



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

**ESTIMATIVA E MODELAGEM DA BIOMASSA
FLORESTAL ACIMA DO SOLO A PARTIR DO USO
DO SENSORIAMENTO REMOTO: 20 ANOS DE
MONITORAMENTO DA VEGETAÇÃO**

Natália Oliveira Ramos

Orientador: Dr. José Roberto Rodrigues Pinto

**Brasília
Distrito Federal – Brasil
Fevereiro de 2020**

Dedico este trabalho a Deus, criador dos céus, da terra e de toda a ciência. Detentor de todas as respostas que investigamos. Meu socorro, refúgio e consolo para os dias bons e maus. Nenhuma oportunidade eu teria se do céu ela não me fosse concedida.

Aos meus pais, Ancelmo e Sandra, por todo esforço e sacrifício para que eu chegasse até aqui e por terem escolhido trilhar o caminho acadêmico comigo.

Aos professores e orientadores de toda minha vida acadêmica, por todo apoio, paciência e conhecimento compartilhado. Eu não poderia ter feito esse trabalho se vocês não tivessem se dedicado ao ensino e a me apresentar o caminho por onde eu deveria andar.

Ao meu noivo, Pedro, por toda a paciência, amor e gentileza demonstrados nos dias bons e maus. Por ser um grande amigo e parceiro de estudos, por ser a pessoa que me acalmou e orou comigo durante os momentos de ansiedade e preocupação.

As minhas amigas mais chegadas que irmãs, Gabrielle e Talita, por todas as palavras ditas nos momentos certos, pelas orações e pela presença de vocês na minha vida pessoal e acadêmica.

Aos meus amigos, por todas as palavras de motivação, consolo e bondade. Por toda a preocupação demonstrada por mim e pelas incessantes orações semanais por este trabalho.

A todos os pesquisadores que se dedicaram na construção do conhecimento.

“Tudo fez Deus formoso no seu devido tempo; também pôs a eternidade no coração do homem, sem que este possa descobrir as obras que Deus fez desde o princípio até ao fim.”

(Eclesiastes 3.11)

“Uma resposta aproximada para o problema certo vale muito mais do que uma resposta exata para um problema aproximado.”

(John Wilder Tukey)

“Essencialmente, todos os modelos estão errados, mas alguns são úteis”

(George E. P. Box)

AGRADECIMENTOS

A Deus pela oportunidade de realizar e aprender com esse trabalho, pelas experiências vividas e pelo cuidado com minha vida.

Aos meus pais Ancelmo e Sandra que apoiaram toda minha trajetória acadêmica.

Ao meu noivo Pedro, pelo carinho, apoio, paciência e cuidado. Obrigada por ser sempre tão gentil, paciente e amoroso e por sempre orar por mim e comigo durante os momentos difíceis.

Ao meu orientador José Roberto Rodrigues Pinto pela oportunidade de trabalhar com os dados da Floresta de Vale do Véu de Noiva, pela orientação tão dedicada e cuidadosa e pela sua paciência e disposição em ensinar. Agradeço a Deus por ter tido um orientador tão maravilhoso. Você é ótimo, Zé!

Aos colegas de campo Milton, Glendo, Santiago e André e aos demais colaboradores na coleta de dados ao longo dos 20 anos de monitoramento da Floresta de Vale do Véu de Noiva.

Aos professores Eraldo, Eder, Samuel e Rômulo pelo apoio no desenvolvimento desse trabalho e pela disposição e paciência que demonstraram em ajudar. Agradeço também aos funcionários do Departamento de Engenharia Florestal da UnB que sempre se mostraram dispostos a auxiliar no que fosse necessário.

Aos membros da banca Antônio Felipe, Eraldo e Tati por todas as considerações e contribuições valiosas feitas.

Aos colegas de Cuiabá que me acolheram durante minha viagem para análise dos dados.

Aos meus amigos e amigas que me apoiaram e acreditaram em mim durante toda minha jornada acadêmica. Obrigada pelas palavras de consolo, cuidado e pelas orações.

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

RESUMO

Diante do importante papel das florestas no contexto de mudanças climáticas globais, estudos que permitam a modelagem da biomassa florestal (BF) na superfície terrestre e o seu monitoramento ao longo do tempo se tornaram imprescindíveis para prever o futuro das florestas e os serviços ecossistêmicos por elas oferecidos. A estimativa da BF pode ser feita através de métodos que utilizam dados de campo, conhecidos como métodos diretos, e através de métodos indiretos, que quantificam a BF a partir de variáveis relacionadas à produção florestal. Os dados provenientes de sensores remotos (SR) são apontados como ferramentas alternativas à estimativa *in locu* da BF em função de sua relação com a atividade fotossintética da vegetação. Dessa forma, o uso de dados do SR na modelagem faz parte dos métodos indiretos para estimativa da BF. Entretanto, a avaliação da precisão dos modelos e sua aplicação para análises multitemporais é um dos desafios atuais. Nesse contexto, o objetivo do presente estudo foi avaliar a utilização de variáveis derivadas de dados de SR na estimativa e monitoramento da BF acima do solo. O estudo foi conduzido em uma floresta de vale, localizada na transição Cerrado-Amazônia. Para isso, foram ajustados modelos de regressão e redes neurais artificiais (RNAs) que relacionaram índices de vegetação (IV) e reflectâncias (RE) com a BF obtida a partir de dados de 20 anos de monitoramento da vegetação. Apesar da relação entre os IV e RE, ambas as variáveis foram testadas, pois nem todas as RE estão presentes no cálculo dos IV. A BF apresentou coeficiente de variação elevado (>48%) para todos os períodos de análise. Foi observado que os IV apresentam potencial para estimar a BF através de modelos de regressão, todavia, com baixa precisão, apresentando erro relativo de 45,38%. As RNAs, por sua vez, apresentaram maior precisão, com erro relativo de 23,60%, que está relacionado ao fato das RNAs explorarem relações entre a BF e os dados de SR que a regressão não é capaz. Além disto, as variáveis de SR podem não ser sensíveis às variações no estoque espacial e anual de BF, o que prejudicou a qualidade dos ajustes. Dessa forma, as variáveis derivadas de SR possuem potencial para estimar e monitorar a BF, entretanto, diferentes métodos devem ser testados a fim de explorar com maior acurácia a relação entre essas variáveis, com especial atenção às Redes Neurais Artificiais.

ABSTRACT

In view of the important role of forests in the context of global climate change, studies that allow the modeling of forest biomass (FB) on the Earth's surface and its monitoring over time have become essential to predict the future of forests and ecosystem services by them offered. The estimation of FB can be done through methods that use field data, known as direct methods, and through indirect methods, which quantify FB from variables related to forest production. The data from remote sensors (RS) are pointed out as alternative tools to the FB *in locu* estimation due to their relationship with the photosynthetic vegetation activity. Thus, the use of SR data in modeling is part of the indirect methods for estimating FB. However, assessing the accuracy of the models and their application for multitemporal analysis is one of the current challenges. In this context, the objective of the present study was to evaluate the use of variables derived from RS data in the estimation and monitoring of FB above ground. The study was conducted in a valley forest, located in the Cerrado-Amazon transition. For that, regression models and artificial neural networks (ANNs) were adjusted, which related vegetation indexes (IV) and reflectances (RE) with the FB obtained from data from 20 years of vegetation monitoring. Despite the relationship between IV and RE, both variables were tested, as not all RE are present in the calculation of IV. The FB presented a high coefficient of variation (> 48%) for all periods of analysis. It was observed that the IVs have the potential to estimate FB through regression models, however, with low precision, presenting a relative error of 45.38%. The ANNs, in turn, were more accurate, with a relative error of 23.60%, which is related to the fact that the ANNs explore relationships between FB and RS data that the regression is not capable of. In addition, the RS variables may not be sensitive to variations in the spatial and annual BF stock, which impaired the quality of the adjustments. Thus, the variables derived from RS have the potential to estimate and monitor FB, however, different methods must be tested in order to more accurately explore the relationship between these variables, with special attention to Artificial Neural Networks.

Sumário

Introdução	9
Objetivo Geral	11
Objetivos Específicos	11
Referencial Teórico	12
Biomassa florestal	12
Dados de sensoriamento remoto e sua relação com a biomassa florestal	13
Hipótese	19
Material e Métodos	20
Área de estudo	20
Amostragem em campo da vegetação	22
Estimativa da biomassa florestal acima do solo	23
Densidade básica da madeira	23
Reflectância e Índices de vegetação	24
Análise anual da biomassa florestal	27
Análise temporal da biomassa florestal	28
Análise temporal da biomassa florestal a partir de Redes Neurais Artificiais (RNA)	29
Resultados	30
Biomassa florestal	30
Estimativa anual da biomassa florestal	32
Estimativa temporal da biomassa florestal	37
Estimativa temporal da biomassa florestal a partir de Redes Neurais Artificiais	39
Discussão	40
Conclusões	43
Referências bibliográficas	44

Lista de Tabelas

Tabela 1. Características das cenas utilizadas para obtenção dos dados de reflectância da vegetação lenhosa para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	26
Tabela 2. Índices de vegetação calculados para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	27
Tabela 3. Modelos utilizados nos ajustes da biomassa florestal acima do solo para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	28
Tabela 4. Média da biomassa florestal acima do solo, menor valor de biomassa, maior valor de biomassa, coeficiente de variação (CV) e desvio padrão (DP) da biomassa florestal da Floresta de Vale do Véu de Noiva, localizada no Parque Nacional da Chapada dos Guimarães - MT, Brasil.	31
Tabela 5. Correlação entre a biomassa florestal e variáveis derivadas do Landsat para os anos de medição registrados na Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil. As três maiores correlações para cada período em negrito.	33
Tabela 6. Estatística de ajuste e precisão: erro absoluto (S), erro relativo (S%), coeficiente de correlação (R) para modelos lineares e não lineares obtidos a partir da utilização dos índices de vegetação SR e EVI, como preditores para a estimativa da biomassa florestal em diferentes períodos, amostrados na Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	35
Tabela 7. Atributos e precisão das redes neurais artificiais treinadas para estimar a biomassa florestal da Floresta de Vale do Véu de Noiva - Parque Nacional da Chapada dos Guimarães - MT, Brasil.	39

Lista de figuras

Figura 1. Localização da Floresta de Vale do Véu de Noiva (FVVN), Parque Nacional da Chapada dos Guimarães, em relação ao estado de Mato Grosso, Brasil. Com destaque para a distribuição das parcelas (600 m ²) na FVVN. Fonte: Esri, DigitalGlobe, GeoEye, Earthstar Geographics, CNES / Airbus DS, USDA, USGS, AEX, Getmapping, Aerogrid, IGN, IGP, swisstopo e a Comunidade de usuários do GIS. Vista frontal do vale da Floresta de Vale do Véu de Noiva.....	21
Figura 2. Cenas do satélite Landsat 5 TM para estação seca (esquerda) e chuvosa (direita) da Floresta de Vale do Véu de Noiva – Parque Nacional da Chapada dos Guimarães – MT, Brasil, onde as parcelas com fogo encontram-se na cor vermelha e as parcelas sem fogo na cor verde.	24
Figura 3. Cenas do satélite Landsat 5 TM (2006 e 2010) e Landsat 8 OLI (2016) para estação seca (esquerda) e chuvosa (direita) da Floresta de Vale do Véu de Noiva – Parque Nacional da Chapada dos Guimarães – MT, Brasil, onde as parcelas com fogo encontram-se na cor vermelha e as parcelas sem fogo na cor verde.....	25
Figura 4. Comportamento da biomassa florestal acima do solo em parcelas com incêndio (linha vermelha), sem incêndio (linha verde) e em todas as parcelas (linha cinza) amostradas na Floresta de Vale do Véu de Noiva, Chapada dos Guimarães - MT, Brasil.	31
Figura 5. Comportamento dos índices de vegetação obtidos na estação seca (linhas) em relação as mudanças da biomassa florestal média (Mg.ha ⁻¹) (barras) , registrado na Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	34
Figura 6. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) das estimativas geradas pelos modelos e relação entre os valores observados e estimados da BF, utilizando o SR no modelo exponencial (A, C, D, E, e F) e no modelo polinomial (B).	36
Figura 7. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) do ajuste do modelo temporal linear múltiplo para estimar a biomassa florestal acima do solo, usando como variáveis preditoras o ano e as variáveis derivadas de sensores remotos: SWIR1, EVI, NDDI e NDWI, para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	38
Figura 8. Valores observados da biomassa florestal acima do solo em relação a biomassa estimada pelo ajuste do modelo temporal linear múltiplo, tendo como variáveis preditoras o ano de medição e as variáveis derivados de sensores remotos: SWIR1, EVI, NDDI e NDWI, para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.	38
Figura 9. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) da RNA3 a partir do ano de medição e das variáveis derivadas de sensores remotos: SWIR1, EVI, NDDI e NDWI e valores observados e estimados para biomassa florestal da Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.....	39

Introdução

Entender a distribuição e a dinâmica florestal por meio de investigações das variações espaciais e temporais pode ajudar a compreender a relação entre o comportamento da vegetação e as mudanças nas condições ambientais (JOHNSON et al., 2016), bem como a contribuição das florestas no ciclo global do carbono (BARBOSA; BROADBENT; BITENCOURT, 2014; GRACE, 2004; LU, 2006). A análise da distribuição espacial da biomassa florestal é importante para avaliar a contribuição das florestas enquanto fonte e sumidouro de carbono, compreender os efeitos das mudanças climáticas globais na estrutura e composição da vegetação e subsidiar as ações de conservação e manejo florestal (BRIENEN et al., 2015; PAN et al., 2013). Para isso, são necessários estudos de monitoramento da vegetação que analisem a dinâmica da fixação de carbono pelas florestas ao longo do tempo (PAN et al., 2013).

Uma das formas de quantificar a contribuição das florestas no ciclo do carbono é através da avaliação de sua biomassa (BRIENEN et al., 2015). A estimativa da biomassa vegetal pode ser determinada através de métodos diretos e indiretos (FEARNSIDE, 1997; SANQUETTA, 2002; SOARES; TOMÉ, 2004). Nos métodos diretos ela é determinada de forma destrutiva, já os indiretos fazem uso de equações alométricas associadas às variáveis de campo como altura, diâmetro e densidade da madeira (FEARNSIDE, 1997; SANQUETTA, 2002; SANQUETTA et al., 2014).

