é a soma do quadrado dos erros residuais; n é o número de observações e k o número de variáveis selecionadas.

A Figura 3 apresenta o fluxograma com a metodologia utilizada para a realização desta pesquisa.

Figura 3 - Fluxograma das principais etapas para modelagem da biomassa arbórea acima do solo para o estado de Minas Gerais.



Fonte: Do autor (2021).

4 RESULTADOS E DISCUSSÃO

4.1 Resultados

Um resumo das estatísticas da modelagem se encontra na Tabela 2. Pode ser observado que todos os R^2 obtiveram um valor de moderado a baixo para o ano de 2007, onde as áreas que apresentaram maior valor foram AGB Total e Cerrado Senso Stricto com $R^2 = 0,36$; seguido do Cerradão com $R^2 = 0,33$ e Floresta Estacional Decidual com $R^2 = 0,22$. As fitofisionomias Floresta Estacional Semidecidual, Floresta Ombrófila e Campo Cerrado obtiveram $R^2 = 0,02$, $R^2 = 0,01$ e $R^2 = 0,01$ respectivamente, sendo considerados resultados muito baixos apresentando um desempenho fraco para a estimativa da biomassa dentro destas fitofisionomias.

Para o inverno pode ser observado que todos os R^2 obtiveram um valor de moderado a baixo, onde as áreas que apresentaram maior valor foram Cerrado Senso Stricto e AGB Total com $R^2 = 0,47$ e $R^2 = 0,39$ respectivamente; seguido da Floresta Estacional Decidual com $R^2 = 0,24$ e Campo Cerrado com $R^2 = 0,22$. As fitofisionomias Floresta Estacional Semidecidual, Floresta Ombrófila e Cerradão obtiveram $R^2 = 0,06$, $R^2 = 0,05$ e $R^2 = 0,05$ respectivamente, sendo considerados resultados muito baixos apresentando um desempenho fraco para a estimativa da biomassa dentro destas fitofisionomias.

Já para o verão Janeiro-Março pode ser observado que todos os R^2 obtiveram um valor de moderado a baixo, onde as áreas que apresentaram maior valor foram Cerrado Senso Stricto, AGB Total e Cerradão com $R^2 = 0,47$; $R^2 = 0,45$ e $R^2 = 0,43$ respectivamente; seguido da Floresta Ombrófila com $R^2 = 0,25$ e Floresta Estacional Decidual com $R^2 = 0,22$. As fitofisionomias Floresta Estacional Semidecidual e Campo Cerrado obtiveram $R^2 = 0,08$, $R^2 = 0,001$ respectivamente, sendo considerados resultados muito baixos apresentando um desempenho fraco para a estimativa da biomassa dentro destas fitofisionomias.

E por fim o verão Outubro-Dezembro obteve todos os R^2 com valores de moderado a baixo, onde as áreas que apresentaram maior valor foram AGB Total, Cerrado Senso Stricto e Floresta Estacional Decidual com $R^2 = 0,40$; $R^2 = 0,34$ e $R^2 = 0,23$ respectivamente; seguido de Campo Cerrado e Floresta Estacional Decidual, ambos com $R^2 = 0,13$. As fitofisionomias Cerradão e Floresta Ombrófila obtiveram $R^2 = 0,10$, $R^2 = 0,001$ respectivamente, sendo considerados resultados muito baixos apresentando um desempenho fraco para a estimativa da biomassa dentro destas fitofisionomias.

Tabela 3 - Estimativa de AGB para cada fitofisionomia para cada época do ano, utilizando o RF.

ÉPOCA DO ANO	ÁREA DE TRABALHO	NÚMERO DE VARIÁVEIS	R² (%)	R² ajus (%)
ANO DE 2007	AGB Total	22	0.36	0.34
	Floresta Estacional Semidecidual	7	0.02	0.00
	Floresta Ombrófila	5	0.01	-0.18
	Cerrado Senso Stricto	18	0.36	0.29
	Campo Cerrado	9	0.01	-0.14
	Cerradão	4	0.33	0.08
	Floresta Estacional Decidual	18	0.22	0.09
	AGB Total	24	0.39	0.38
	Floresta Estacional Semidecidual	8	0.06	0.04
	Floresta Ombrófila	20	0.05	-0.19
Inverno	Cerrado Senso Stricto	6	0.47	0.43
	Campo Cerrado	12	0.22	0.13
	Cerradão	7	0.05	-0.58
	Floresta Estacional Decidual	6	0.24	0.10
	AGB Total	4	0,45	0,44
	Floresta Estacional Semidecidual	2	0,08	0,07
	Floresta Ombrófila	11	0,25	0,09
	Cerrado Senso Stricto	5	0,47	0,38
Verão Jan-Mar	Campo Cerrado	24	0,001	-0,06
	Cerradão	4	0,43	0,28
	Floresta Estacional Decidual	3	0,22	0,15
	AGB Total	7	0,40	0,40
	Floresta Estacional Semidecidual	5	0,13	0,12

Tabela 3 – Conclusão.

ÉPOCA DO ANO	ÁREA DE TRABALHO	NÚMERO DE VARIÁVEIS	R² (%)	R² ajus (%)
Verão Out-Dez	Floresta Ombrófila	8	0,001	-0,36
	Cerrado <i>Senso Stricto</i>	8	0,34	0,23
	Campo Cerrado	22	0,13	-0,03
	Cerradão	11	0,10	-0,35
	Floresta Estacional	5	0,23	0,18
	Decidual			

Fonte: Do autor (2021).

O modelo de RF para o ano de 2007 mostrou que das 30 variáveis totais, 22 variáveis apresentavam melhor precisão preditiva e foram selecionadas para o AGB total do estado de Minas Gerais, 7 variáveis para a fitofisionomia Floresta Estacional Semidecidual, 5 variáveis para Floresta Ombrófilas, 18 variáveis para Cerrado *Senso Stricto*, 9 variáveis para Campo Cerrado, 4 variáveis para Cerradão e 18 variáveis para Floresta Estacional Decidual. As variáveis selecionadas com seus respectivos Incrementos no Erro Quadrático Médio (% INCMSE) podem ser encontradas na Tabela 3.

Tabela 4 - Variáveis selecionadas na modelagem de AGB para o ano de 2007 do estado de Minas Gerais.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
AGB Total	GPP Acum	40.40
	EVI Max	35.75
	GPP Max	35.11
	GPP DP	34.56
	GPP CV	31.54
	EVI DP	31.50
	LAI Acum	31.37
	GPP Med	30.79
	Lai CV	29.72
	EVI Min	29.31
	EVI Med	29.10
	Fpar Max	28.48
	NDVI Acum	27.83
	Fpar DP	27.02
	NDVI Min	27.01
NDVI CV	26.82	

Tabela 4 – Continuação.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
AGB Total	NDVI Max	26.24
	GPP Min	26.23
	EVI CV	25.92
	NDVI DP	25.26
	Fpar CV	23.45
	Lai DP	23.28
Floresta Estacional Semidecidual	GPP Acum	49.62
	Fpar DP	46.60
	NDVI Max	41.55
	GPP DP	40.38
	GPP CV	39.02
	NDVI DP	36.83
Floresta Ombrófila	NDVI CV	36.05
	NDVI Min	19.07
	Fpar Acum	15.46
	Fpar Max	14.28
	NDVI DP	13.37
Cerrado Censo Stricto	EVI Acum	12.82
	EVI Min	23.62
	GPP DP	20.57
	EVI Max	19.05
	NDVI Min	18.94
	EVI Med	18.72
	EVI Acum	17.27
	NDVI Acum	13.33
	NDVI Med	13.15
	GPP Min	13.09
	Lai Acum	12.85
	NDVI CV	12.75
	Fpar Min	12.63
	Fpar DP	12.57
	EVI CV	12.17
NDVI Max	12.15	
Fpar CV	11.99	
GPP Acum	11.16	
Fpar Acum	10.64	
Campo Cerrado	NDVI Med	16.10
	NDVI Min	15.80
	EVI Med	14.17
	GPP Min	13.97
	NDVI Acum	13.96
	Lai Max	12.79
	Lai Med	12.77
EVI Acum	11.81	