Mesmo adotando métodos indiretos a estimativa da biomassa vegetal é bastante dispendiosa, pois para os ajustes dos modelos alométricos são necessários dados de campo que, via de regra, tem sua coleta como uma atividade onerosa (BROWN; LUGO, 1984; HIGUCHI et al., 1998; ROITMAN et al., 2018). Portanto, são necessários métodos que relacionem essa variável à variáveis de menor custo de obtenção, que permitam sua estimativa em maior escala espacial, bem como seu monitoramento ao longo do tempo (BARBOSA; BROADBENT; BITENCOURT, 2014; BUSTAMANTE et al., 2016; ROITMAN et al., 2018), como por exemplo as variáveis derivadas de sensores remotos.

O sensoriamento remoto possui grande potencial de baixo custo para monitoramento de ecossistemas em áreas extensas (HANSEN et al., 2013; LEITÃO et al., 2018) e de difícil acesso (NOVO; PONZONI, 2001). Os dados obtidos através de sensores à bordo de satélites podem ser uma alternativa viável para o estudo da biomassa florestal, pois estão associados à parâmetros biofísicos da vegetação (HANSEN et al., 2013; LI et al., 2019; PONZONI; SHIMABUKURO; KUPLICH, 2007; ROY; RAVAN, 1996). A reflectância, ou seja, a radiação

refletida pela vegetação que é captada pelos sensores é resultado da razão entre a radiação que foi absorvida pela vegetação e a que foi refletida de volta para a atmosfera (MENESES, P.R., ALMEIDA, T, BAPTISTA, 2019; PONZONI; SHIMABUKURO; KUPLICH, 2007). Dessa forma, a reflectância da vegetação permite, de forma indireta, quantificar a variação espacial da biomassa florestal.

A utilização dos dados advindos de sensores remotos na quantificação da biomassa florestal por meio de modelos matemáticos permite estimar a sua distribuição em escala espacial maior do que a possibilitada pelos dados de campo, resultando em extrapolação da superfície de distribuição da biomassa para uma região (CASSOL; SALDANHA; KUPLICH, 2013; LI et al., 2019; PROPASTIN, 2013; ZHU; LIU, 2015). Entretanto, a precisão dos modelos é influenciada pela utilização de dados de campo, o que limita a modelagem à locais específicos da superfície terrestre. Neste caso, avaliação da precisão desses modelos e sua aplicação para análises multitemporais da biomassa é um dos principais desafios atuais para monitoramento da biomassa através do sensoriamento remoto. Afinal, a maioria dos estudos é feito para um período de tempo específico, pois na maioria dos casos são escassos os dados de monitoramento da biomassa à nível local (BARBOSA; BROADBENT; BITENCOURT, 2014).

A ausência de dados de campo é uma das principais causas de variações, para uma mesma área, nas estimativas do estoque de carbono a partir de modelos matemáticos (HOUGHTON, 2005). Adicionalmente, o enfoque apenas no sensoriamento remoto pode deixar de identificar padrões ecológicos críticos da floresta (BARBOSA et al., 2014). Portanto, é necessário relacionar esses dados derivados de sensores remotos com os dados de campo a fim de obter modelos mais próximos da realidade e que não estejam limitados apenas a área de abrangência dos dados de campo. Uma possibilidade de se melhorar a acurácia das estimativas a partir do sensoriamento remoto é avaliar o ajuste de diferentes modelos matemáticos e variáveis predictoras que superem essas limitações na estimativa da biomassa (BARBOSA; BROADBENT; BITENCOURT, 2014; CASSOL; SALDANHA; KUPLICH, 2013).

Os dados derivados de sensores remotos mais utilizados na estimativa da biomassa florestal são a reflectância e os índices de vegetação (FERRAZ et al., 2014; HUETE, 1988; LU, 2006; SARMIENTO; PINILLOS; GARAY, 2005). Entre os índices de vegetação os mais empregados são o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) e o Índice de Realce da Vegetação (*Enhanced Vegetation Index* - EVI) em função de sua relação com a atividade fotossintética da vegetação (GARROUTTE;

HANSEN; LAWRENCE, 2016; GIZACHEW et al., 2016; ZHU; LIU, 2015). Sendo que, em geral, os satélites mais utilizados são os do programa Landsat e MODIS, em função da facilidade de obtenção dos dados e maior cobertura temporal e espacial (ZHENG et al., 2004; ZHU; LIU, 2015).

Diante do cenário apresentado até aqui, a Floresta de Vale do Véu de Noiva, localizada no Parque Nacional da Chapada dos Guimarães – Mato Grosso, surge como uma oportunidade para se avaliar a estimativa da biomassa nas florestas tropicais por meio de dados de sensores remotos associados a dados de campo. Esta floresta está inserida na região de transição Cerrado-Amazônia (ICMBIO, 2009) e vem sendo monitorada desde 1996. Usando os dados de monitoramento da vegetação obtidos em campo e dados de sensores remotos foi investigada a seguinte questão:

1. Qual a relação entre a variação espacial e temporal da biomassa florestal acima do solo, calculada a partir dos dados de campo, e a atividade fotossintética da vegetação representada pelos índices de vegetação e valores de reflectância oriundos de sensores remotos?

Objetivo Geral

Avaliar a relação entre a biomassa florestal acima do solo obtida a partir de dados de campo, índices de vegetação e reflectâncias oriundos de sensores remotos.

Objetivos Específicos

- 1) Estimar a biomassa florestal acima do solo para a Floresta de Vale do Véu de Noiva, no período de 20 anos, a partir de seis inventários de campo (1996, 1999, 2003, 2006, 2010 e 2016);
- 2) Estimar as variáveis derivadas de sensores remotos (valores de reflectância e índices de vegetação) para o mesmo período de 20 anos de monitoramento da Floresta de Vale do Véu de Noiva;
- 3) Estimar a biomassa florestal acima do solo por meio de modelos de regressão e redes neurais artificiais relacionando dados obtidos em campo com índices de vegetação e reflectâncias derivadas de sensores remotos.

Referencial Teórico

Biomassa florestal

As emissões de gás carbônico (CO₂) aumentaram desde meados do século XVII, como consequência da industrialização e das mudanças no uso e cobertura do solo (IPCC, 2014). A emissão de CO₂ somada a emissão de outros gases poluentes na atmosfera tem como consequência o chamado “efeito estufa” que ocasiona o aumento da temperatura global (IPCC, 2007). Neste contexto de mudanças climáticas globais, as florestas são apontadas como importantes mitigadoras do efeito estufa enquanto fontes de sumidouros de carbono devido à sua capacidade em fixar carbono atmosférico na forma de biomassa através do processo de fotossíntese, contendo cerca de 25% do carbono da biosfera terrestre (BONAN, 2008; FEARNSTIDE, 2006; PAN et al., 2013).

A biomassa florestal (BF) é uma propriedade complexa que integra processos funcionais e atributos estruturais da floresta, ligando área basal, altura, densidade da madeira e produtividade (CHAVE et al., 2005, 2014; PAN et al., 2013; RÉJOU-MÉCHAIN et al., 2017). A BF é resultado do equilíbrio, à longo prazo, entre o crescimento da floresta, que é consequência do aumento da área basal, e a mortalidade, que resulta em uma perda de madeira (PAN et al., 2013).

As mudanças no estoque de BF são fundamentais para compreender o balanço de carbono nas florestas (BACCINI et al., 2012; PAN et al., 2013). Dessa forma, são necessários estudos de monitoramento (BRIENEN et al., 2015). Além disso, compreender a distribuição da biomassa ao longo do tempo e do espaço é fundamental para avaliar os impactos dos processos de conversão e uso do solo e os impactos do efeito das mudanças climáticas, pois ambos alteram o papel das florestas no ciclo global do carbono (BRIENEN et al., 2015; BUSTAMANTE et al., 2016).

Existem poucos estudos voltados para a quantificação da BF nas formações florestais do bioma Cerrado, o que é prejudicial para a compreensão do seu papel na fixação de carbono no contexto das mudanças climáticas globais (ROQUETTE, 2018). As formações florestais correspondem a 20,54% do bioma Cerrado (BRASIL, 2015). Provavelmente a dificuldade de se obter dados confiáveis sobre a BF está no fato de que muitas vezes essas estimativas exigem o abate e pesagem de indivíduos, o que inviabiliza seu estudo em áreas de proteção integral, áreas extensas e áreas de difícil acesso (HIGUCHI et al., 1994; SOMOGYI et al., 2007).

As variáveis de campo que mais se relacionam com a BF são: área basal e densidade da madeira (BRIENEN et al., 2015; SOMOGYI et al., 2007). Além de serem usadas nos cálculos para obtenção direta da BF, essas variáveis também são utilizadas como estimadores em modelos matemáticos para estimar a BF de forma indireta (CHAVE et al., 2014; MIGUEL et al., 2015; SANQUETTA, 2002). Todavia, as equações resultantes dessa estimativa limitam a predição da BF ao local de coleta dos dados (BARBOSA; BROADBENT; BITENCOURT, 2014). Portanto, são necessários estudos que possibilitem a extrapolação da estimativa da BF com certo grau de precisão para áreas maiores (LEITÃO et al., 2018; LI et al., 2019).

Ainda existem muitas incertezas nas extrapolações da BF das regiões tropicais. Os mapas atuais da BF para a floresta Amazônica, por exemplo, possuem variação substancial na biomassa total e em sua distribuição espacial (OMETTO et al., 2014). Como as estimativas das emissões de carbono do desmatamento são altamente dependentes da distribuição espacial da BF (BACCINI et al., 2012), gerar mapas de distribuição da biomassa com incertezas são prejudiciais para prever as emissões de carbono (OMETTO et al., 2014). Ademais, as respostas da floresta à perturbação dependem do tipo, frequência, intensidade e extensão da perturbação e das características intrínsecas do local, como clima, solo, topografia, ocorrência de fogo, composição de espécies e interações (BUSTAMANTE et al., 2016; SILVA et al., 2018). Além disso, os mapas de distribuição da BF, em sua maioria, não consideram suas mudanças ao longo do tempo (OMETTO et al., 2014).

Dados de sensoriamento remoto e sua relação com a biomassa florestal

O sensoriamento remoto é a área do conhecimento que envolve a utilização de tecnologias para a obtenção de imagens da superfície terrestre através da detecção e medição quantitativa da interação entre a radiação eletromagnética com os alvos terrestres (JENSEN, 2009). O resultado da interação do espectro eletromagnético com os alvos presentes na superfície ao longo de suas faixas espectrais é conhecido como reflectância (NOVO, 2008). No caso da vegetação, esta 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; SHIMABUKURO; KUPLICH, 2007).

A reflectância resultante da interação entre a radiação e a vegetação é dependente da estrutura da vegetação, onde a radiação eletromagnética interage com os pigmentos presentes nos cloroplastos das folhas, com seu conteúdo de água e com sua estrutura foliar (GATES et al., 1965). Assim, o resultado da interação da luz, em diferentes faixas do espectro

eletromagnético, com a vegetação captada pelos sensores reflete parâmetros biofísicos da vegetação que estão relacionados ao processo de fotossíntese (PONZONI; SHIMABUKURO; KUPLICH, 2007).

Dados espectrais derivados de sensores remotos são variáveis de grande interesse para análise das mudanças que ocorrem na superfície terrestre, principalmente para a avaliação da BF e do estoque de carbono (BACCINI et al., 2012; GOETZ et al., 2009; LI et al., 2019). As variáveis obtidas dos sensores são utilizadas em estudos que as relacionam com os dados obtidos em campo, por exemplo, com a biomassa vegetal acima do solo. Esses estudos são baseados na sensibilidade dos sensores para capturar variações estruturais da vegetação, principalmente no dossel da floresta, que são resultado da interação da luz com a vegetação (KUMAR et al., 2015; LI et al., 2019; MENESES, P.R., ALMEIDA, T, BAPTISTA, 2019; PONZONI; SHIMABUKURO; KUPLICH, 2007).

Os índices de vegetação e as razões de bandas derivadas de dados ópticos são usados para quantificar a BF a partir da associação entre os valores do índice de vegetação ou os valores de razão de banda com as estimativas obtidas de campo (CASSOL; SALDANHA; KUPLICH, 2013; FERRAZ et al., 2014; KUMAR et al., 2015; MIGUEL et al., 2015). Dentre as variáveis obtidas a partir do sensoriamento remoto, os índices de vegetação são os mais utilizados na estimativa da BF.

O SR (*Simple Ratio*) é apontado como o primeiro índice de vegetação verdadeiro (JENSEN, 2009). Ele é calculado a partir da razão entre a reflectância no infravermelho próximo e da reflectância do vermelho (BIRTH; MCVEY, 1968). Porém, o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) e o Índice de Realce da Vegetação (*Enhanced Vegetation Index* - EVI) são os mais comuns (JENSEN, 2009).

O NDVI reflete o estado sadio da vegetação em função da sua estimativa envolver as bandas espectrais do vermelho e do infravermelho próximo (ROUSE et al., 1974). Já o EVI é uma aprimoração do NDVI para reduzir efeitos da atmosfera e do solo, sendo mais sensível a variações na estrutura do dossel (HONGJUN et al., 2007; HUETE et al., 2002). O SR é mais sensível que o NDVI para variações em regiões de alto acúmulo de biomassa por possuir intervalo dinâmico maior (JENSEN, 2009). Ao contrário do NDVI, que satura em regiões de alto acúmulo de biomassa, o valor do SR continua aumentando conjuntamente com o estágio da vegetação.

Outro índice usado na avaliação da vegetação é o Índice de Umidade por Diferença Normalizada (*Normalized Difference Moisture Index* – NDWI), também conhecido como Índice de Água (GAO, 1996). O NDWI é altamente correlacionado ao conteúdo de água do dossel vegetal e foi desenvolvido para estimar a condição de umidade da vegetação (GAO, 1996). Seu cálculo envolve a refletância das bandas do infravermelho próximo e infravermelho de ondas curtas, tornando este índice sensível para monitorar o estresse causado pela seca na vegetação, pois ele reflete as alterações no conteúdo de água e mesofilo nos dosséis da vegetação (GU et al., 2008).

O NDWI é normalizado a partir da diferença entre o infravermelho próximo (0,858 μm) e o infravermelho de ondas curtas (1,230 μm) (GAO, 1996). Em florestas plantadas, o NDWI é capaz de acompanhar melhor as mudanças no dossel e na biomassa quando comparado ao NDVI, pois enquanto o NDVI satura, perdendo a capacidade de acompanhar alterações no conteúdo de água na vegetação, o NDWI continua acompanhando essas alterações (JACKSON, 2004). Assim, seu uso pode ser eficiente para acompanhar alterações na vegetação (JIN; SADER, 2005).

O Índice de Seca Normalizado (*Normalized Difference Drought Index* – NDDI) foi gerado a partir do NDVI e NDWI (GU et al., 2007). O NDDI apresenta uma resposta mais forte às condições de seca do que a diferença entre o NDVI e o NDWI, sendo um indicador mais sensível que o NDVI (GU et al., 2007). Ele é um índice híbrido que aproveita o fato de que o NDVI detecta material vegetal e o NDWI detecta a umidade das plantas (RENZA et al., 2010). Ao contrário dos demais índices, que aumentam conforme há um aumento da atividade fotossintética, o NDDI aumenta durante os períodos de seca (GU et al., 2007).

Além do avanço na elaboração dos índices de vegetação, a facilidade e qualidade das imagens orbitais também tem evoluído. Atualmente, a alta resolução espacial com características multiespectrais se tornou uma importante fonte de dados para a estimativa de biomassa florestal. No entanto, as sombras, a variação espectral e a baixa separabilidade espectral entre as copas das árvores e outras superfícies vegetadas no sub-bosque dificultam o desenvolvimento de modelos de estimativa da BF (KUMAR et al., 2015). Além disso, dados de alta resolução precisam de grande capacidade de armazenamento de dados, maior tempo de processamento e são muito mais caros o que limita, em parte, a sua aplicação na estimativas da BF em maior escala (BARBOSA; BROADBENT; BITENCOURT, 2014; KUMAR et al.,

2015), embora o seu uso seja bastante difundido no meio florestal (FERRAZ et al., 2014; WATZLAWICK; KIRCHNER; SANQUETTA, 2009).

Entre as imagens utilizadas no sensoriamento remoto as obtidas da série de satélites Landsat são as mais difundidas. Esta série conta com atualmente oito satélites, todos com imagens multiespectrais. O Landsat-1 foi lançado em 23 de julho de 1972 e de lá para cá, vários outros satélites foram colocados em órbita, sempre aprimorando a qualidade e periodicidade na obtenção de imagens da superfície terrestre (INPE, 2019).

O satélite Landsat-5 TM (*Thematic Mapper*) foi lançado em 1984 e o Landsat-8 OLI (*Operational Land Imager*) em 2013, ambos geram imagens com resolução espacial de 30 metros, o que facilita a identificação e caracterização dos alvos na superfície terrestre (INPE, 2019). Porém, a resolução radiométrica desses dois satélites é diferente, o sensor TM possui resolução de 8 bits e o sensor OLI de 16 bits (MASEK et al., 2006; VERMOTE et al., 2016). Dessa forma, eles capturam diferentes variações de energia refletida pela superfície (NOVO, 2008).

Em geral, a maioria dos estudos que utilizam índices de vegetação na estimativa da BF ainda estão limitados a um período de tempo específico, o que torna premente a necessidade de se avaliar a relação desses índices com a BF ao longo do tempo (ZHU; LIU, 2015). Todavia, existem limitações para sua utilização em grandes áreas em função da utilização de variáveis de campo como estimadores nos modelos e das condições da superfície que podem mudar mais rapidamente que o tempo de repetição das imagens obtidas dos satélite (BARBOSA; BROADBENT; BITENCOURT, 2014; GOETZ et al., 2009). A superestimação do valor da BF quando os valores em campo são pequenos e subestimação para grandes valores de BF são questões importantes que ainda carecem de estudos envolvendo dados ópticos que minimizem tais erros (GAO et al., 2018).

Dentre os modelos utilizados na predição da biomassa, estão os modelos de regressão (CASSOL; SALDANHA; KUPLICH, 2013; MIGUEL et al., 2015; WATZLAWICK; KIRCHNER; SANQUETTA, 2009). Os modelos de regressão relacionam a variação de uma variável dependente a partir de uma ou mais variáveis independentes através de funções de ligação lineares e não lineares (GUJARATI; PORTER, 2011).

Os modelos de regressão são utilizados quando se deseja predizer uma variável resposta, considerada dependente, em função de variáveis explanatórias, também chamadas de variáveis

independentes. A partir das variáveis independentes são obtidos estimadores dos parâmetros para a variável dependente (GUJARATI; PORTER, 2011; ZUUR et al., 2009). Os modelos podem ser lineares e não lineares. Os modelos lineares são aqueles onde os parâmetros possuem uma relação de linearidade entre si, já os modelos não-lineares não possuem essa relação linear entre parâmetros (GUJARATI; PORTER, 2011; ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013).

O modelo clássico de regressão linear deve seguir algumas premissas, sendo elas: linearidade dos parâmetros, valores das variáveis independentes (X) fixas ou independentes do termo de erro, valor médio do termo de erro igual a zero, homocedasticidade, ou seja, a variância do termo de erro é a mesma independente do valor de X, ausência de autocorrelação entre os termos de erro, número de observações maior que o número de parâmetros a serem estimados e variabilidade dos valores de X (GUJARATI; PORTER, 2011). Com tais suposições, os modelos lineares podem se tornar restritivos nas relações entre a variável dependente e as variáveis independentes (ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013).

Os modelos não lineares baseiam-se em informações sobre as relações entre a variável dependente e as variáveis independentes (ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013). Muitos pesquisadores acreditam que relações entre variáveis biológicas são melhores descritas por modelos não lineares (PEEK et al., 2002; ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013). A estimativa dos parâmetros desses modelos envolve procedimentos iterativos de estimação baseados no fornecimento de valores iniciais para os parâmetros (ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013)

Em estudos ecológicos os dados raramente atendem as suposições de normalidade, homogeneidade e independência dos resíduos (ZUUR et al., 2009). Em estudos que envolvem séries temporais, uma mesma amostra é medida repetidas vezes ao longo do tempo, em momentos diferentes e sob condições diversas (LAIRD; WARE, 1982). Assim, os pressupostos da regressão, como normalidade, homocedasticidade e independência dos resíduos podem não ser atendidos, tendo em vista que as séries temporais são repetições das amostras ao longo do tempo (ZUUR et al., 2009). Por isso, ao utilizar a regressão para estimar variáveis ecológicas e séries temporais, os pressupostos devem ser observados.

A utilização de redes neurais artificiais (RNA) se apresenta como alternativa viável na estimativa da BF a partir de dados de sensores remotos (ZHU; LIU, 2015). Recentemente a estimativa da biomassa da vegetação a partir de variáveis derivadas de sensores remotos por

meio do uso de redes neurais artificiais apresentaram resultados superiores aos encontrados nos ajustes feitos a partir de modelos de regressão (ZHU; LIU, 2015; FERRAZ et al., 2014; MIGUEL et al., 2015).

As RNAs são modelos computacionais criados para simular o funcionamento de neurônios biológicos. Elas possuem a capacidade de aprendizagem e suas unidades de processamento são formadas por neurônios artificiais interligados por forças de conexões chamadas de pesos sinápticos (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2016). A aprendizagem supervisionada das RNAs envolve a alteração dos pesos sinápticos a partir da entrada de um conjunto de amostras de treinamento até que a rede alcance estabilidade, quando não há mais alterações significativas dos pesos sinápticos (HAYKIN, 2001).

A relevância de cada uma das variáveis de entrada, tidas como neurônios artificiais na rede, é definida a partir da ponderação após sua multiplicação pelos pesos sinápticos (SILVA; SPATTI; FLAUZINO, 2016). O neurônio artificial é composto por sete elementos básicos: sinais de entrada (variáveis independentes), pesos sinápticos, combinador linear, que agrega os sinais de entrada já ponderados pelos pesos sinápticos a fim de chegar ao potencial de ativação, limiar de ativação, que especifica qual será o patamar apropriado para que o neurônio produza um potencial excitatório, função de ativação, que limita a saída do neurônio dentro de um intervalo e sinal de saída, que é o valor final produzido pelo neurônio no final do processo (variável dependente estimada) (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2016).

A representação matemática de um modelo básico de neurônio artificial pode ser dada da seguinte forma (HAYKIN, 2001; LEAL et al., 2015):

$$Y_k = \varphi(V_k),$$

em que: Y_k = saída do neurônio artificial, φ = função de ativação, V_k = resultado do combinador linear, sendo ele:

$$V_k = \sum x_m \cdot w_m$$

V_k = combinador linear; x_m são as entradas; e w_m representa o peso das entradas de m .

De forma mais simples, a aprendizagem é o treinamento das redes neurais, onde ocorre o ajuste dos parâmetros da rede a partir de amostras de treinamento (BINOTI; BINOTI; LEITE, 2014; HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2016). 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).

O desafio na modelagem da BF está em equilibrar a influência dos erros com a interpretação dos dados ecológicos e em observar como os erros de cada etapa de modelagem influenciam o erro geral (BARBOSA; BROADBENT; BITENCOURT, 2014). Dados de alta resolução espacial podem fornecer estimativas precisas de biomassa em escalas locais, todavia, para escalas regionais, é necessário grande volume de dados, que não é apenas caro, mas também difícil de processar, limitando a sua aplicação para áreas maiores (KUMAR et al., 2015). Poucos estudos examinaram especificamente quais as melhores técnicas e ferramentas para prever as mudanças na BF acima do solo em grandes áreas e em longos intervalos de tempo usando séries temporais (POWELL et al., 2010). Assim, a escassez dessas informações torna premente a investigação sobre quais os melhores modelos estatísticos e quais as variáveis preditoras afetam mais na estimativa da trajetória da BF ao longo do tempo.

Hipótese

Assumindo como premissa o fato de que os índices de vegetação e os valores de reflectância derivados de sensores remotos são amplamente utilizados como preditores da biomassa vegetal acima do solo (MIGUEL et al., 2015; PROPASTIN, 2013; WATZLAWICK; KIRCHNER; SANQUETTA, 2009), uma vez que essas variáveis se relacionam com a atividade fotossintética da vegetação (PONZONI; SHIMABUKURO; KUPLICH, 2007). Portanto, modelar a biomassa através de dados derivados de sensores remotos é uma alternativa viável para compreender a distribuição da biomassa no espaço e no tempo (BARBOSA; BROADBENT; BITENCOURT, 2014). Assim, este trabalho visa testar a seguinte hipótese:

- 1) A variação espacial e temporal da biomassa florestal acima do solo pode ser expressa por meio de variáveis derivadas de sensores remotos, uma vez que os valores de reflectância e os índices de vegetação são capazes de captar as mudanças apresentadas pela vegetação em função de sua relação com a atividade fotossintética.

Material e Métodos

Área de estudo

O estudo foi realizado na Floresta de Vale do Véu de Noiva (FVVN), localizada nas coordenadas 15°24'18,80" S e 55°49'55,35" W e que abrange aproximadamente 30 hectares. A FVVN está situada no sudeste do Parque Nacional da Chapada dos Guimarães (PNCG), no estado do Mato Grosso (ICMBIO, 2009). A vegetação é classificada como Floresta de Vale em função da dificuldade em separar a floresta de encosta da mata de galeria (PINTO; OLIVEIRA-FILHO, 1999), conforme sugerido por Eiten (1994).

O clima da região é classificado como Aw e Cw, segundo o sistema de Köppen, caracterizado como úmido nas épocas mais quentes e seco nas épocas mais frias (ALVARES et al., 2013). A precipitação média anual dos últimos 20 anos foi de 1680 mm, com período frio e seco entre os meses de maio a setembro e o período chuvoso entre os meses de outubro a março (MEIRA JUNIOR, 2019). A altitude no PNCG varia de 250 m a 800 metros e a vegetação predominante no parque é típica do bioma Cerrado (ICMBIO, 2009), com componentes florísticos que caracterizam a região como de transição Cerrado-Amazônia (PINTO; OLIVEIRA-FILHO, 1999).

A altitude na FVVN varia de 350 a 550 metros (PINTO, 1997). A FVVN possui solos litólicos em fase arenosa, com manchas de areia quartzosa distrófica e solos aluviais no fundo do vale, sendo eles rasos e com afloramentos rochosos de arenito e filito (PINTO; OLIVEIRA-FILHO; HAY, 2005). A flora é composta por espécies da Amazônia, Mata Atlântica e Cerrado, apresentando caráter transicional (PINTO; OLIVEIRA-FILHO, 1999). A vegetação apresenta dinâmica acelerada em relação às mudanças florísticas (ABREU; PINTO; MEWS, 2014; PINTO; HAY, 2005) e estruturais (MEIRA JUNIOR, 2019) devido as elevadas taxas de mortalidade e de recrutamento. Durante todo o período de monitoramento da vegetação, apenas em 2010 foi registrado incêndio florestal na FVVN, queimando a vegetação do lado direito do vale (ABREU; PINTO; MEWS, 2014; MEIRA JUNIOR, 2019) (Figura 1).