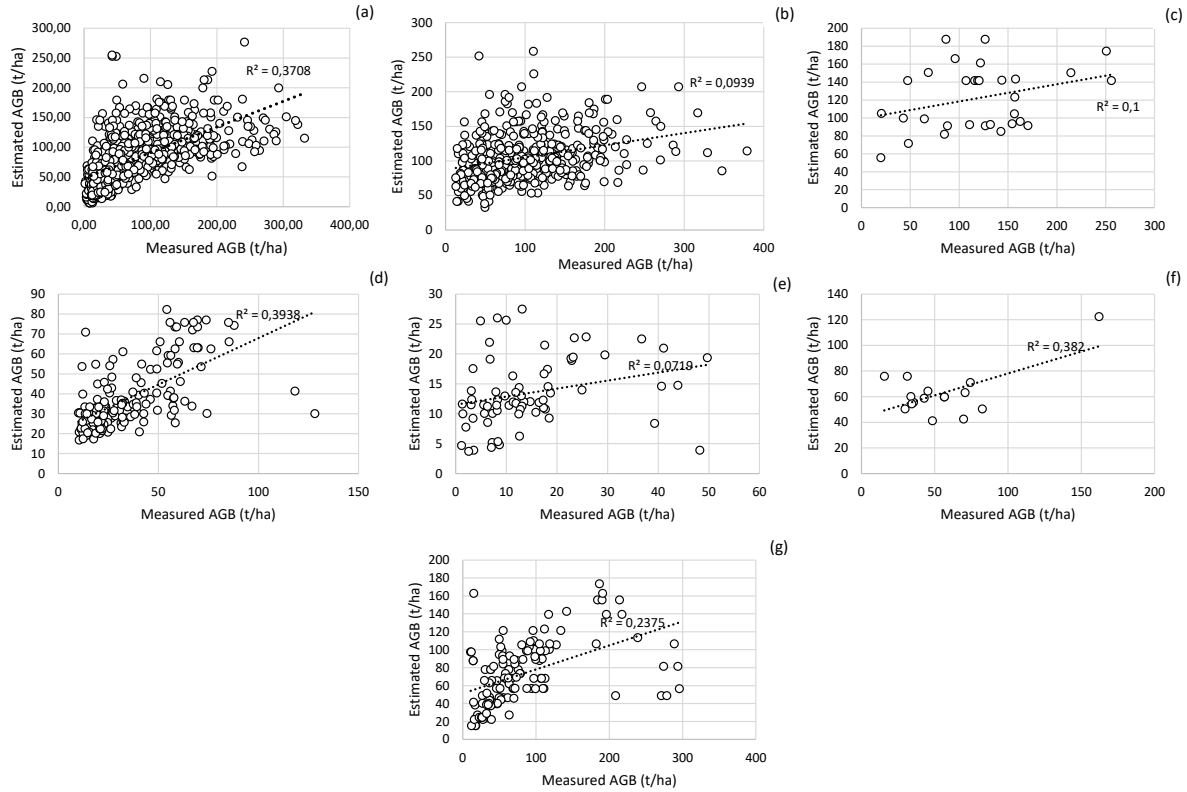
Tabela 4 – Conclusão.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Campo Cerrado	EVI CV	8.33
Cerradão	Fpar Min	15.95
	Fpar Max	14.59
	Lai Max	14.03
	Fpar Med	13.83
Floresta Estacional Decidual	EVI Min	25.82
	EVI Max	24.73
	GPP CV	23.77
	GPP Med	23.75
	EVI DP	22.90
	Fpar DP	20.78
	NDVI Min	19.94
	GPP Acum	19.54
	Lai Acum	19.13
	Lai Max	18.55
	GPP Min	18.21
	Lai Min	17.94
	EVI Acum	17.32
	NDVI Max	17.20
	NDVI Acum	17.18
EVI Med	17.13	
NDVI Med	16.98	
EVI CV	16.67	

Fonte: Do autor (2021).

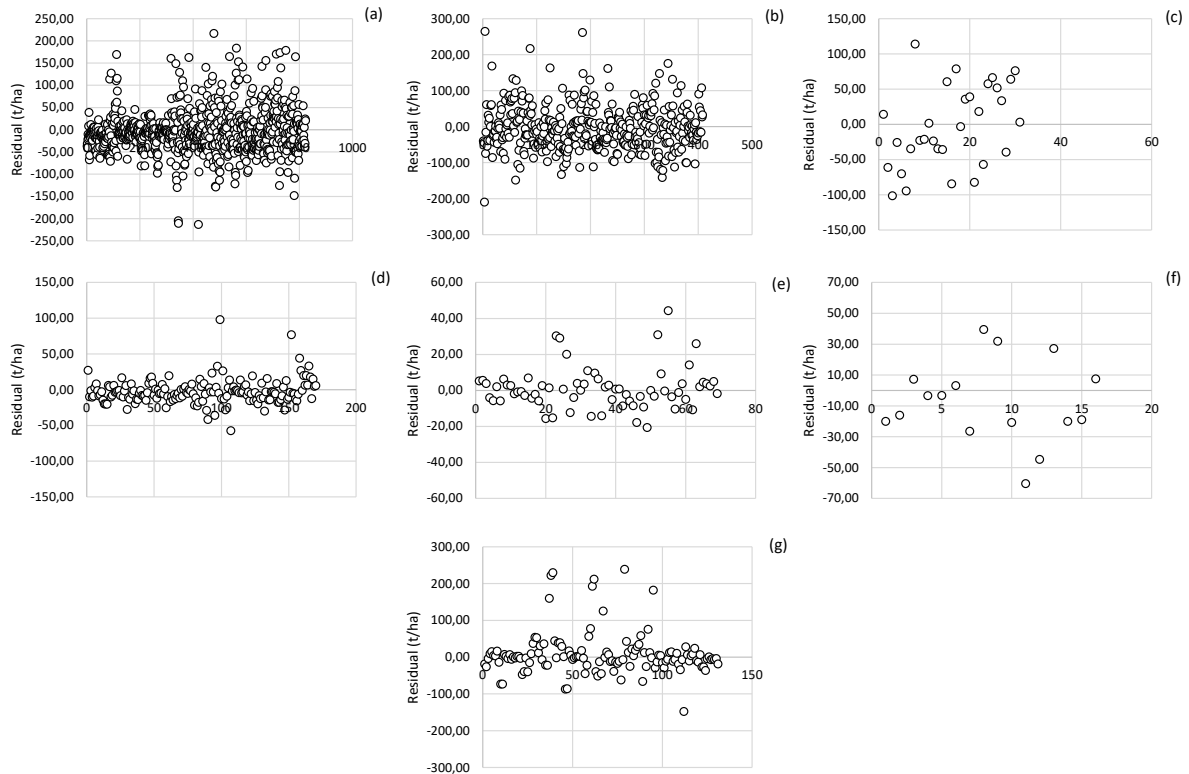
Os gráficos de dispersão e de distribuição de resíduos são apresentados nos gráficos 1, 2, 3, 4, 5, 6, 7 e 8.

Gráfico 1 - Gráficos de dispersão de valores medidos versus estimados de AGB por tipo de vegetação : (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

Gráfico 2 - Análise de resíduos: (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

O modelo de RF para o inverno mostrou que das 30 variáveis totais, 24 variáveis apresentavam melhor precisão preditiva e foram selecionadas para o AGB total do estado de Minas Gerais, 8 variáveis para a fitofisionomia Floresta Estacional Semidecidual, 6 variáveis para Floresta Ombrófilas, 12 variáveis para Cerrado Sensu Stricto, 7 variáveis para Campo Cerrado, 6 variáveis para Cerradão e 20 variáveis para Floresta Estacional Decidual, sendo apresentadas na Tabela 4, com seus respectivos Incrementos no erro quadrático médio (% INCMSE).

Tabela 5 - Variáveis selecionadas na modelagem de AGB para o inverno de 2007 do estado de Minas Gerais.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Área Total	Lai DP	39.35
	EVI DP	37.70
	GPP DP	33.30
	Lai CV	32.97
	EVI CV	32.80

Tabela 5 – Continuação.