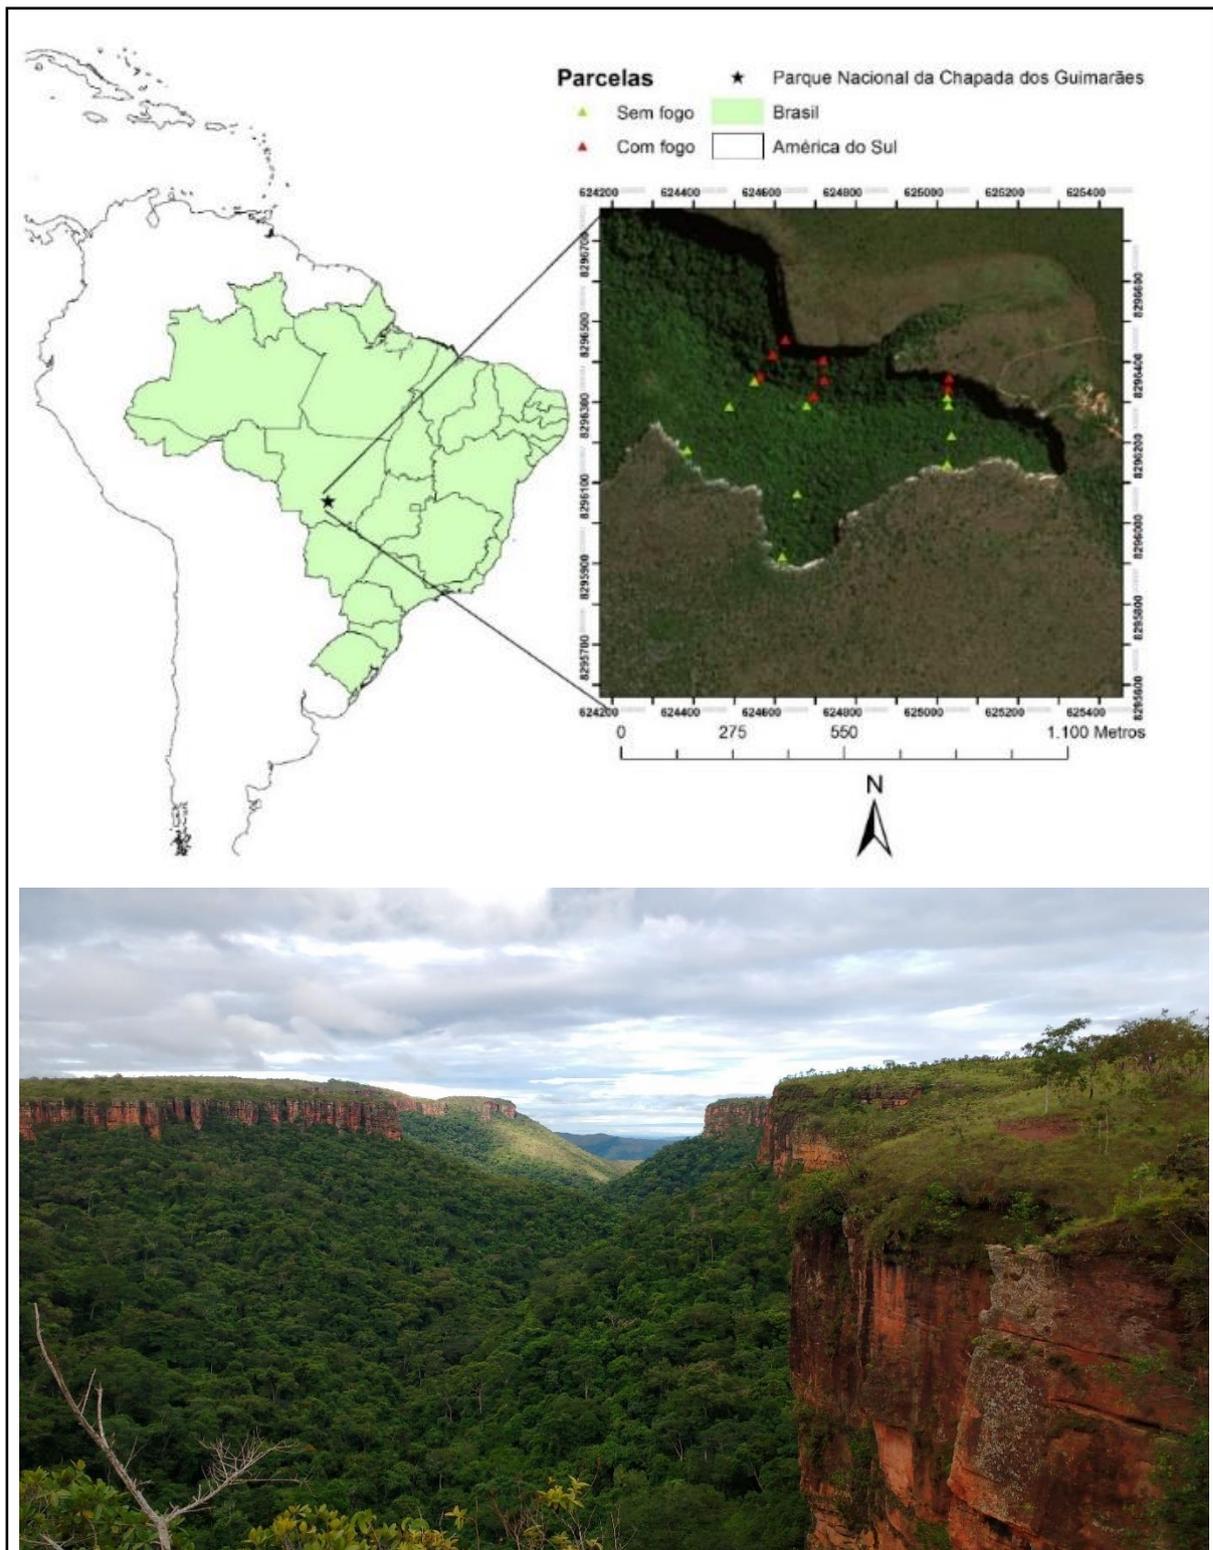


Figura 1. Localização da Floresta de Vale do Véu de Noiva (FVVN), Parque Nacional da Chapada dos Guimarães, em relação ao estado de Mato Grosso, Brasil. Com destaque para a distribuição das parcelas (600 m²) na FVVN. Fonte: Esri, DigitalGlobe, GeoEye, Earthstar Geographics, CNES / Airbus DS, USDA, USGS, AEX, Getmapping, Aerogrid, IGN, IGP,

swisstopo e a Comunidade de usuários do GIS. Vista frontal do vale da Floresta de Vale do Véu de Noiva.

Amostragem em campo da vegetação

Para a amostragem da vegetação lenhosa foi utilizado o processo de amostragem sistemática (PÉLLICO NETTO; BRENA, 1997), composto por três transeções (próximo a queda dá água; na posição intermediária e na posição final do vale). Cada transeção é formada por seis parcelas de 600 m² instaladas em três setores topográficos: beira do córrego, meio e alto da encosta, três em cada margem do córrego, totalizando 18 parcelas. Nas parcelas foram amostrados todos os indivíduos com CAP (circunferência à altura do peito; 1,30 m de altura) \geq 15,7 cm, exceto lianas e indivíduos mortos, e todos os indivíduos com mais de um fuste que obtiveram média quadrática das ramificações à altura do peito \geq 15 cm. Os indivíduos que atenderam o critério de inclusão foram identificados com plaquetas metálicas numeradas e foram registradas as seguintes informações: identificação taxonômica e, ou coleta botânica; circunferência a 1,3m do solo (CAP) e altura total (HT).

A FVVN foi inventariada em seis ocasiões: 1996, 1999, 2003, 2006, 2010 e 2016. Pinto e Oliveira-Filho (1999) estudaram o perfil florístico e estrutural da comunidade arbustiva-arbórea e encontram fortes semelhanças com a flora Amazônia e Atlântica, demonstrando o caráter transicional desta vegetação. Pinto e Hay (2005) avaliaram as mudanças florísticas e estruturais da comunidade de árvores e arvoretas da FVVN de 1996 a 1999 e 1999 a 2001, e observaram mudança na composição florística e estrutura estável ao longo dos anos. Pinto et al. (2005) investigaram as influências do solo e topografia na distribuição das espécies arbóreas da FVVN e encontraram que a fertilidade, textura e regime de água no solo foram os principais determinantes da distribuição das espécies arbóreas.

Abreu et al. (2014) analisaram as mudanças na riqueza e na diversidade de espécies da comunidade arbustiva-arbórea da FVVN no período de 14 anos e verificaram que a mudança na composição florística foi acelerada, porém com a manutenção temporal da diversidade de espécies ao longo do tempo. Meira Junior (2019) analisou as mudanças nos aspectos florísticos, estruturais e funcionais ao longo dos 20 anos de monitoramento da FVVN, concluindo que a riqueza de espécies está relacionada significativamente e positivamente com a biomassa e que não houve modificações significativas na composição de espécies ao longo do período de monitoramento, entretanto, foi observado aumento na taxa de mortalidade, principalmente das árvores de grande porte e com isso a FVVN apresentou declínio no estoque de biomassa ao longo dos 20 anos de monitoramento.

Para estimar a biomassa foram utilizados dados de inventário obtidos por estes autores nos anos de 1996, 1999, 2003, 2006, 2010 e 2016. É importante ressaltar que no ano de 2010, oito das 18 parcelas foram acometidas por incêndio (ABREU; PINTO; MEWS, 2014) no lado direito do vale (Figura 1). Como duas parcelas próximas ao córrego estavam localizadas sobre o mesmo *pixel*, uma delas foi desconsiderada nas análises. Dessa forma, foram utilizadas 17 parcelas nas análises anuais e 102 parcelas na análise temporal, que são resultantes da repetição destas 17 parcelas em seis períodos de amostragem.

Estimativa da biomassa florestal acima do solo

Para calcular a biomassa florestal acima do solo foi utilizada a equação proposta por Chave et al. (2014), pelo pacote BIOMASS do software R (RÉJOU-MÉCHAIN et al., 2017):

$$B = 0,0673 \times (Db \times Ht \times DAP^2)^{0,976}$$

Em que: B= Biomassa acima do solo (kg); Db= Densidade básica da espécie (g.cm⁻³); Ht= Altura total (m); DAP= Diâmetro à 1,3m do solo (cm).

A biomassa lenhosa total acima do solo de cada parcela foi determinada pela soma da biomassa dos indivíduos amostrados (MEIRA JUNIOR, 2019). Em seguida, a biomassa total das parcelas foi transformada para a unidade de Megagrama (Mg) por hectare, conforme feito por Brien et al. (2015).

Densidade básica da madeira

A determinação da densidade básica média da madeira foi calculada para as espécies que corresponderam a 80% da abundância de indivíduos em relação ao monitoramento realizado em 2016 (MEIRA JUNIOR, 2019). Para cada espécie, foram sorteados cinco indivíduos entre as classes de diâmetro, onde foram obtidas amostras de madeira a 1,30 m do solo utilizando trado Pressler. A densidade básica da madeira para as espécies não coletadas foi obtida pela média da densidade básica da madeira para as espécies coletadas (SOUZA et al., 2012). Os procedimentos para determinação da densidade básica da madeira seguiram o protocolo da NBR 11941 (ABNT, 2003).

Reflectância e Índices de vegetação

Foram obtidos os dados em reflectância de superfície a partir de dados dos satélites Landsat 5 TM e Landsat 8 OLI, com resolução espacial de 30 metros. Para isso, foram adquiridas cenas anuais, através do site do Serviço Geológico dos Estados Unidos (*United States Geological Survey* - USGS) (<https://earthexplorer.usgs.gov/>) para todos os anos de medição, de 1996 a 2016 (Tabela 1). Todas as imagens foram obtidas em dados sob demanda de reflectância de superfície, para as estações seca e chuvosa (Tabela 1), com exceção do período chuvoso de 2006, onde não foram encontradas cenas sem nuvens. As cenas utilizadas encontram-se nas Figuras 2 e 3.

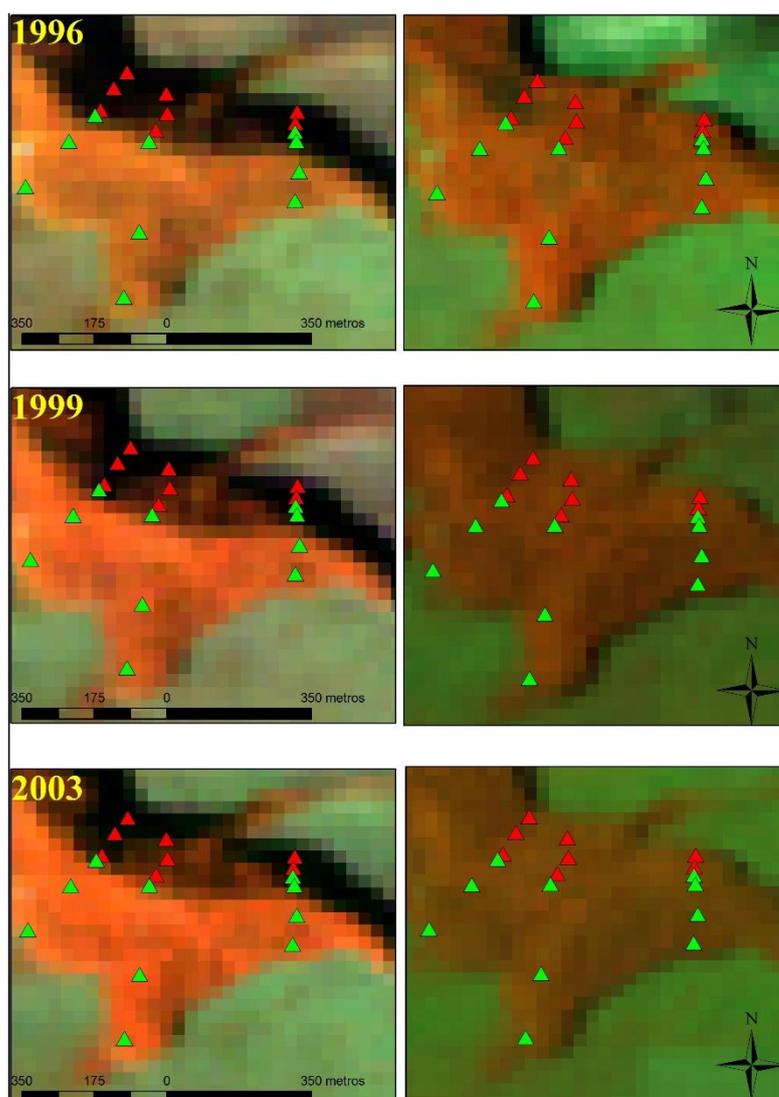


Figura 2. Cenas do satélite Landsat 5 TM para estação seca (esquerda) e chuvosa (direita) da Floresta de Vale do Véu de Noiva – Parque Nacional da Chapada dos Guimarães – MT, Brasil, onde as parcelas com fogo encontram-se na cor vermelha e as parcelas sem fogo na cor verde.

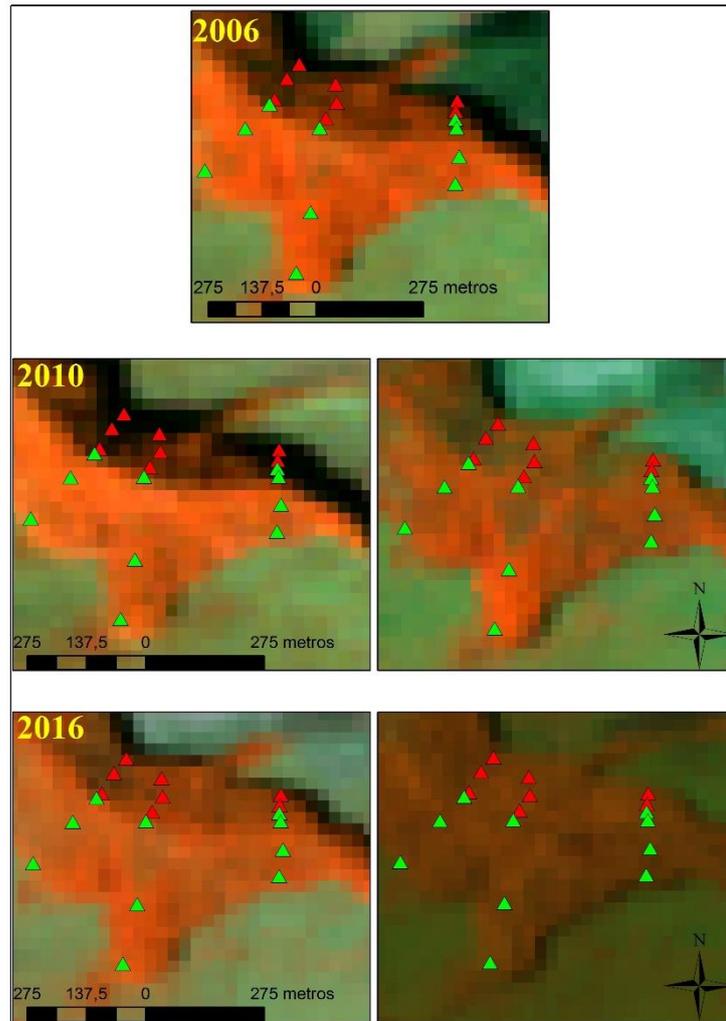


Figura 3. Cenas do satélite Landsat 5 TM (2006 e 2010) e Landsat 8 OLI (2016) para estação seca (esquerda) e chuvosa (direita) da Floresta de Vale do Véu de Noiva – Parque Nacional da Chapada dos Guimarães – MT, Brasil, onde as parcelas com fogo encontram-se na cor vermelha e as parcelas sem fogo na cor verde.

O Datum das cenas é o WGS1984 e a projeção escolhida foi a UTM 23S. As cenas foram georreferenciadas com base na estação seca de 1996, que estava em conformidade com os pontos coletados em campo (PINTO; OLIVEIRA-FILHO, 1999). Apenas as cenas da estação seca e chuvosa de 1999 apresentaram deslocamento, sendo georreferenciadas a partir de quatro pontos de controle, com erro médio quadrático de 7.75 m e 5.22 m.

As cenas do satélite Landsat 5 TM foram processadas pelo USGS para reflectância de superfície através do *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS), software desenvolvido pela Administração Nacional da Aeronáutica e Espaço (NASA) e pela

Universidade de Maryland (MASEK et al., 2006). Já as cenas do Landsat 8 OLI foram processadas para reflectância de superfície através do Código de Reflectância de Superfície para o Landsat (LaSRC) (VERMOTE et al., 2016). Apesar da reflectância ser obtida a partir de algoritmos diferentes, por se tratar de uma série temporal, esses dados não foram analisados separadamente nos modelos temporais.

Tabela 1. Características das cenas utilizadas para obtenção dos dados de reflectância da vegetação lenhosa para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Órbita/Ponto	Ano de medição	Estação Seca	Estação Chuvosa	Satélite
226/071	1996	15/06/1996	05/10/1996	Landsat 5 TM
	1999	08/06/1999	01/12/1999	Landsat 5 TM
	2003	21/07/2003	10/11/2003	Landsat 5 TM
	2006	14/08/2006	-	Landsat 5 TM
	2010	22/06/2010	28/10/2010	Landsat 5 TM
	2016	10/09/2016	29/11/2016	Landsat 8 OLI

Os dados de reflectância foram obtidos para as bandas 1, 2, 3, 4, 5 e 7 do Landsat 5 TM, correspondentes as bandas do azul (0,45 a 0,52 μm), verde (0,52 a 0,60 μm), vermelho (0,63 a 0,69 μm), infravermelho próximo (NIR) (0,76 a 0,90 μm) e infravermelho de ondas curtas (SWIR 1 e SWIR 2 – 1,55 a 1,75 μm e 2,08 a 2,35 μm). Para o Landsat 8 OLI, os dados de reflectância foram obtidos para as bandas 2, 3, 4, 5, 6 e 7, correspondentes as bandas do azul (0,45 a 0,51 μm), verde (0,53 a 0,59 μm), vermelho (0,64 a 0,67 μm), infravermelho próximo (NIR) (0,85 a 0,88 μm) e infravermelho de ondas curtas (SWIR 1 e SWIR 2 – 1,57 a 1,65 μm e 2,11 a 2,29 μm). A partir dos dados de reflectância, foram calculados índices de vegetação (Tabela 2): NDVI (*Normalized Difference Vegetation Index*), EVI (*Enhanced Vegetation Index*), NDWI (*Normalized Difference Water Index*), NDDI (*Normalized Difference Drought Index*) e SR (*Simple Ratio Index*).

Os valores das reflectâncias para cada unidade amostral foram obtidas por meio da ferramenta *Extract MultiValues to Point* do software ArcMap 10.6 (Licença institucional da ESRI para a Universidade de Brasília). Os valores de reflectância foram extraídos de cada banda espectral do *pixel* onde estavam os pontos de localização das parcelas, para as cenas da estação seca e chuvosa. Duas parcelas próximas ao córrego ficaram localizadas nas imagens sobre o mesmo *pixel*, logo, uma delas foi desconsiderada. Assim utilizamos 17 parcelas nas análises. A partir dos dados de reflectância, calculamos os índices de vegetação (Tabela 2) mais comuns

para estudos de BF (SR, NDVI e EVI) e que se relacionam ao conteúdo de água no dossel (NDWI e NDDI).

Tabela 2. Índices de vegetação calculados para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Nome do índice	Sigla	Fórmula	Referência
Razão Simples - <i>Simple Ratio</i>	SR	$(\text{NIR}) / (\text{Vermelho})$	(BIRTH; MCVEY, 1968)
Índice de Vegetação da Diferença Normalizada - <i>Normalized Difference Vegetation Index</i>	NDVI	$(\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho})$	(ROUSE et al., 1974)
Índice de Realce da Vegetação - <i>Enhanced Vegetation Index</i>	EVI	$(G * (\text{NIR} - \text{Vermelho})) / (\text{NIR} + C1 * \text{Vermelho} - C2 * \text{Azul} + L)$	(HUETE et al., 2002):
Índice de Umidade por Diferença Normalizada - <i>Normalized Difference Water Index</i>	NDWI	$(\text{NIR} - \text{SWIR1}) / (\text{NIR} + \text{SWIR1})$	(GAO, 1996)
Índice de Seca Normalizado - <i>Normalized Difference Drought Index</i>	NDDI	$(\text{NDVI} - \text{NDWI}) / (\text{NDVI} + \text{NDWI})$	(GU et al., 2007)

Sendo G= 2,5, C1=6, C2=7,5 e L=1.

Análise anual da biomassa florestal

Foi verificada a normalidade dos dados anuais da biomassa florestal acima do solo através do teste de normalidade de Shapiro-Wilk (SHAPIRO; WILK, 1965). Para analisar a relação entre a biomassa florestal acima do solo e os dados derivados do satélite Landsat foi calculada a correlação de Pearson entre essas variáveis (CASSOL; SALDANHA; KUPPLICH, 2014; LU, 2005). Apesar dos índices de vegetação serem obtidos a partir dos dados de reflectância, nem todas as reflectâncias são utilizadas no cálculo dos índices. Dessa forma, ambas as variáveis foram testadas. Assim, a partir da correlação foram definidos quais índices e valores de reflectância estariam mais correlacionados à biomassa da FVVN nos anos inventariados.

Foram ajustados modelos lineares e não lineares através do *software* Curve 1.4 (Tabela 3) para cada ano de inventário da vegetação para definir qual a melhor variável derivada de dados de sensores remotos para estimar a BF. Além disso, avaliamos qual modelo apresentou o melhor ajuste, considerando o erro padrão da estimativa (S), erro padrão da estimativa relativo (S%), distribuição gráfica dos resíduos e coeficiente de correlação (R) (GUJARATI; PORTER, 2011; MIGUEL et al., 2015):

$$1) \quad S = \sqrt{\left(\frac{\sum(Ye - Yo)^2}{gl}\right)}$$

$$2) \quad S (\%) = \frac{S}{Ym} * 100$$

Onde Ye corresponde a biomassa florestal estimada pelo modelo, Yo corresponde a biomassa observada, gl corresponde ao grau de liberdade dos resíduos e Ym a média da biomassa florestal observada.

Em função da baixa quantidade de amostras por ano, foram ajustados apenas modelos de regressão simples, tendo em vista que incluir mais estimadores dos parâmetros no modelo reduziria os graus de liberdade disponíveis para estimar a variabilidade das estimativas dos parâmetros e acrescentar mais variáveis poderia trazer multicolinearidade para o ajuste (GUJARATI; PORTER, 2011). Para selecionar as variáveis independentes dos modelos, foram escolhidos os dois índices que aparecerem mais vezes com as maiores correlações entre os anos avaliados. Dessa forma, o SR e o EVI foram usados como estimadores.

Tabela 3. Modelos utilizados nos ajustes da biomassa florestal acima do solo para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Modelos	Equação
Linear	$y = \beta_0 + \beta_1.X + \varepsilon$
Exponencial	$y = \beta_0.(\beta_1.X) + \varepsilon$
Logaritmo	$y = \beta_0 + \beta_1.\ln(X) + \varepsilon$
Quadrático	$y = \beta_0 + \beta_1.X + \beta_2.X^2 + \varepsilon$
Polinomial	$y = \beta_0 + \beta_1.X + \beta_2.X^2 + \beta_3.X^3 + \beta_4.X^4 + \varepsilon$

Onde: β_i : estimadores dos parâmetros; X: índice de vegetação; ε : erro do modelo.

Análise temporal da biomassa florestal

A segunda etapa desse estudo foi verificar a viabilidade e precisão dos índices de vegetação como estimadores dos parâmetros de modelos preditores da biomassa ao longo do tempo. Na etapa anterior, os anos foram analisados isoladamente, aqui, eles foram considerados como estimadores da biomassa.

Para definir quais as melhores variáveis preditoras para estimar a variação temporal da biomassa florestal a partir de regressão linear foi utilizada a função StepAIC do software R (VENABLES; RIPLEY, 2002). Essa função define a partir do método de *stepwise*, modelos que identificam os melhores preditores, eliminando preditores que possuem alta correlação entre si. Ela identifica quais são as variáveis mais significativas, adicionando sistematicamente esta variável e removendo a variável menos significativa durante cada etapa do ajuste (HOCKING, 1976).

Dessa forma, vários modelos foram ajustados a partir do conjunto de variáveis informadas como possíveis preditoras, entre elas: ano de monitoramento, SWIR1, EVI, NDVI, NDDI, NDWI, SR, Verde, Vermelho e NIR. Assim, a função forneceu qual o melhor modelo a partir do Critério de Informação de Akaike - AIC (AKAIKE, 1998). O AIC supõe a existência de um modelo real desconhecido que descreve a variável de interesse, dessa forma, quanto menor o valor de AIC, mais próximo do modelo real está o modelo ajustado. Esse critério é relevante na análise de regressão, pois penaliza modelos com números excessivos de parâmetros, selecionando modelos mais parcimoniosos (AKAIKE, 1992; CARVALHO et al., 2011).

Após a seleção do melhor modelo, foram verificadas as premissas da regressão, ou seja: normalidade dos resíduos a partir do teste de Shapiro-Wilk (SHAPIRO; WILK, 1965), ausência de correlação entre erros através do teste de Durbin-Watson (DURBIN; WATSON, 1951) e homocedasticidade dos resíduos através do teste de Goldfeld-Quandt (GOLDFELD; QUANDT, 1965). A rotina utilizada no software R para o ajuste encontra-se descrita no Anexo I.

Na etapa de ajuste dos modelos para a estimativa anual da biomassa florestal acima do solo não foram utilizados testes estatísticos de homocedasticidade nem de autocorrelação entre os erros. Em estudos pontuais, as amostras são independentes e a análise gráfica dos resíduos é suficiente para verificar esses pressupostos, já em séries temporais, as amostras são repetições, podendo haver a violação desses pressupostos (CRAWLEY, 2007; ZUUR et al., 2009). Assim, foram aplicados testes estatísticos para verificar esses pressupostos.

Análise temporal da biomassa florestal a partir de Redes Neurais Artificiais (RNA)

A aplicação das redes neurais artificiais (RNAs) para estimativa da biomassa florestal foi realizada no software NeuroForest 3.2 (BINOTI; BINOTI; LEITE, 2014; LEAL et al., 2015). Foram treinadas cinco redes, de forma supervisionada, ou seja, com indicação das variáveis de

entrada e de saída, com arquitetura do tipo *Multilayer Perceptron*, com cinco neurônios na camada de entrada (ano de medição, SWIR1, EVI, NDDI e NWDI), e um neurônio na camada de saída (biomassa florestal). O algoritmo de treinamento usado foi o *Resilient Propagation* (LEAL et al., 2015; SILVA; SPATTI; FLAUZINO, 2016). A camada oculta possuiu oito neurônios e a função de ativação da camada de entrada e de saída foi a sigmoideal, dessa forma, a estrutura das redes foi MLP 5-8-1.

Para o treinamento das RNAs foram selecionadas aleatoriamente 70 das 102 amostras, cerca de 69% do total. O restante das amostras foi utilizada para validação da rede (BINOTI; BINOTI; LEITE, 2014; MIGUEL et al., 2015). A qualidade das RNAs foi avaliada a partir do erro padrão da estimativa absoluto (S), erro padrão da estimativa em percentual (S%) e da distribuição gráfica dos resíduos (GUJARATI; PORTER, 2011; LEAL et al., 2015; MIGUEL et al., 2015). A RNA que apresentou o melhor ajuste foi validada através do teste t de Student (CARRIJO, 2019; MIGUEL et al., 2015).

$$S\% = \frac{\left(\sqrt{\frac{\sum(Ye - Yo)^2}{n}} \right)}{Ym} * 100$$

Onde: Ye corresponde a biomassa florestal estimada pela rede, Yo corresponde a biomassa observada, n corresponde a quantidade de amostras utilizadas no ajuste e Ym corresponde a média da biomassa florestal das amostras utilizadas no ajuste.

Resultados

Biomassa florestal

A média da BF aumentou ao longo do tempo, exceto no último período avaliado 2010 e 2016 (Tabela 4). A variação da BF entre as parcelas apresentou distribuição normal para todos os anos de medição (Shapiro-Wilk, $\alpha= 5\%$). No entanto, o coeficiente de variação foi superior a 50% em todos os períodos de inventário, o que demonstra a alta variação da biomassa entre as unidades amostrais.