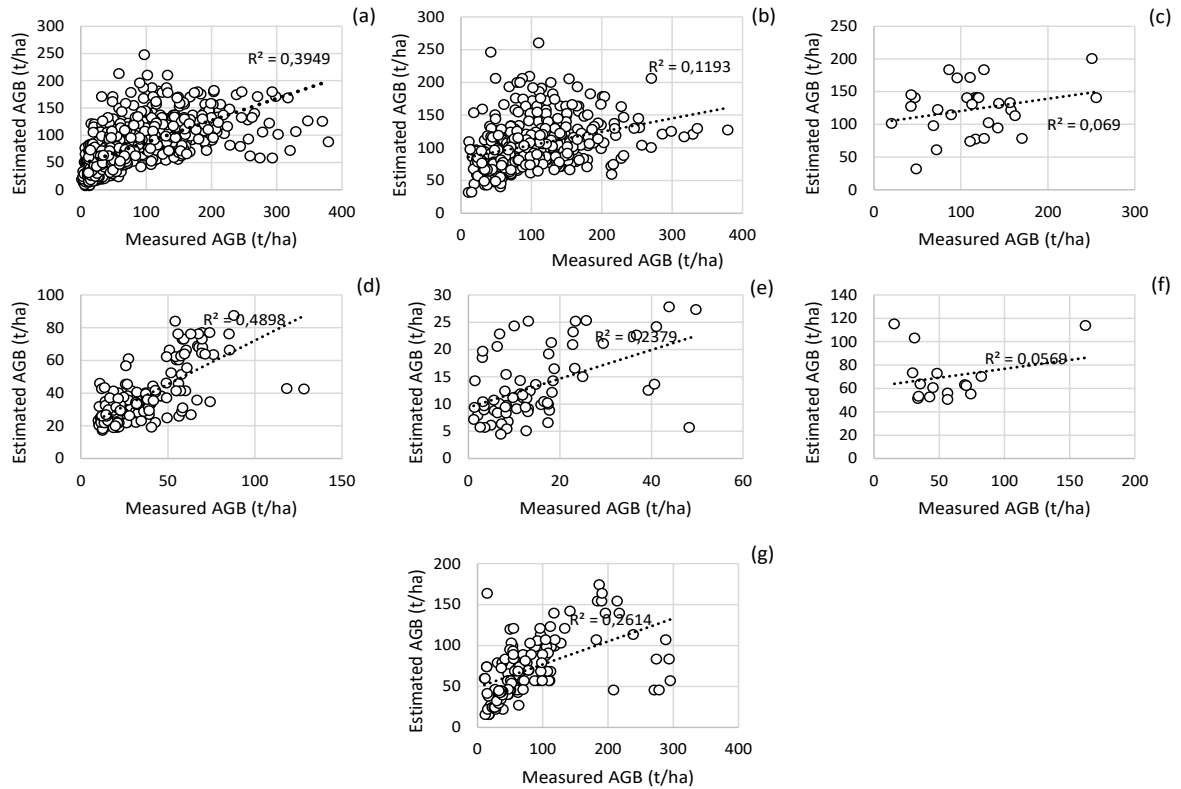
ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Área Total	Fpar Acum	30.85
	GPP Acum	30.23
	EVI Max	30.09
	Fpar DP	30.01
	GPP Min	29.35
	NDVI CV	29.05
	GPP CV	28.46
	GPP Med	28.18
	Fpar CV	27.68
	NDVI Min	26.24
	Lai Acum	26.21
	Fpar Med	25.85
	GPP Max	25.16
	NDVI Max	25.14
	Fpar Min	24.82
	EVI Min	24.22
	NDVI Acum	23.23
	NDVI DP	21.61
NDVI Med	21.08	
Floresta Estacional Semidecidual	GPP DP	44.14
	GPP Min	44.04
	GPP Acum	42.63
	Fpar CV	39.60
	Fpar Acum	38.22
	Fpar DP	35.91
	EVI DP	35.43
	NDVI DP	35.35
Floresta Ombrófila	NDVI DP	20.60
	NDVI CV	18.43
	NDVI Med	12.95
	EVI Max	12.56
	NDVI Acum	11.88
	Fpar CV	11.31
Cerrado Censo Stricto	NDVI CV	21.81
	NDVI Acum	20.44
	Lai Acum	20.33
	NDVI DP	20.19
	NDVI Med	19.17
	NDVI Max	18.71
	EVI Min	18.57
	GPP CV	17.15
	Fpar CV	16.94
	Fpar DP	15.57
NDVI Min	15.00	

Tabela 5 – Conclusão.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Cerrado Censo Stricto	Fpar Acum	13.09
Campo Cerrado	GPP Min	23.36
	NDVI Med	21.50
	Fpar Med	20.89
	Lai Max	19.19
	Lai DP	19.16
	Fpar DP	18.10
	NDVI Min	16.61
Cerradão	Lai Med	23.54
	NDVI Max	14.49
	EVI Max	13.42
	NDVI Min	11.40
	Fpar Min	10.76
	Lai Acum	8.66
Floresta Estacional Decidual	EVI CV	24.51
	Fpar Max	24.39
	Lai DP	23.37
	EVI DP	21.15
Floresta Estacional Decidual	Fpar DP	20.32
	EVI Max	20.27
	NDVI Max	19.21
	NDVI Min	19.20
	GPP Med	18.67
	NDVI Acum	18.47
	NDVI CV	18.33
	EVI Med	17.59
	Lai Max	17.59
	GPP DP	16.89
	GPP Min	16.76
	NDVI DP	16.59
	EVI Acum	16.58
	GPP Acum	16.57
GPP Max	16.44	
GPP CV	16.42	

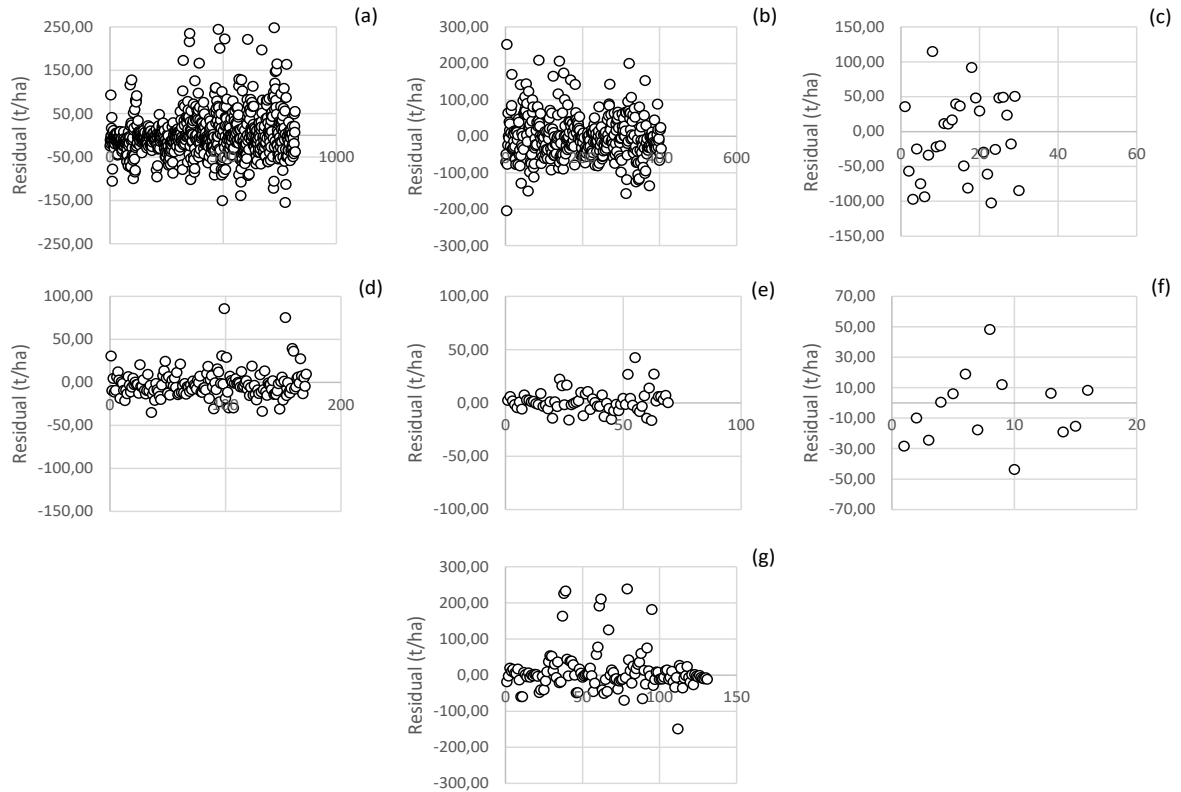
Fonte: Do autor (2021).

Gráfico 3 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação para o inverno de 2007 : (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

Gráfico 4 - Análise de resíduos para o inverno de 2007: (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: do autor (2021).

O modelo de RF para verão de janeiro a março mostrou que das 30 variáveis totais, 4 variáveis apresentavam melhor precisão preditiva e foram selecionadas para o AGB total do estado de Minas Gerais, 2 variáveis para a fitofisionomia Floresta Estacional Semidecidual, 5 variáveis para Floresta Ombrófilas, 24 variáveis para Cerrado Sensu Stricto, 4 variáveis para Campo Cerrado, 3 variáveis para Cerradão e 11 variáveis para Floresta Estacional Decidual. As variáveis selecionadas com seus respectivos Incrementos no Erro Quadrático Médio (% INCMSE) podem ser encontradas na Tabela 5.

Tabela 6 - Variáveis selecionadas na modelagem de AGB para o verão de Janeiro a Março de 2007 do estado de Minas Gerais.

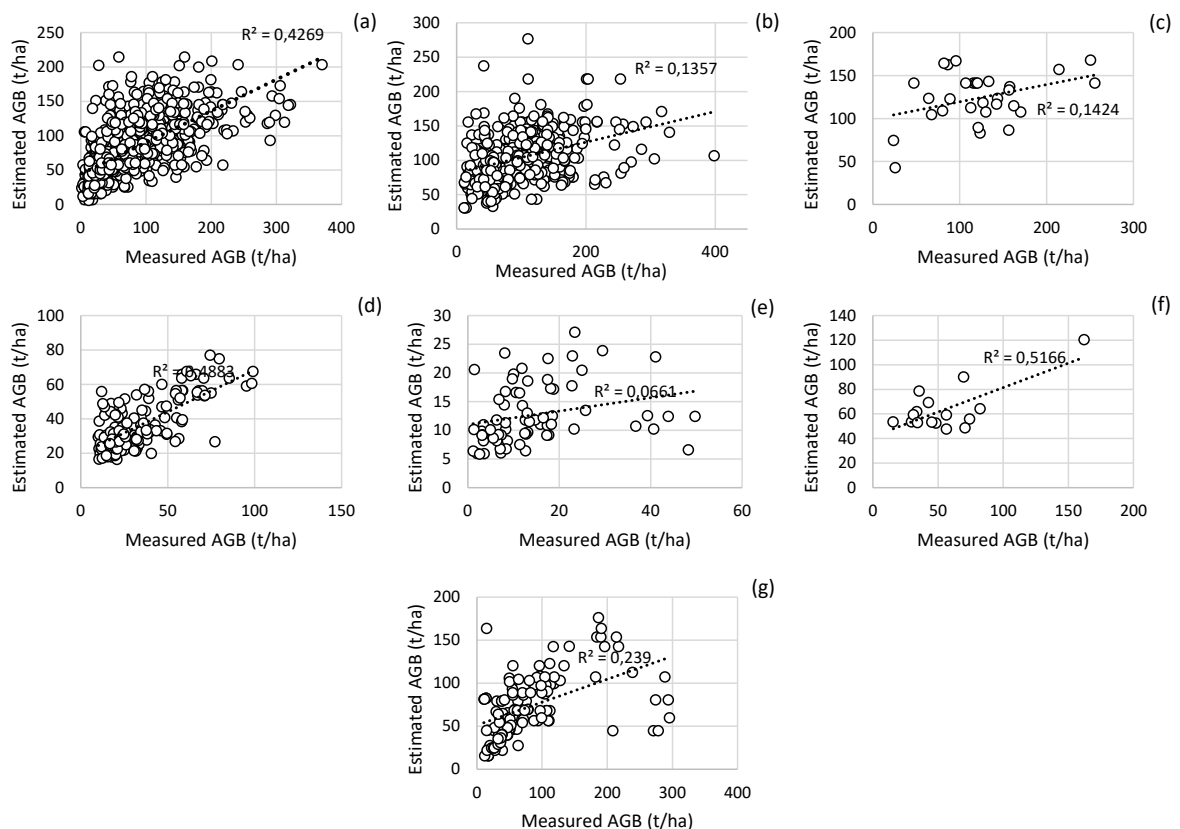
ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
AGB Total	GPP Acum	116.99
	Fpar Med	109.96
	GPP Med	102.41
	GPP Min	96.91
Floresta Estacional Semidecidual	GPP Acum	81.13
	GPP Max	80.61
Floresta Ombrófila	Fpar DP	13.03
	Lai DP	12.92
	NDVI Med	10.77
	GPP DP	9.84
	EVI Acum	9.18
	NDVI DP	19.37
Cerrado Censo Stricto	Lai Med	15.89
	GPP Max	15.77
	NDVI Min	14.62
	Fpar Max	14.41
	GPP Acum	14.38
	NDVI CV	14.35
	NDVI Med	14.18
	GPP Med	13.85
	Fpar Min	13.79
	Lai Max	13.55
	EVI Med	13.06
	Fpar Acum	12.60
	EVI DP	12.58
	Fpar Med	12.39
	NDVI Max	12.20
	NDVI Acum	12.19
	Lai DP	11.63
	EVI Acum	11.63
	Lai Acum	11.39
	EVI Max	11.28
GPP Min	11.04	
Fpar DP	10.63	
Lai CV	9.99	
Campo Cerrado	GPP Min	21.32
	Lai Max	19.22
	EVI Max	18.09
	GPP DP	17.31
Cerradão	EVI Acum	22.00
	NDVI Med	17.30
	NDVI Acum	16.89
Floresta Estacional Decidual	NDVI DP	29.92
	Fpar Min	29.76

Tabela 6 – Conclusão.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Floresta Estacional Decidual	GPP Max	29.35
	Fpar Med	29.14
	EVI Med	26.91
	EVI CV	26.89
	GPP CV	26.28
	Lai Min	26.00
	EVI Acum	25.38
	Fpar Acum	24.94
	NDVI Max	24.21

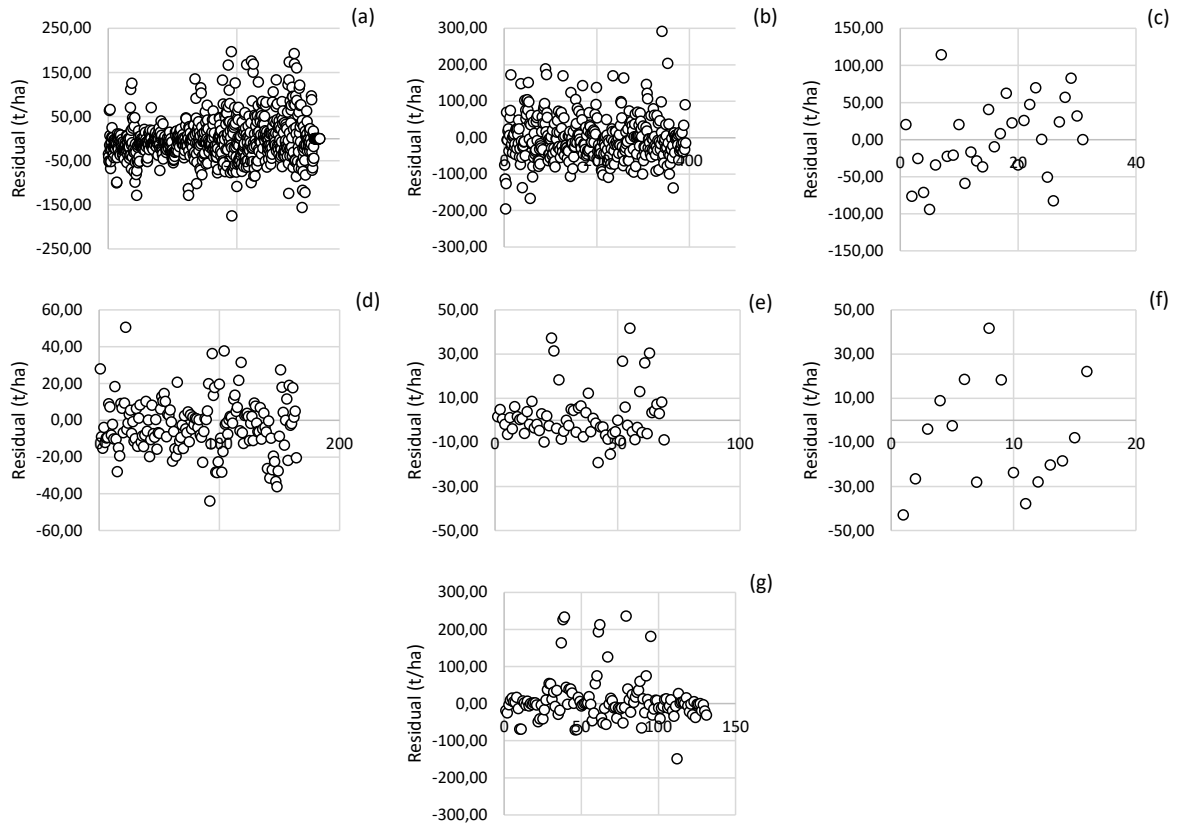
Fonte: Do autor (2021).

Gráfico 5 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação para o verão de janeiro a março de 2007 : (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

Gráfico 6 - Análise de resíduos: (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

O modelo de RF para verão outubro a dezembro mostrou que das 30 variáveis totais, 7 variáveis apresentavam melhor precisão preditiva e foram selecionadas para o AGB total do estado de Minas Gerais, 5 variáveis para a fitofisionomia Floresta Estacional Semidecidual, 8 variáveis para Floresta Ombrófilas, 22 variáveis para Cerrado Sensu Stricto, 11 variáveis para Campo Cerrado, 5 variáveis para Cerradão e 8 variáveis para Floresta Estacional Decidual. As variáveis selecionadas para cada fitofisionomia são apresentadas na Tabela 6, junto com seus Incrementos no Erro Quadrático Médio (% INCMSE).

Tabela 7 - Variáveis selecionadas na modelagem de AGB para o verão de outubro a dezembro de 2007 do estado de Minas Gerais.