Tabela 4. Média da biomassa florestal acima do solo, menor valor de biomassa, maior valor de biomassa, coeficiente de variação (CV) e desvio padrão (DP) da biomassa florestal da Floresta de Vale do Véu de Noiva, localizada no Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Ano	Biomassa acima do solo (Mg.ha ⁻¹)	Menor Biomassa (Mg. ha ⁻¹)	Maior Biomassa (Mg. ha ⁻¹)	CV (%)	DP (Mg.ha ⁻¹)
1996	117,74	33,17	248,49	52,22	61.49
1999	123,71	38,77	251,36	51,19	63.33
2003	138,53	48,46	298,48	52,55	72.80
2006	151,23	64,99	319,56	48,94	74.02
2010	159,25	47,91	339,40	54,17	86.26
2016	141,56	42,44	321,48	58,06	82.19

Analisando separadamente as parcelas com e sem ocorrência de incêndio florestal (SF e CF) foi possível observar comportamento distinto no acúmulo de BF ao longo do tempo. Embora ambas as áreas apresentaram acúmulo de BF ao longo do tempo, até a passagem do fogo em 2010, a SF foi a que apresentou maior estoque e maior acúmulo de BF, bem como a que registrou maior queda, após a passagem do fogo (Figura 4). Essas parcelas de maior BF estão localizadas no lado esquerdo da vertente, lado menos sombreado da FVVN (Figura 2 e Figura 3).

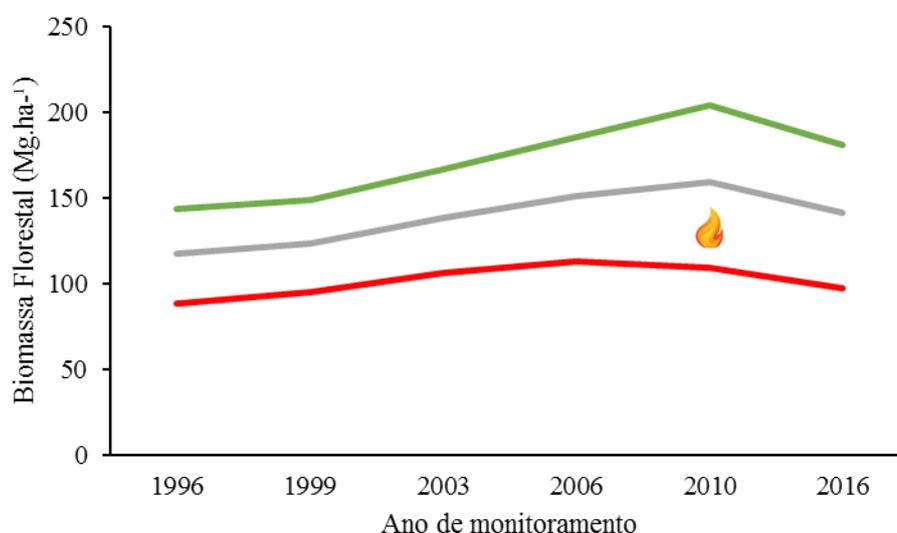


Figura 4. Comportamento da biomassa florestal acima do solo em parcelas com incêndio (linha vermelha), sem incêndio (linha verde) e em todas as parcelas (linha cinza) amostradas na Floresta de Vale do Véu de Noiva, Chapada dos Guimarães - MT, Brasil.

Estimativa anual da biomassa florestal

Os índices de vegetação apresentaram correlações maiores que os dados de reflectância por mais vezes entre os períodos de análise (Tabela 5). Dentre eles, o SR e o EVI foram os mais frequentes entre os de maior correlação com a BF na estação seca, para cinco dos seis períodos avaliados. Por isso, os ajustes dos modelos foram feitos a partir deles.

Para a maioria dos anos, tanto o SR quanto o EVI não foram estimadores significativos na predição da BF através de modelos lineares ($\alpha= 5\%$). Para o modelo exponencial, que é um modelo não linear, o SR foi o que apresentou o menor erro para todos os anos, com exceção de 1999, onde o melhor ajuste foi através do modelo polinomial (Tabela 6). O SR, em média, foi o que melhor acompanhou o aumento da BF ao longo do tempo (Figura 5) e o que apresentou as melhores estimativas da BF (Tabela 6), quando comparado ao EVI.

A distribuição gráfica dos resíduos para os ajustes utilizando o SR foi homogênea. Todavia, podemos observar que para todos os anos, houve parcelas que tiveram sua biomassa superestimada e subestimada em valores superiores a 50% (Figura 6). Enquanto isso o EVI foi o índice que apresentou menor erro para o período de 1996, porém superestimando a BF em algumas parcelas (Figura 6).

Tabela 5. Correlação entre a biomassa florestal e variáveis derivadas do Landsat para os anos de medição registrados na Floresta de Vale do Vêu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil. As três maiores correlações para cada período em negrito.

Ano	Período	Índices de vegetação					Reflectâncias				
		SR	EVI	NDDI	NDVI	NDWI	Verde	Vermelho	NIR	SWIR 1	SWIR2
1996	Seca	0,30	0,29	0,28	0,27	-0,16	0,09	0,17	0,25	0,21	0,20
	Chuva	0,54*	0,42	-0,25	0,51*	0,42	-0,25	-0,34	0,31	0,06	-0,09
1999	Seca	0,32	0,33	0,27	0,28	-0,15	0,35	0,38	0,32	0,32	0,31
	Chuva	0,16	0,34	-0,02	0,20	0,04	-0,08	-0,04	0,33	0,21	0,02
2003	Seca	0,32	0,27	-0,10	0,24	0,40	0,19	0,16	0,25	0,10	0,12
	Chuva	-0,13	0,02	0,18	-0,10	-0,18	0,20	0,13	-0,07	0,07	0,24
2006	Seca	0,44	0,30	0,10	0,40	0,06	-0,01	-0,02	0,24	0,16	0,12
	Chuva						#				
2010	Seca	0,38	0,29	0,17	0,27	-0,02	0,23	0,11	0,25	0,21	0,14
	Chuva	0,49	0,43	-0,50*	0,47	0,53*	-0,21	-0,61*	0,37	-0,15	-0,43
2016	Seca	0,66*	0,44	-0,56*	0,62*	0,62*	0,0008	-0,22	0,37	0,07	-0,10
	Chuva	-0,29	-0,37	0,47	-0,28	-0,46	-0,46	-0,09	-0,40	-0,1	0,0011

* significativo $\alpha=5\%$ (Correlação de Pearson). Valores entre parênteses correspondem a unidade de medida das variáveis. #: não foram encontradas cenas sem nuvem para o período. SR: Simple Ratio, EVI: Enhanced Vegetation Index, NDVI: Normalized Difference Vegetation Index, NDDI: Normalized Difference Drought Index, NIR: reflectância do infravermelho próximo, SWIR: reflectância do Infravermelho de Ondas Curtas, NDDI: Normalized Difference Drought Index, NDWI: Normalized Difference Water Index, Vermelho: reflectância do vermelho e Verde: reflectância do verde.

Apesar da correlação entre a biomassa e os índices na estação chuvosa serem maiores e significativos para alguns períodos (Tabela 5), esses dados não foram utilizados na modelagem em função das variáveis mais correlacionadas não serem constantes entre os períodos de chuva, como ocorreu para a estação seca, e da dificuldade em se obter cenas sem nuvens nessa estação. Outro ponto a ser considerado é o fato de ter sido observado aumento da correlação entre a BF e os índices de vegetação em 2016, que pode ter ocorrido em função da mudança de satélite e sensor, todavia, o erro relativo do ajuste para nesse ano não apresentou grande variação em relação aos encontrados nos demais anos (Tabela 6).

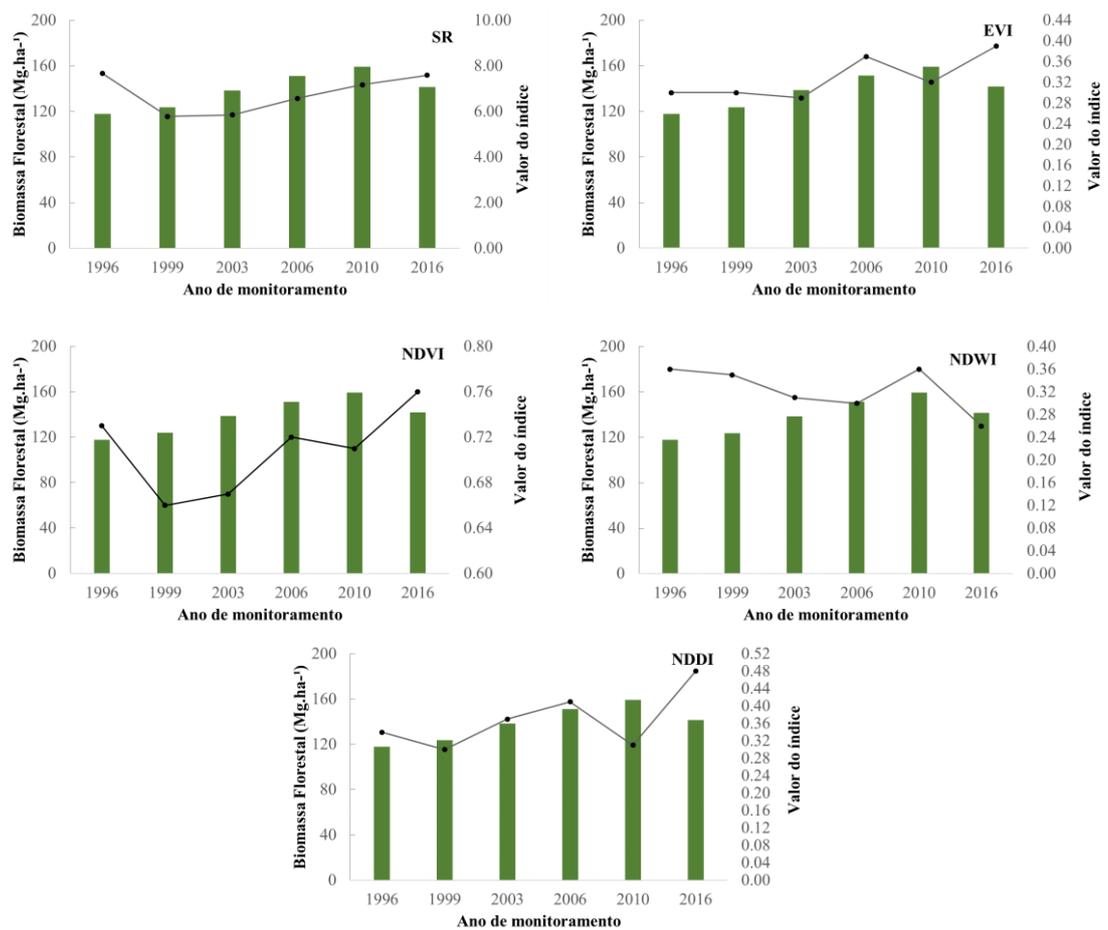


Figura 5. Comportamento dos índices de vegetação obtidos na estação seca (linhas) em relação as mudanças da biomassa florestal média (Mg.ha⁻¹) (barras) , registrado na Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

O uso do SR como preditor no modelo exponencial foi o índice de vegetação que apresentou o menor erro para todos os períodos, com exceção de 1999, onde o menor erro

encontrado foi para o modelo polinomial (Tabela 6). A distribuição gráfica dos resíduos para os ajustes através do SR foi homogênea, todavia houve parcelas com estimativa da biomassa superestimada e subestimada em valores superiores a 50% (Figura 6).

Tabela 6. Estatística de ajuste e precisão: erro absoluto (S), erro relativo (S%), coeficiente de correlação (R) para modelos lineares e não lineares obtidos a partir da utilização dos índices de vegetação SR e EVI, como preditores para a estimativa da biomassa florestal em diferentes períodos, amostrados na Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Ano	Modelo	SR			EVI		
		S (Mg.ha ⁻¹)	S (%)	R	S (Mg.ha ⁻¹)	S (%)	R
1996	Exponencial	60,41	51,30	0,30	60,87	51,69	0,28
1999	Polinomial	54,78	44,27	0,66	-	-	-
	Exponencial	61,89	50,03	0,32	62,03	50,13	0,31
2003	Exponencial	70,85	51,14	0,33	72,52	52,35	0,26
2006	Exponencial	68,11	45,03	0,45	72,85	48,17	0,30
2010	Exponencial	81,55	51,21	0,40	85,49	53,68	0,28
2016	Exponencial	62,33	44,02	0,68	75,44	53,29	0,46
	Linear	63,99	45,20	0,66	-	-	-

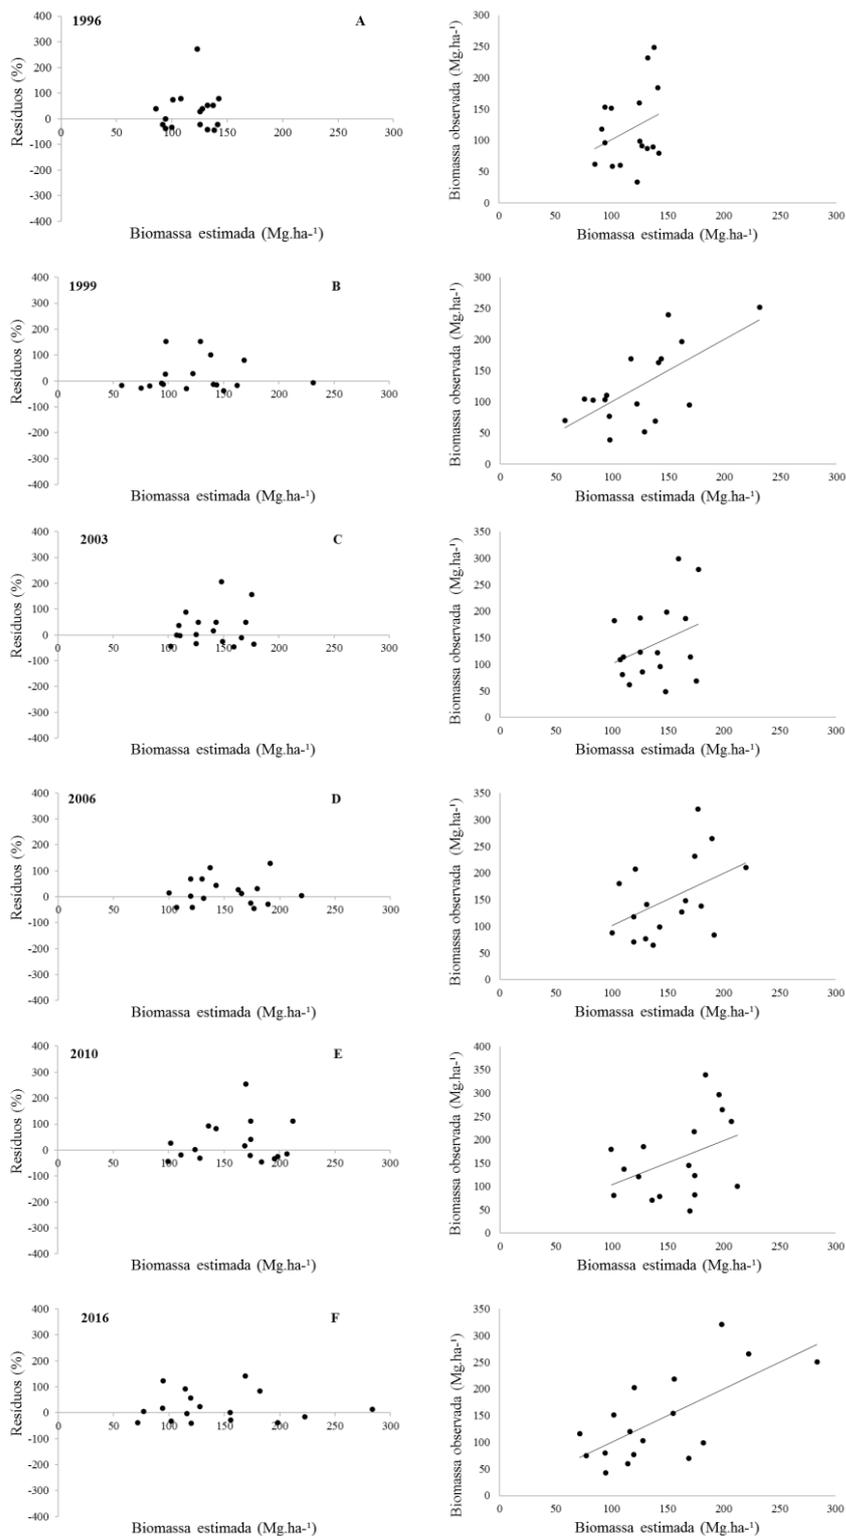


Figura 6. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) das estimativas geradas pelos modelos e relação entre os valores observados e estimados da BF, utilizando o SR no modelo exponencial (A, C, D, E, e F) e no modelo polinomial (B).