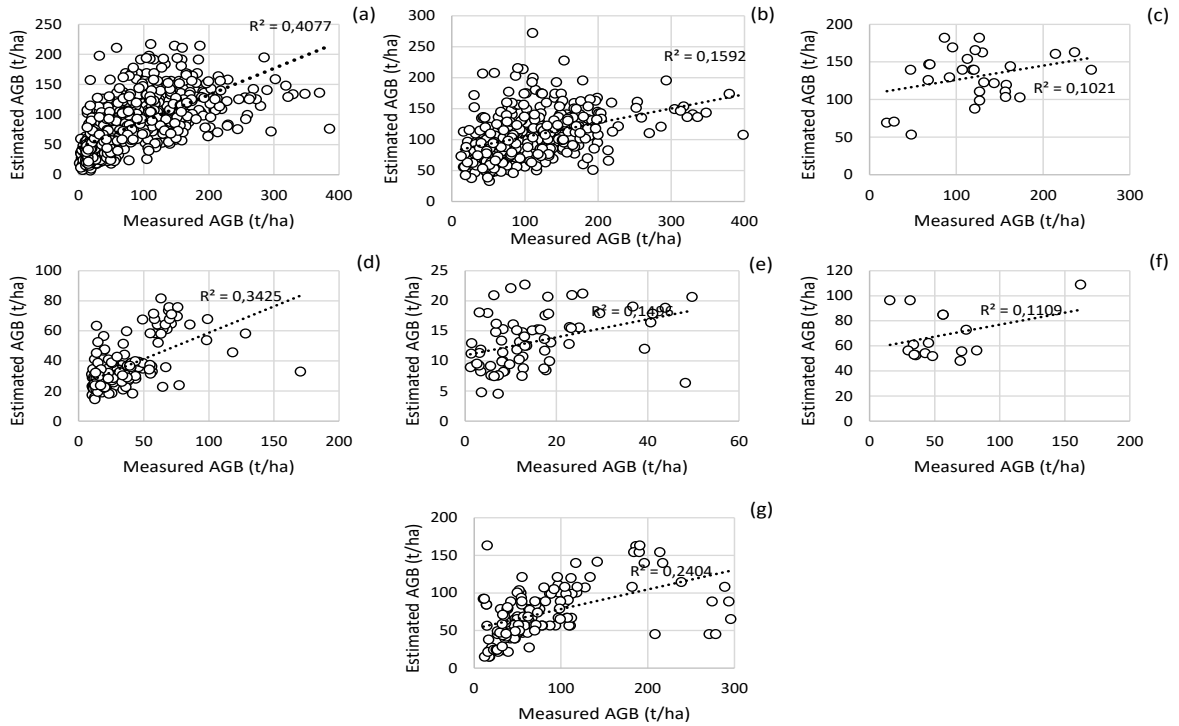
ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
AGB Total	Fpar Min	82.67
	EVI DP	66.46
	GPP Max	59.37
	EVI Max	58.59
	GPP Min	51.74
	GPP Med	51.03
	NDVI Max	50.26
Floresta Estacional Semidecidual	GPP Min	57.69
	Fpar Acum	55.58
	EVI Max	51.03
	GPP Max	48.25
	GPP Med	45.65
Floresta Ombrófila	EVI Min	16.23
	EVI DP	15.41
	EVI CV	14.91
	GPP Med	13.91
	EVI Acum	13.11
	NDVI DP	12.46
	NDVI Min	12.00
	GPP Acum	10.19
Cerrado Censo Stricto	EVI Med	20.30
	GPP DP	19.45
	EVI Acum	19.39
	NDVI Max	19.08
	Lai DP	18.14
	Fpar Max	17.94
	EVI Max	17.80
	Lai Max	17.49
	EVI Min	17.28
	Fpar Acum	16.59
	GPP CV	16.31
	NDVI Med	15.36
	GPP Acum	15.09
	NDVI Min	15.00
	GPP Min	14.06
	NDVI Acum	13.93
	Lai Min	13.00
GPP Med	12.69	
Lai Acum	12.53	
NDVI DP	12.46	
Fpar DP	12.29	
Fpar Min	10.67	
Campo Cerrado	NDVI Min	13.98

Tabela 7 – Conclusão.

ÁREA DE TRABALHO	VARIÁVEL	% INCMSE
Campo Cerrado	EVI Min	13.30
	EVI CV	12.64
Campo Cerrado	NDVI Med	11.91
	Lai Med	11.60
	Lai DP	11.45
	GPP Max	11.31
	NDVI Acum	11.25
	Fpar DP	10.01
	Lai CV	9.86
	NDVI CV	9.25
Cerradão	Fpar Min	15.63
	GPP Max	13.84
	GPP DP	13.20
	Fpar Med	12.28
	GPP Min	11.90
Floresta Estacional Decidual	NDVI Max	37.83
	GPP CV	37.49
	Lai CV	36.92
	Fpar Min	34.74
	Fpar DP	33.14
	EVI Min	31.55
	NDVI Min	30.74
Lai Min	29.65	

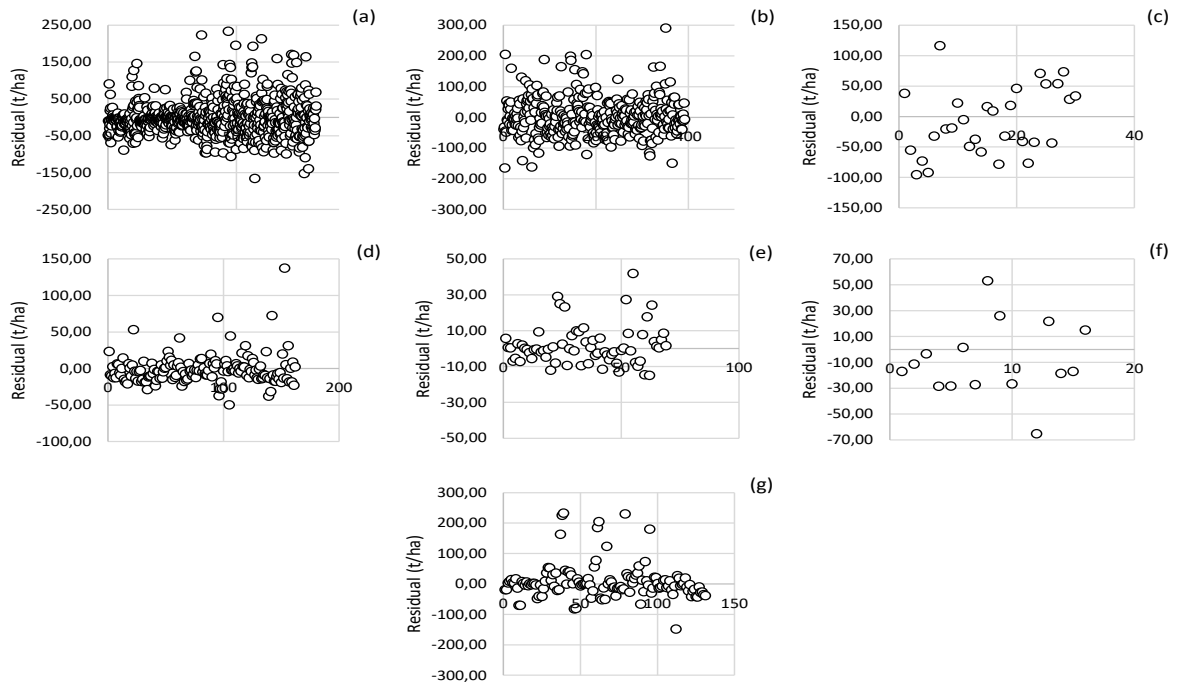
Fonte: Do autor (2021).

Gráfico 7 - Gráficos de dispersão de valores medidos versus estimados por modelo de floresta aleatória estratificada por tipo de vegetação : (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

Gráfico 8 - Análise de resíduos: (a) área total ; (b) Floresta Estacional Semidecidual; (c) Floresta Ombrófila; (d) Cerrado Sensu Stricto ; (e) Campo Cerrado; (f) Cerradão e (g) Floresta Estacional Decidual.



Fonte: Do autor (2021).

Na Tabela 8 pode ser observado a estimativa da biomassa para o estado de Minas Gerais para o ano de 2007 e para cada estação do ano assim como para cada fitofisionomia do estado. Pode ser observado também a comparação desta estimativa com a retirada do inventário florestal de Minas Gerais de 2007. Os dados obtidos para a tipologia Floresta Ombrófila foram superestimados para as épocas do ano de inverno e verão de outubro à dezembro, e subestimado para o verão de janeiro a março e para o ano todo de 2007. Ao se observar todas as outras fitofisionomias os valores obtidos foram subestimados ao se comparar com a biomassa do Inventário Florestal. A biomassa total para os dois verões e o inverno foram subestimados e para o ano todo de 2007 foi superestimado. No inverno se considera ser a melhor época do ano para realizar tais estimativas utilizando dados coletados remotamente devido a uma melhor presença de nuvens se comparado com o verão.

Tabela 8 - Biomassa total acima do solo para cada tipologia vegetal do estado de Minas Gerais.

Área de Estudo	Fitofisio-nomia	AGB – ton/ha				
		Inventário Florestal 2007	Ano todo 2007	Inverno 2007	Verão Jan-Mar	Verão Out-Dez
Mata Atlântica	FOM	12.781,96	12.693,03	13.290,65	12.722,49	14.367,83
	FES	140.563,93	135.767,13	133.552,15	136.353,09	137.909,68
	Cdao	3.451,05	3.110,31	3.273,37	2.987,20	3.053,97
Cerrado	CampC	3.171,55	2.754,16	2.557,53	2.525,00	2.938,12
	CSS	19.763,46	18.588,31	18.001,54	17.219,33	17.767,57
Caatinga	FED	33.147,86	29.526,58	29.605,99	29.558,01	29.157,94
AGB Total		212.879,80	216.410,87	201.919,37	202.108,15	207.501,52

Fonte: Do autor (2021).