Estimativa temporal da biomassa florestal

O ajuste final a partir da seleção das variáveis preditoras com base no AIC (849,87) foi:

$$\text{Biomassa Florestal (Mg.ha}^{-1}\text{)} = 0,18062 * \text{Ano} - 3006,83479 * \text{SWIR1} + 1117,78437 * \text{EVI} - 216,73460 * \text{NDWI} - 652,01075 * \text{NDDI}$$

O coeficiente de determinação (R^2) desse modelo foi de 0,85 e o erro absoluto de 62.94 Mg.ha⁻¹, o que corresponde ao erro relativo (S%) de 45,38%.

Os estimadores (ano, SWIR1, EVI e NDWI) foram significativos na regressão ($\alpha= 1\%$). O NDDI, por sua vez, foi significativo apenas para $\alpha= 10\%$. Ao retirar esse índice do modelo, foi verificado que a qualidade do ajuste foi prejudicada, com aumento do erro absoluto para 63,58 Mg.ha⁻¹, redução do R^2 (0,84) e não normalidade dos resíduos (Shapiro Wilk, $\alpha= 5\%$).. Dessa forma, optou-se por manter esse índice, visto que ele contribuiu para a qualidade do ajuste.

A distribuição dos valores residuais apresentou normalidade (Shapiro Wilk, $\alpha= 5\%$), e ausência de autocorrelação entre os resíduos (Durbin-Watson, $\alpha= 5\%$). A distribuição gráfica dos resíduos sugere heterocedasticidade (Figura 7), todavia, ela foi descartada pelo teste de Goldfeld-Quandt ($\alpha= 5\%$). Pode ser observado que os valores estimados pelo modelo apresentam tendência em superestimar e subestimar a biomassa para áreas de maior acúmulo da BF (Figuras 7 e 8).

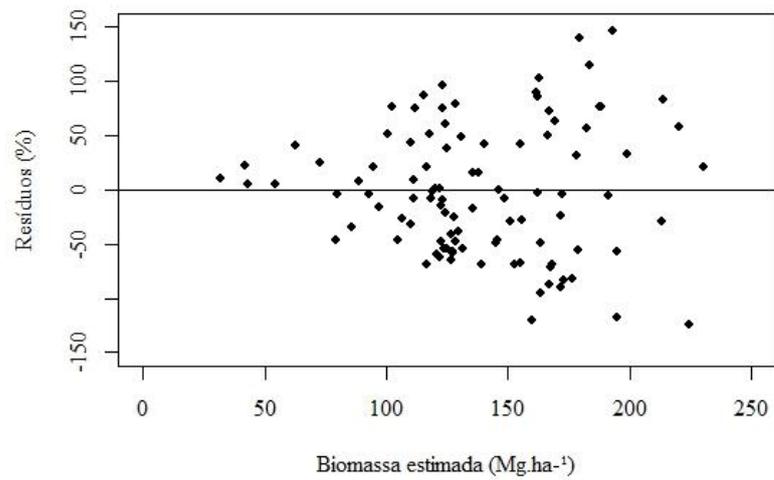


Figura 7. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) do ajuste do modelo temporal linear múltiplo para estimar a biomassa florestal acima do solo, usando como variáveis predictoras o ano e as variáveis derivadas de sensores remotos: SWIR1, EVI, NDDI e NDWI, para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

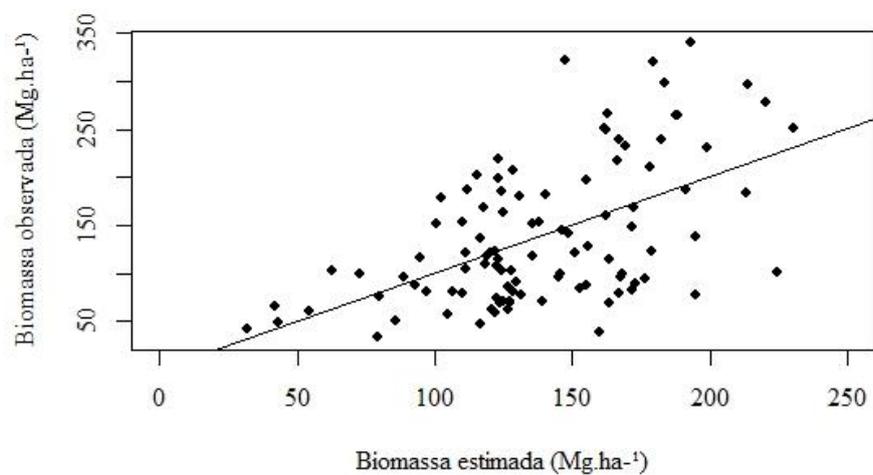


Figura 8. Valores observados da biomassa florestal acima do solo em relação a biomassa estimada pelo ajuste do modelo temporal linear múltiplo, tendo como variáveis predictoras o ano de medição e as variáveis derivadas de sensores remotos: SWIR1, EVI, NDDI e NDWI, para a Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

Estimativa temporal da biomassa florestal a partir de Redes Neurais Artificiais

Todas as cinco redes treinadas apresentaram erro padrão relativo $S\% < 35\%$, sendo a RNA3 a que apresentou melhor capacidade preditiva da biomassa florestal, com menor erro ($S\% = 23,60\%$) e maior coeficiente de correlação ($R = 0,89$) (Tabela 8). A distribuição gráfica dos resíduos foi homogênea (Figura 9) e apresentou melhor distribuição dos resíduos que a encontrada no ajuste do modelo de regressão temporal.

Tabela 7. Atributos e precisão das redes neurais artificiais treinadas para estimar a biomassa florestal da Floresta de Vale do Véu de Noiva - Parque Nacional da Chapada dos Guimarães - MT, Brasil.

RNA	Arquitetura	Nº de ciclos	Ativação oculta	Ativação saída	S (Mg.ha ⁻¹)	S (%)	R
1	MLP 5-8-1	3000			45,22	31,14	0,79
2	MLP 5-8-1	3000			40,39	27,81	0,84
3	MLP 5-8-1	3000	Sigmoidal	Sigmoidal	34,27	23,60	0,89
4	MLP 5-8-1	3000			43,42	29,90	0,81
5	MLP 5-8-1	3000			38,36	26,41	0,86

Onde: ativação oculta: função de ativação da camada oculta; ativação saída: função de ativação da camada de saída, S: erro padrão residual, S (%): erro padrão da estimativa em porcentagem, R: coeficiente de correlação entre biomassa estimada e biomassa observada.

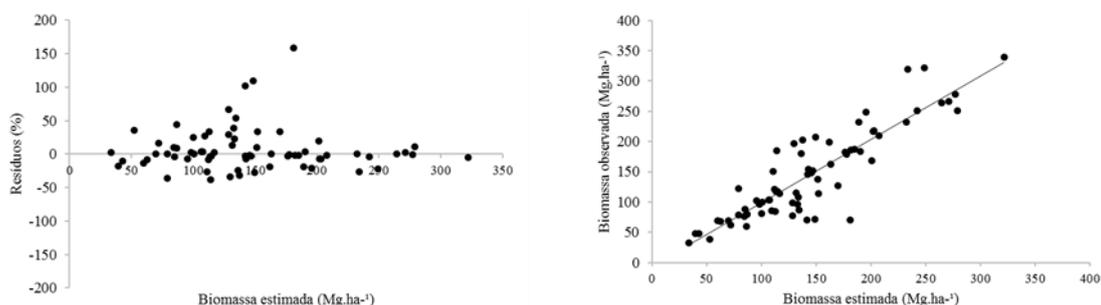


Figura 9. Distribuição gráfica dos resíduos (Biomassa estimada - Biomassa observada) da RNA3 a partir do ano de medição e das variáveis derivadas de sensores remotos: SWIR1, EVI, NDDI e NDWI e valores observados e estimados para biomassa florestal da Floresta de Vale do Véu de Noiva, Parque Nacional da Chapada dos Guimarães - MT, Brasil.

O resultado do teste t de Student para validação da RNA selecionada foi não significativo ($\alpha= 5\%$), indicando que não há diferenças estatísticas entre os valores estimados pela rede neural e os valores observados para as parcelas de validação.

Discussão

A tendência de aumento de BF observada pode estar associada ao fato de que o ganho de biomassa ao longo do tempo ocorre principalmente em função da reconstrução da floresta após algum tipo de distúrbio (FISHER et al., 2008). Os solos rasos, relevo íngreme e a ação canalizada de ventos na região da FVVN proporcionam a queda de árvores de grande porte (PINTO; OLIVEIRA-FILHO, 1999), causando mudanças na vegetação (PINTO; HAY, 2005; ABREU; PINTO; MEWS, 2014). Além disso, o incêndio florestal que ocorreu em 2010 e que atingiu algumas parcelas afetou a estrutura da vegetação (ABREU; PINTO; MEWS, 2014; MEIRA JUNIOR, 2019; PINTO; HAY, 2005) e, conseqüentemente, interrompeu a tendência de aumento da BF que vinha sendo observada. Assim, a ação em conjunto desses distúrbios pode ter influenciado às oscilações no estoque de biomassa na floresta.

A variação no estoque de BF entre as parcelas denota a heterogeneidade estrutural da floresta. A fertilidade, a textura do solo e a umidade do solo são fatores determinantes na distribuição das espécies arbóreas na FVVN (PINTO; OLIVEIRA-FILHO; HAY, 2005). Como a biomassa está positivamente relacionada a riqueza de espécies (MEIRA JUNIOR, 2019), essa heterogeneidade ambiental influencia na distribuição espacial da biomassa. Variações espaciais no acúmulo da biomassa ocorrem principalmente em função de alterações físicas do ambiente, como luminosidade, relevo e condições do solos (LU et al., 2014; PAN et al., 2013; ROITMAN et al., 2018; WALLIS et al., 2019).

A heterogeneidade na estrutura da floresta dificulta as estimativas da BF a partir de dados de sensoriamento remoto, que podem ser pouco sensíveis a essas 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).

A baixa acurácia dos modelos de regressão usados na estimativa da BF usando os índices de vegetação como preditores reflete a heterogeneidade nas condições ambientais em função das diferentes posições topográficas avaliadas, bem como das variações na estrutura da vegetação, tanto espacial como temporal. Variações biofísicas e a complexidade estrutural da

floresta afetam a estimativa da biomassa através de dados de sensores remotos e reduz o poder de predição dos modelos (LU, 2005). Neste caso, a resposta espectral captada pelos sensores teve pouca sensibilidade às mudanças espaciais da BF, como ficou evidenciado pelo elevado erro relativo encontrado em todos os modelos de regressão (> 44,02%). Por outro lado, o uso de índices de vegetação deve ser estimulado na estimativa da BF em áreas heterogêneas e de difícil acesso.

As RNAs apresentaram estimativas superiores aos modelos de regressão na estimativa da BF (MIGUEL et al., 2015; ZHU; LIU, 2015). Isso ocorre porque as RNAs são capazes de modelar relações complexas entre as variáveis sem as suposições que os modelos de regressão exigem (HAYKIN, 2001; MIGUEL et al., 2015; ZHU; LIU, 2015). Dessa forma, apesar delas exigirem uma maior complexidade computacional para seu treinamento (HAYKIN, 2001), seu uso se justifica em função de sua maior precisão.

Os sensores a bordo dos satélites captam valores de reflectância e não a biomassa (BARBOSA; BROADBENT; BITENCOURT, 2014; BOISVENUE et al., 2016), portanto, os valores de reflectância são variáveis que expressam de maneira indireta a atividade fotossintética. Outra fator a ser considerado é que, como a maioria dos estudos que utilizam os satélites MODIS e Landsat para a modelagem da BF, nosso estudo também foi influenciado por pixels mistos, bem como pela incompatibilidade entre o tamanho do pixel e a área das unidades amostrais (WALLIS et al., 2019). Além disso, a FVVN está localizada em um vale, dessa forma, há ocorrência de sombra em um dos lados da vertente no período seco. Os dados de sensoriamento utilizados para as análises desse trabalho foram deste período e a sombra interfere na qualidade desses dados (KUMAR et al., 2015), dessa forma, ela pode ter prejudicado a qualidade dos ajustes.

O baixo desempenho do NDVI na avaliação da BF pode estar associado ao fato deste índice apresentar saturação em florestas densas (HUETE et al., 2002; JENSEN, 2009) além da heterogeneidade no estoque de biomassa registrado na área. Assim, apesar desse índice ser amplamente divulgado, em regiões com alto acúmulo de biomassa em algumas parcelas, ele pode não ser sensível a essas variações.