4.2 Discussão

Para o desenvolvimento de modelos de estimativa de biomassa é fundamental a seleção de variáveis adequadas. Neste estudo foram combinados dados de sensoriamento remoto extraídos do sensor MODIS com dados de campo extraídos do Inventário Florestal de Minas

Gerais. Os resultados apresentaram uma grande diversidade de variáveis selecionadas para cada época do ano analisada. Os resultados adquiridos da correlação das 30 variáveis espectrais com a biomassa de diferentes tipos de vegetação mostraram que em apenas 5 áreas de trabalho apresentou uma correlação significativa de mais de 18 variáveis, indicando que grande parte das informações extraídas de sensoriamento remoto não representa as características da vegetação. Foi utilizado o algoritmo RandomForest para selecionar as variáveis independentes que estão intimamente ligadas a biomassa.

Fayad et al. (2016) utilizou dados de sensoriamento remoto, inventário florestal e ambientais para a estimativa de AGB e relatou que a precisão dos mapas foi 73,1 Mg / ha ($R^2 = 0,07$); 53,4 Mg / ha ($R^2 = 0,46$) e 46,7 Mg / ha ($R^2 = 0,48$) para diferentes tamanhos de grades gerados pelo RF. Du et al. (2012) utilizaram imagens Landsat para estimar a AGB por regressão linear múltipla e relataram um R^2 de 0,36. Silveira et al. (2019) encontrou um $R^2 = 0,28$ para AGB estimada a partir de dados de sensoriamento remoto como entrada no Random Forest.

O RandomForest é um algoritmo de aprendizado de máquina que tem sido amplamente utilizado na quantificação de AGB utilizando dados de sensoriamento remoto (CHEN et al., 2019; ZHANG et al., 2021; HOOVER et al., 2018; HLATSHWAYO et al., 2019; SILVEIRA et al., 2019). Um estudo realizado por Hlatshwayo et al. (2019), comparou a precisão de diferentes combinações de bandas extraídos do sensor SPOT-6 para a previsão de AGB, utilizando RL e Regressão Múltipla Linear (MLR), observando que o algoritmo de RF se mostrou superior ao MLR obtendo um R^2 variando entre 0,53 a 0,93 e 0,29 a 0,85, respectivamente. Silveira et al., (2019) em seu estudo utilizou a comparação do desempenho de modelo de regressão pelo RF para o mapeamento de AGB de diferentes tipos de vegetação do estado e Minas Gerais utilizando modelos estratificados e não estratificados. Em seus resultados, a autora, encontrou 7 variáveis para o modelo não estratificado e 9 variáveis para o modelo estratificado, sendo os dois modelos tendo seu desempenho avaliados baseado em estatísticas do Erro Médio Absoluto (MAE, %), Erro Médio Quadrático da Raiz (RMSE, Mg/ha) e também através dos gráficos de resíduos, e pode constatar que o modelo estratificado minimizou o RMSE e o MAE para todos os tipos de vegetação, produzindo mapas mais confiáveis.

As estimativas de AGB para as áreas de estudo mostraram que o mapeamento foi subestimado para todas as fitofisionomias de todas as épocas do ano com exceção da Floresta Ombrófila. A biomassa total foi subestimada para os dois verões e o inverno e superestimado para Ao se observar o R^2 , seus valores mostram uma interação de moderada a baixa entre a

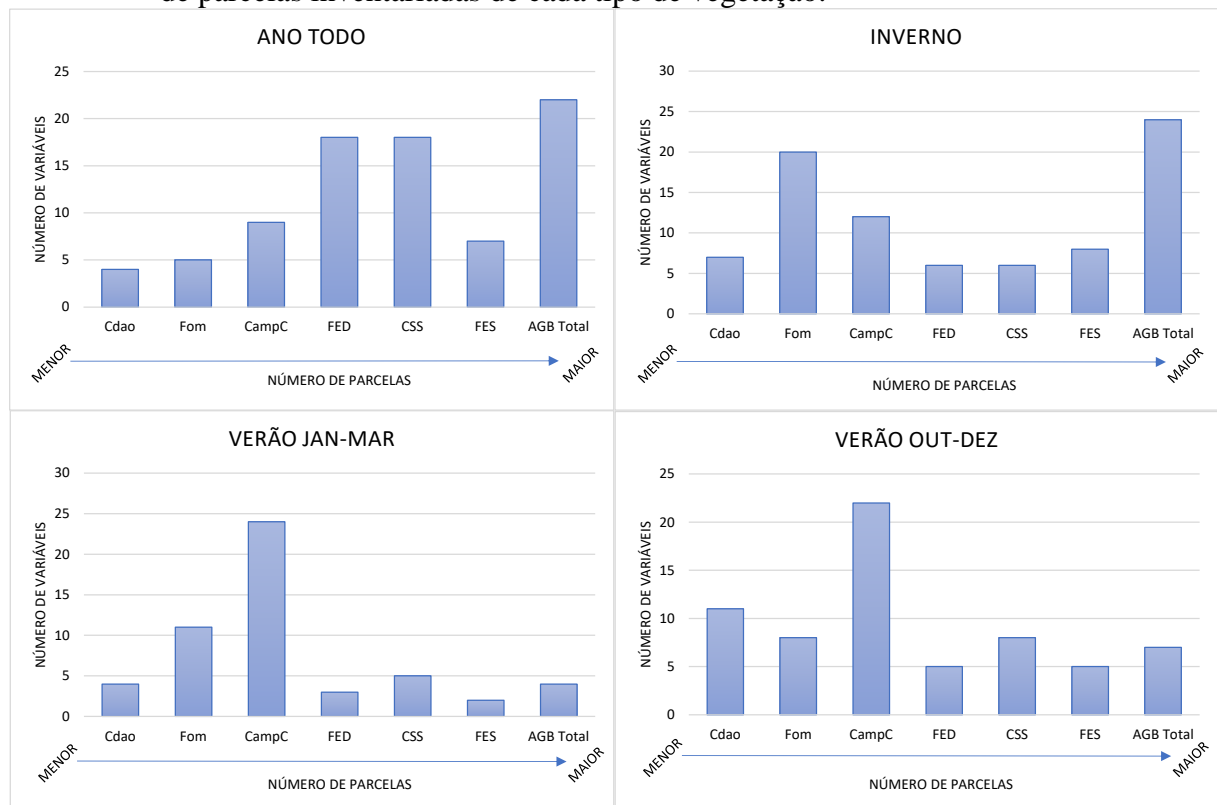
estimativa e as áreas de trabalho. Das áreas de trabalho analisadas, apenas 8 apresentaram R² entre 0,33 a 0,47. O restante ficando com valores inferiores.

A quantificação da biomassa pode ser afetada por diversos fatores ambientais, como precipitação, temperatura, relevo, tipo de solo, incidência de radiação solar. A combinação de um ou mais destes fatores afetam diretamente no desenvolvimento da vegetação, fazendo com que uma fitofisionomia se desenvolva mais que a outra e conseqüentemente apresente uma maior quantidade de biomassa.

A distribuição espacial de cada tipologia não afetou na seleção da quantidade das variáveis selecionadas, por exemplo, a Floresta Estacional Semidecidual que apresenta a maior distribuição espacial do estado apresentou 7 variáveis selecionadas, enquanto que para Floresta Ombrófila que apresenta a menor distribuição espacial foi representada por 5 variáveis para o ano todo de 2007. O mesmo pode ser observado quando se trata das estações do ano.

Em relação a quantidade de parcelas inventariadas pode-se ver uma correlação sobre o aumento de quantidade de variáveis selecionadas com quantidade de parcelas inventariadas, para o ano de 2007 inteiro. Já nas estações do ano este processo não se aplica.

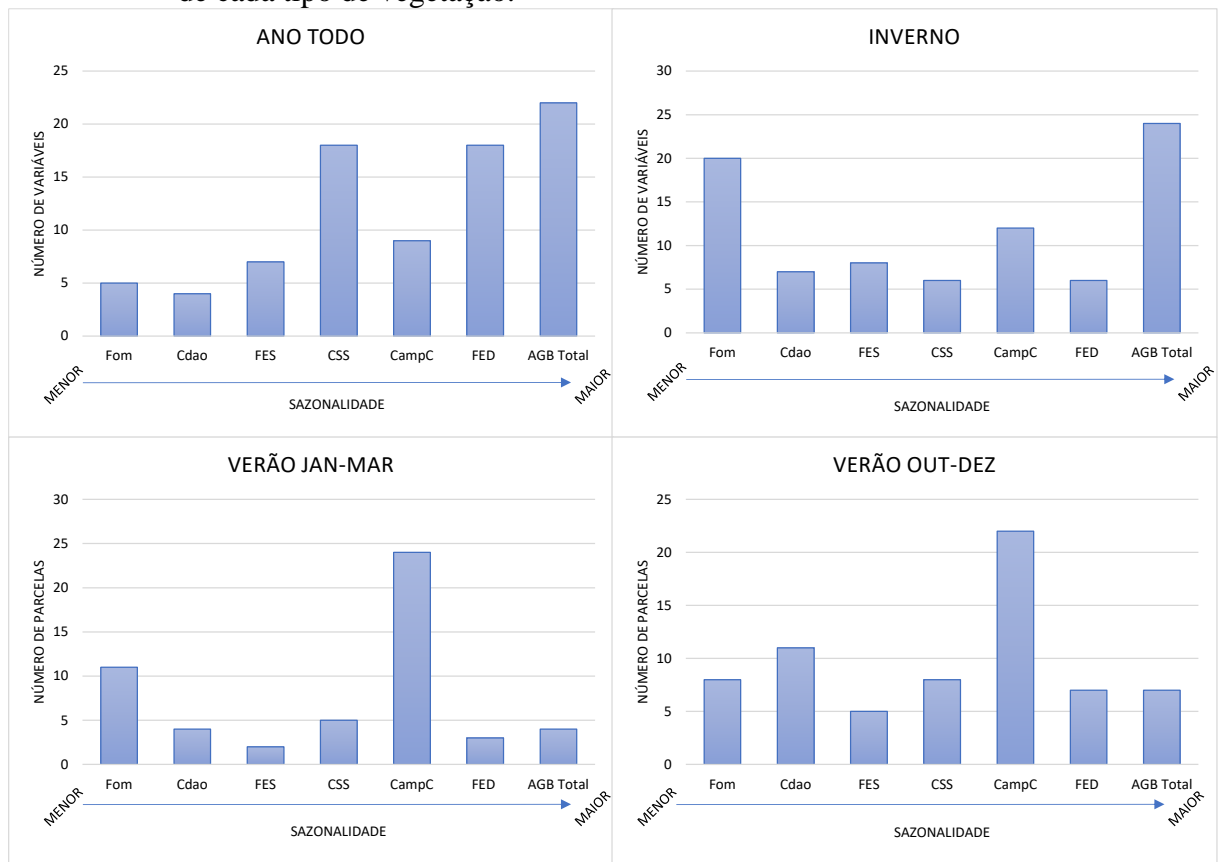
Gráfico 9 - Número de variáveis selecionadas para modelar o AGB em função da quantidade de parcelas inventariadas de cada tipo de vegetação.



Fonte: Do autor (2021).

Em relação a sazonalidade, para o ano todo de 2007 houve uma correlação de fitofisionomias mais sazonais, como ao Cerrado Censo Stricto e a Floresta Estacional Decidual apresentarem mais variáveis representativas e tipologias menos sazonais, como Floresta Ombrófila e Cerradão apresentarem menos variáveis selecionadas (gráfico 10). Informações sobre a fenologia explicam as diferenças entre as formações vegetais, podendo assim, ser fundamentais para modelar e mapear sua distribuição espacial (Schwieder et al., 2016).

Gráfico 10 – Número de variáveis selecionadas para modelar AGB em função da sazonalidade de cada tipo de vegetação.



Fonte: Do autor (2021).

5 CONCLUSÃO

Este estudo analisou a capacidade dos índices de sensoriamento remoto na modelagem da biomassa acima do solo das fitofisionomias presentes no estado Minas Gerais.

Apesar da amostragem destrutiva ser o melhor método para a estimativa de biomassa, o seu uso se torna inviável devido aos altos custos, grande demanda de tempo quando se trata de áreas muito grandes e com diferentes tipos de vegetação. Com este projeto pode-se ver a importância do uso de sensoriamento remoto para auxiliar em tais estimativas.

Concluiu-se que os índices de sensoriamento remoto podem ser bons indicadores, uma vez que para algumas áreas de trabalho explicam, com valores moderados, a variabilidade da biomassa acima do solo das fitofisionomias no estado Minas Gerais. Contudo, para uma maior precisão nas estimativas recomenda-se combinar esses índices com dados auxiliares como dados de clima e dados do relevo da área de estudo, além de complementar com metodologias que possam contribuir para a redução de erros como a estratificação das áreas de trabalho.

REFERÊNCIA

ALVARES, Clayton Alcarde et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ASNER, Gregory P. et al. High-fidelity national carbon mapping for resource management and REDD+. **Carbon balance and management**, v. 8, n. 1, p. 1-14, 2013.

BACCINI, A. et al. A first map of tropical Africa's above-ground biomass derived from satellite imagery. **Environmental Research Letters**, v. 3, n. 4, p. 045011, 2008.

BARBOSA, Humberto Alves et al. Assessment of caatinga response to drought using meteosat-SEVIRI normalized difference vegetation index (2008–2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 148, p. 235-252, 2019.

BREIMAN, Leo. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

BROWN, Sandra. Measuring carbon in forests: current status and future challenges. **Environmental pollution**, v. 116, n. 3, p. 363-372, 2002.

CARVALHO, L. M. T. et al. Análises espaciais e estatísticas da flora nativa. In: CARVALHO, L. M. T.; SCOLFORO, J. R. (Ed.). **Inventário florestal de Minas Gerais: monitoramento da flora nativa 2005-2007**. Lavras: Ed. UFLA, 2008. cap. 2, p.25-316.

CHEN, Lin et al. Assessment of multi-wavelength SAR and multispectral instrument data for forest aboveground biomass mapping using random forest kriging. **Forest Ecology and Management**, v. 447, p. 12-25, 2019.

DA SILVA, José Maria Cardoso et al. Status of the biodiversity of the Atlantic Forest of Brazil. The Atlantic Forest of South America: Biodiversity Status, Threats, and Outlook. **CABS and Island Press**, Washington, p. 43-59, 2003.

DAVID, Hassan Camil et al. Carbon stock classification for tropical forests in Brazil: Understanding the effect of stand and climate variables. **Forest Ecology and Management**, v. 404, p. 241-250, 2017.

DE SOUZA, José João Lelis Leal et al. Geochemistry and spatial variability of metal (loid) concentrations in soils of the state of Minas Gerais, Brazil. **Science of The Total Environment**, v. 505, p. 338-349, 2015.

DENG, Songqiu et al. Estimating forest aboveground biomass by combining ALOS PALSAR and WorldView-2 data: A case study at Purple Mountain National Park, Nanjing, China. **Remote Sensing**, v. 6, n. 9, p. 7878-7910, 2014.

DRIGO, R.; LASSERRE, Bruno; MARCHETTI, Marco. Patterns and trends in tropical forest cover. **Plant Biosystems**, v. 143, n. 2, p. 311-327, 2009.

DU, Huaqiang et al. Satellite-based carbon stock estimation for bamboo forest with a non-linear partial least square regression technique. **International Journal of Remote Sensing**, v. 33, n. 6, p. 1917-1933, 2012.

FAYAD, Ibrahim et al. Aboveground biomass mapping in French Guiana by combining remote sensing, forest inventories and environmental data. **International journal of applied earth observation and geoinformation**, v. 52, p. 502-514, 2016.

FERNÁNDEZ-MANSO, Oscar; FERNÁNDEZ-MANSO, Alfonso; QUINTANO, C. Estimation of aboveground biomass in Mediterranean forests by statistical modelling of ASTER fraction images. **International journal of applied earth observation and geoinformation**, v. 31, p. 45-56, 2014.

FOODY, Giles M.; BOYD, Doreen S.; CUTLER, Mark EJ. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote sensing of environment**, v. 85, n. 4, p. 463-474, 2003.

FAO. 2020. Global Forest Resources Assessment 2020 – Key findings. Rome. Disponível em <<https://doi.org/10.4060/ca8753en>>

FRANÇOSO, Renata D. et al. Habitat loss and the effectiveness of protected areas in the Cerrado Biodiversity Hotspot. **Natureza & Conservação**, v. 13, n. 1, p. 35-40, 2015.

FUCHS, Hans et al. Estimating aboveground carbon in a catchment of the Siberian forest tundra: Combining satellite imagery and field inventory. **Remote Sensing of Environment**, v. 113, n. 3, p. 518-531, 2009.

GALLAUN, Heinz et al. EU-wide maps of growing stock and above-ground biomass in forests based on remote sensing and field measurements. **Forest Ecology and Management**, v. 260, n. 3, p. 252-261, 2010.)

GIBBS, Holly K. et al. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, p. 045023, 2007.

GLEASON, Colin J.; IM, Jungho. Forest biomass estimation from airborne LiDAR data using machine learning approaches. **Remote Sensing of Environment**, v. 125, p. 80-91, 2012.

GOETZ, Scott J. et al. Mapping and monitoring carbon stocks with satellite observations: a comparison of methods. **Carbon balance and management**, v. 4, n. 1, p. 2, 2009.

GOWER, Stith T. Patterns and mechanisms of the forest carbon cycle. **Annual Review of Environment and Resources**, v. 28, n. 1, p. 169-204, 2003.

HALL, Forrest G. et al. Characterizing 3D vegetation structure from space: Mission requirements. **Remote Sensing of Environment**, v. 115, n. 11, p. 2753-2775, 2011.)

HE, Qi-Sheng et al. Forest stand biomass estimation using ALOS PALSAR data based on LiDAR-derived prior knowledge in the Qilian Mountain, western China. **International Journal of Remote Sensing**, v. 33, n. 3, p. 710-729, 2012.

HE, Qisheng et al. Above-ground biomass and biomass components estimation using LiDAR data in a coniferous forest. **Forests**, v. 4, n. 4, p. 984-1002, 2013.

HLATSHWAYO, Sizwe Thamsanqa et al. Mapping forest aboveground biomass in the reforested Buffelsdraai landfill site using texture combinations computed from SPOT-6 pan-sharpened imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 74, p. 65-77, 2019.

HOOVER, Coeli M. et al. Evaluation of alternative approaches for landscape-scale biomass estimation in a mixed-species northern forest. **Forest ecology and management**, v. 409, p. 552-563, 2018.

HOUGHTON, Richard A. et al. Annual fluxes of carbon from deforestation and regrowth in the Brazilian Amazon. **Nature**, v. 403, n. 6767, p. 301-304, 2000.

HOUGHTON, R. A.; HALL, Forrest; GOETZ, Scott J. Importance of biomass in the global carbon cycle. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. G2, 2009.

HU, Tianyu et al. Mapping global forest aboveground biomass with spaceborne LiDAR, optical imagery, and forest inventory data. **Remote Sensing**, v. 8, n. 7, p. 565, 2016.

HUSCH, B.; MILLER, C.I.; KERSHAW, J. Forest mensuration. 4. ed. **New Jersey: John Willey e Sons, Inc**, 2003. 443 p.

HYYPPÄ, J. et al. Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, v. 29, n. 5, p. 1339-1366, 2008.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Cidades e Estados: Minas Gerais. Disponível em: < <https://www.ibge.gov.br/cidades-e-estados/mg.html>>. Acesso em 20 maio 2020.

JARED, Carlos et al. Life history of frogs of the Brazilian semi-arid (Caatinga), with emphasis in aestivation. **Acta Zoologica**, 2019.

LIAO, Zhanmang; HE, Binbin; QUAN, Xingwen. Potential of texture from SAR tomographic images for forest aboveground biomass estimation. **International Journal of Applied Earth Observation and Geoinformation**, v. 88, p. 102049, 2020.

LIU, Yi Y. et al. Recent reversal in loss of global terrestrial biomass. **Nature Climate Change**, v. 5, n. 5, p. 470-474, 2015.

LEFSKY, Michael A. et al. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. **BioScience**, v. 52, n. 1, p. 19-30, 2002.

LU, Dengsheng. The potential and challenge of remote sensing-based biomass estimation. **International journal of remote sensing**, v. 27, n. 7, p. 1297-1328, 2006.

LU, Dengsheng 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, Jinbo et al. Estimation of aboveground biomass of Robinia pseudoacacia forest in the Yellow River Delta based on UAV and Backpack LiDAR point clouds. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, p. 102014, 2020.

MAGALHÃES, K. D. N. et al. Medicinal plants of the Caatinga, northeastern Brazil: Ethnopharmacopeia (1980-1990) of the late professor Francisco José de Abreu Matos. **Journal of ethnopharmacology**, v. 237, p. 314-353, 2019.

MATTSSON, Eskil et al. Heterogeneity and assessment uncertainties in forest characteristics and biomass carbon stocks: Important considerations for climate mitigation policies. **Land use policy**, v. 59, p. 84-94, 2016.

MCROBERTS, Ronald E.; TOMPPA, Erkki O. Remote sensing support for national forest inventories. **Remote sensing of environment**, v. 110, n. 4, p. 412-419, 2007.

MENESES, P. R.; DE ALMEIDA, T. Introdução Ao Processamento De Imagens De Sensoriamento Remoto. 1 ed. **UNB**. 2012. 266 p.

MORAIS, Vinícius Augusto et al. Spatial distribution of soil carbon stocks in the Cerrado biome of Minas Gerais, Brazil. **Catena**, v. 185, p. 104285, 2020.

MUUKKONEN, Petteri; HEISKANEN, Janne. Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories. **Remote Sensing of Environment**, v. 107, n. 4, p. 617-624, 2007.

MYERS, Norman et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853, 2000.

NÆSSET, Erik; GOBAKKEN, Terje. Estimation of above-and below-ground biomass across regions of the boreal forest zone using airborne laser. **Remote Sensing of Environment**, v. 112, n. 6, p. 3079-3090, 2008

OLIVEIRA-FILHO, Ary T.; FONTES, Marco Aurélio L. Patterns of floristic differentiation among Atlantic Forests in Southeastern Brazil and the influence of climate 1. **Biotropica**, v. 32, n. 4b, p. 793-810, 2000.

PEREIRA, Marcos Paulo Santos et al. Brazilian Dry Forest (Caatinga) Response To Multiple ENSO: the role of Atlantic and Pacific Ocean. **Science of The Total Environment**, v. 705, p. 135717, 2020.

PFLUGMACHER, Dirk et al. Using Landsat-derived disturbance and recovery history and lidar to map forest biomass dynamics. **Remote Sensing of Environment**, v. 151, p. 124-137, 2014.

POPESCU, Sorin C. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646-655, 2007.

PRADO, Darién E. As caatingas da América do Sul. **Ecologia e conservação da Caatinga**, v. 2, p. 3-74, 2003.

RIBEIRO, Milton Cezar et al. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? **Implications for conservation. Biological conservation**, v. 142, n. 6, p. 1141-1153, 2009.

RODRÍGUEZ-VEIGA, Pedro et al. Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. **Remote Sensing of Environment**, v. 183, p. 265-281, 2016

RYLANDS, Anthony B.; BRANDON, Katrina. **Brazilian protected areas. Conservation biology**, v. 19, n. 3, p. 612-618, 2005.

SALATINO, Antonio et al. Fingerprinting of cerrado species based on cork lipophilic constituents. **Biochemical Systematics and Ecology**, v. 88, p. 103989, 2020.

SANO, Edson E. et al. Cerrado ecoregions: A spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. **Journal of environmental management**, v. 232, p. 818-828, 2019.

SCHWIEDER, Marcel et al. Mapping Brazilian savanna vegetation gradients with Landsat time series. **International journal of applied earth observation and geoinformation**, v. 52, p. 361-370, 2016.

SCOLFORO, J. R. et al. Amostragem e coleta de dados para equações de volume, peso de matéria seca, tanino, cortiça, óleo, sistema radicular, conversão de volumes e carbono. In: SCOLFORO, J. R.; OLIVEIRA, A. D.; ACERBI JÚNIOR, F. W. (Ed.). Inventário florestal de Minas Gerais – Equações de Volume, Peso de Matéria Seca e Carbono para Diferentes Fisionomias da Flora Nativa. Lavras: Ed. **UFLA**, 2008. cap. 1, p.1-65.

SCOLFORO, Henrique Ferraco et al. Spatial distribution of aboveground carbon stock of the arboreal vegetation in Brazilian biomes of Savanna, Atlantic Forest and Semi-Arid Woodland. **PLoS One**, v. 10, n. 6, 2015.

SCOLFORO, Henrique Ferraco et al. Spatial interpolators for improving the mapping of carbon stock of the arboreal vegetation in Brazilian biomes of Atlantic forest and Savanna. **Forest Ecology and Management**, v. 376, p. 24-35, 2016.

SILVEIRA, Eduarda MO et al. Pre-stratified modelling plus residuals kriging reduces the uncertainty of aboveground biomass estimation and spatial distribution in heterogeneous savannas and forest environments. **Forest Ecology and Management**, v. 445, p. 96-109, 2019.

SILVEIRA, Eduarda Martiniano de Oliveira et al. Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, p. 1-18, 2019.

SOARES, C. P B.; PAULA NETO, F.; SOUZA, A. L. Dendrometria e Inventário Florestal. 2. Ed. **Editora UFV**. 2011. 272 p.

SONG, Conghe. Optical remote sensing of forest leaf area index and biomass. **Progress in Physical Geography**, v. 37, n. 1, p. 98-113, 2013.)

THURNER, Martin et al. Carbon stock and density of northern boreal and temperate forests. **Global Ecology and Biogeography**, v. 23, n. 3, p. 297-310, 2014.

TSUI, Olivier W. et al. Using multi-frequency radar and discrete-return LiDAR measurements to estimate above-ground biomass and biomass components in a coastal temperate forest. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 69, p. 121-133, 2012.

VAN PHAM, Manh et al. Integrating Sentinel-1A SAR data and GIS to estimate aboveground biomass and carbon accumulation for tropical forest types in Thuan Chau district, Vietnam. **Remote Sensing Applications: Society and Environment**, v. 14, p. 148-157, 2019.

XIE, Yichun; SHA, Zongyao; YU, Mei. Remote sensing imagery in vegetation mapping: a review. **Journal of plant ecology**, v. 1, n. 1, p. 9-23, 2008

YAN, Feng; WU, Bo; WANG, Yanjiao. Estimating spatiotemporal patterns of aboveground biomass using Landsat TM and MODIS images in the Mu Us Sandy Land, China. **Agricultural and forest meteorology**, v. 200, p. 119-128, 2015.

ZHANG, Yue et al. Estimating the maize biomass by crop height and narrowband vegetation indices derived from UAV-based hyperspectral images. **Ecological Indicators**, v. 129, p. 107985, 2021.

ZHAO, Kaiguang; POPESCU, Sorin; NELSON, Ross. Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, v. 113, n. 1, p. 182-196, 2009.

ZHENG, Daolan et al. Carbon changes in conterminous US forests associated with growth and major disturbances: 1992–2001. **Environmental Research Letters**, v. 6, n. 1, p. 014012, 2011.

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.