O EVI foi um dos índices que esteve mais correlacionado a BF, sendo também selecionado no ajuste do modelo temporal. Isso pode ter ocorrido em função dele apresentar correções para o problema de saturação que ocorre em áreas florestais densas, sendo mais

sensível em regiões de elevada BF (JENSEN, 2009). Dessa forma, seu uso deve ser considerado em estudos posteriores para áreas nativas, com elevado acúmulo de biomassa entre as parcelas.

O SR foi o mais sensível a variações da biomassa por possuir maior intervalo dinâmico para acompanhar as variações da biomassa em regiões de alto acúmulo, quando comparado ao NDVI, que também se destaca no estudo do comportamento da biomassa (JENSEN, 2009). O NDVI, o EVI e o SR possuem alta correlação entre si em função de serem derivações uns dos outros, entretanto, para os modelos anuais, o SR gerou estimativas superiores ao EVI. No modelo temporal, por sua vez, o EVI foi melhor quando combinado com outros índices. Assim, o uso desses três índices deve ser avaliado, pois apesar de serem similares, dependendo do tipo de vegetação estudado, um deles pode ser superior ao outro.

O NDWI e o NDDI não estiveram entre os índices mais correlacionados com a biomassa. Eles estão relacionados às mudanças no teor de água no dossel da floresta, o que pode torná-los mais sensíveis que o NDVI para o monitoramento da vegetação nos períodos de seca (GAO, 1996; GU et al., 2007). Porém, na FVVN ambos não tiveram relação constante com a BF anual, apresentando ora correlações positivas, ora negativas. Assim não recomendamos a utilização desses índices na estimativa da variação espacial da BF.

No modelo temporal, o NDWI e o NDDI, quando combinados com outros índices, foram relevantes para estimar a BF. Esse comportamento entre o EVI, NDDI, NDWI e SWIR1 pode ter ocorrido em função de que, em regressões lineares múltiplas, os estimadores são estimadores parciais da regressão, dessa forma, eles sofrem influências dos outros estimadores (GUJARATI; PORTER, 2011), não refletindo sua relação direta com a variável dependente, como acontece com os modelos de regressão linear simples. Dessa forma, o uso integrado desses diferentes índices de vegetação deve ser utilizado de forma combinada na estimativa da biomassa florestal em séries temporais.

Os métodos de modelagem e as variáveis a serem incluídas no modelo devem ser escolhidos conforme a necessidade prática do usuário e das características da região estudada (BARBOSA et al., 2014; ZHU; LIU, 2015). Embora o SR tenha sido o índice de vegetação mais sensível às variações da BF, em média, ao longo do tempo, ele não foi o estimador selecionado no modelo temporal.

As baixas correlações das faixas espectrais do vermelho e do verde com a BF pode estar associada ao fato de que normalmente, os valores de reflectância sofrem interferências das

condições da atmosfera e do solo (JENSEN, 2009). Essas faixas do espectro se tornam instáveis e sujeitas a erros de estimativas quando comparadas aos índices de vegetação, que normalizam e modelam efeitos externos, como sombra, influência do solo e da atmosfera (JENSEN, 2009; PONZONI; SHIMABUKURO; KUPLICH, 2007). Assim, a redução de interferências externas à vegetação observada nos índices os tornariam mais sensíveis e correlacionados a BF do que as faixas espectrais. Dessa forma, não se recomenda a utilização exclusiva das bandas espectrais na modelagem da BF em condições similares as analisadas. Porém, quando combinado com outros estimadores, como no modelo temporal, por sua vez, o SWIR1, foi selecionado como uma variável explicativa importante para a BF.

As variáveis independentes dentro dos modelos devem ser capazes de estimar a variável de interesse (GUJARATI; PORTER, 2011), nesse caso, a BF. Os índices de vegetação não foram sensíveis o suficiente para acompanhar a variação da BF entre as parcelas com alta precisão nos modelos de regressão. A inclusão de dados de campo como variáveis preditoras em modelos de estimativa da BF tende a aumentar a qualidade dos ajustes (MIGUEL et al., 2015). Todavia, essa inclusão limita a extrapolação da estimativa da BF para áreas onde o inventário florestal não foi feito.

O SR apresentou maior precisão para os modelos anuais. No ajuste temporal, onde foram utilizados os índices EVI, que possui forte correlação com o SR, NDDI, NDWI e a banda espectral do SWIR1, a precisão do modelo de regressão continuou baixa. Usando apenas variáveis derivadas de sensores remotos como preditoras, foi possível explicar de forma razoável a variação espacial e temporal da biomassa através de modelos de regressão. O uso das RNAs na estimativa da BF apresentou maior precisão que os modelos de regressão. Dessa forma, nos estudos envolvendo a BF com os dados de sensoriamento remoto, deve-se buscar os métodos que consigam explorar a relação entre essas variáveis, considerando que os índices de vegetação são variáveis indiretas da BF. Assim, o uso dessas variáveis deve ser estimulado considerando a escassez de informações quantitativas da BF para áreas de difícil acesso.

Conclusões

Em geral a contribuição dos dados de sensoriamento remoto como variáveis preditoras na estimativa da biomassa florestal teve baixa precisão. Os preditores SR e EVI usados em modelos de regressão exponencial foram os índices de vegetação que melhor explicaram a variação espacial da biomassa florestal, porém com baixa precisão ($S\% = 44,02$). O ajuste de regressão linear múltipla utilizando como preditores os índices EVI, NDDI, NDWI e a

reflectância do SWIR1 foi o que melhor representou à variação temporal da biomassa florestal, todavia, também com baixa precisão ($S\% = 45,38$). As redes neurais artificiais, por sua vez, apresentam melhores estimativas temporais da biomassa ($S\% = 23,60$). Assim, a hipótese testada neste estudo foi parcialmente aceita, uma vez que as variáveis derivadas de sensores remotos possuem potencial como preditoras para estimar a variação temporal e espacial da biomassa florestal. No entanto, diferentes métodos de predição, sensores e índices de vegetação derivados de sensores remotos devem ser explorados a fim de melhorar a precisão das estimativas, com especial atenção às Redes Neurais Artificiais.

Referências bibliográficas

ABNT. **Madeira: determinação da densidade básica**. NBR 11941/2003. **Anais...**Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2003

ABREU, T. A. L.; PINTO, J. R. R.; MEWS, H. A. Variações na riqueza e na diversidade de espécies arbustivas e arbóreas no período de 14 anos em uma Floresta de Vale , Mato Grosso , Brasil. **Rodriguésia**, v. 65, n. 1, p. 73–88, 2014.

AKAIKE, H. Information Theory and an Extension of the Maximum Likelihood Principle. In: **Breakthroughs in Statistics**. New York: Springer, 1992. p. 610–624.

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.

BACCINI, A. et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 3, p. 182–185, 29 mar. 2012.

BARBOSA, J. M. et al. Remotely sensed biomass over steep slopes: An evaluation among successional stands of the Atlantic Forest, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 91–100, 2014.

BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote Sensing of Aboveground Biomass in Tropical Secondary Forests: A Review. **International Journal of Forestry Research**, v. 2014, n. ID 715796, p. 1–14, 2014.

BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de Redes Neurais Artificiais para Estimativa do Volume de Árvores. **Revista Ciência da Madeira - RCM**, v. 5, n. 1, p. 58–67, 31 maio 2014.

BIRTH, G. S.; MCVEY, G. R. Measuring Color of Growing Turf with a Reflectance Spectrophotometer. **Agronomy Journal**, v. 60, p. 640–649, 1968.

BOISVENUE, C. et al. Integration of Landsat time series and field plots for forest productivity estimates in decision support models. **Forest Ecology and Management**, v. 376, p. 284–297, set. 2016.

BONAN, G. B. Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. **Science**, v. 320, n. 5882, p. 1444–1449, 2008.

BRASIL, M. DO M. A. **Mapeamento do Uso e Cobertura do Cerrado Projeto TerraClass Cerrado 2013**. Ministério do Meio Ambiente: Brasília, 2015. Disponível em: <<http://www.dpi.inpe.br/tccerrado/index.php?mais=1>>

BRIENEN, R. J. W. et al. Long-term decline of the Amazon carbon sink. **Nature**, v. 519, n. 7543, p. 344–348, 2015.

BROWN, S.; LUGO, A. E. Biomass of Tropical Forests: A New Estimate Based on Forest Volumes. **Science**, v. 223, n. 4642, p. 1290–1293, 23 mar. 1984.

BUSTAMANTE, M. M. C. et al. Toward an integrated monitoring framework to assess the effects of tropical forest degradation and recovery on carbon stocks and biodiversity. **Global Change Biology**, v. 22, n. 1, p. 92–109, jan. 2016.

CARRIJO, J. V. N. **Inteligência artificial associada à dados de satélite na predição do potencial energético em área de Cerradão**. [s.l.] Dissertação de Mestrado, Universidade de Brasília, 2019.

CARVALHO, S. DE P. C. E et al. Modelos não lineares generalizados aplicados na predição da área basal e volume de Eucalyptus clonal. **CERNE**, v. 17, n. 4, p. 541–548, dez. 2011.

CASSOL, H. L. G.; SALDANHA, D. L.; KUPLICH, T. M. Comparação dos sensores ASTER e TM para a estimativa de biomassa e carbono em uma Floresta Ombrófila Mista. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto**, n. 2003, p. 3090–3097, 2013.

CASSOL, H. L. G.; SALDANHA, D. L.; KUPLICH, T. M. Inventário de carbono em fragmento de floresta ombrófila mista por detecção remota. **Floresta**, v. 44, n. 4, p. 697, 31 dez. 2014.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in

- tropical forests. **Oecologia**, v. 145, n. 1, p. 87–99, 2005.
- CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, out. 2014.
- CRAWLEY, M. J. **The R Book**. Chichester, UK: John Wiley & Sons, Ltd, 2007.
- DURBIN, J.; WATSON, G. S. Testing for Serial Correlation in Least Squares Regression. II. **Biometrika**, v. 38, n. 1/2, p. 159, jun. 1951.
- EITEN, G. Vegetação do cerrado. In: **Cerrado: caracterização, ocupação e perspectivas**. In M. N. P ed. Brasília: Universidade de Brasília, 1994. p. 17–73.
- FEARNSIDE, P. M. Wood density for estimating forest biomass in Brazilian Amazonia. **Forest Ecology and Management**, v. 90, p. 59–87, 1997.
- FEARNSIDE, P. M. Desmatamento na Amazônia: dinâmica, impactos e controle. **Acta Amazonica**, v. 36, n. 3, p. 395–400, 2006.
- 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, 29 jul. 2014.
- FISHER, J. I. et al. Clustered disturbances lead to bias in large-scale estimates based on forest sample plots. **Ecology Letters**, v. 11, n. 6, p. 554–563, jun. 2008.
- GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, dez. 1996.
- GARROUTTE, E. L.; HANSEN, A. J.; LAWRENCE, R. L. Using NDVI and EVI to map spatiotemporal variation in the biomass and quality of forage for migratory elk in the Greater Yellowstone Ecosystem. **Remote Sensing**, v. 8, n. 5, 2016.
- GATES, D. M. et al. Spectral properties of plants. **Applied Optics**, v. 4, n. 1, p. 11–20, 1965.
- GIZACHEW, B. et al. Mapping and estimating the total living biomass and carbon in low-biomass woodlands using Landsat 8 CDR data. **Carbon Balance and Management**, v. 11, n. 1, p. 13, 2016.
- GOETZ, S. 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.

- GOLDFELD, S. M.; QUANDT, R. E. Some Tests for Homoscedasticity. **Journal of the American Statistical Association**, v. 60, n. 310, p. 539–547, jun. 1965.
- GRACE, J. Understanding and managing the global carbon cycle. **Journal of Ecology**, v. 92, n. 2, p. 189–202, abr. 2004.
- GU, Y. et al. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, v. 34, n. 6, p. 1–6, 27 mar. 2007.
- GU, Y. et al. Evaluation of MODIS NDVI and NDWI for vegetation drought monitoring using Oklahoma Mesonet soil moisture data. **Geophysical Research Letters**, v. 35, n. 22, p. 1–5, 2008.
- GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5^a ed. Porto Alegre - RS: AMGH Editora Ltda, 2011.
- HANSEN, M. C. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, v. 342, n. 6160, p. 850–853, 15 nov. 2013.
- HAYKIN, S. **Redes neurais : princípios e prática** Porto Alegre - RS: Bookman, , 2001.
- HIGUCHI, N. et al. Aboveground biomass estimate for Amazonian dense tropical moist forests. **Mem. Fac. Agr. Kagoshima Univ.**, v. 30, n. t 987, p. 43–54, 1994.
- HIGUCHI, N. et al. Biomassa da parte aérea da vegetação da Floresta Tropical úmida de terra-firme da Amazônia Brasileira. **Acta Amazonica**, v. 28, n. 2, p. 153–153, jun. 1998.
- HOCKING, R. R. A Biometrics Invited Paper. The Analysis and Selection of Variables in Linear Regression. **Biometrics**, v. 32, n. 1, p. 1, mar. 1976.
- HONGJUN, L. et al. Comparison of NDVI and EVI based on EOS/MODIS. **Progress in Geography**, v. 26, p. 26–32, 2007.
- HOUGHTON, R. A. Aboveground Forest Biomass and the Global Carbon Balance. **Global Change Biology**, v. 11, n. 6, p. 945–958, jun. 2005.
- 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, nov. 2002.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**,

v. 25, n. 3, p. 295–309, 1988.

ICMBIO. **Plano de Manejo: Parque Nacional da Chapada dos Guimarães**. Chapada dos Guimarães: Ministério do Meio Ambiente, 2009.

INPE. **LANDSAT**. Disponível em: <<http://www.dgi.inpe.br/documentacao/satelites/landsat>>.

IPCC. Summary for policymakers. In: PARRY, M. L. AND CANZIANI, O. F. AND PALUTIKOF, J. P. AND VAN DER LINDEN, P. J. AND HANSON, C. E. (Ed.). . **Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge, UK: Cambridge University Press, 2007. p. 7–22.

IPCC. **Climate Change 2013 - The Physical Science Basis** (Intergovernmental Panel on Climate Change, Ed.) **Climate Change 2013: The Physical Science Basis**. Cambridge: Cambridge University Press, 2014. Disponível em: <<http://ebooks.cambridge.org/ref/id/CBO9781107415324>>.

JACKSON, T. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. **Remote Sensing of Environment**, v. 92, n. 4, p. 475–482, set. 2004.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. 2. ed. São José dos Campos: Parêntese Editoria, 2009.

JIN, S.; SADER, S. A. Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances. **Remote Sensing of Environment**, v. 94, n. 3, p. 364–372, fev. 2005.

JOHNSON, M. O. et al. Variation in stem mortality rates determines patterns of above-ground biomass in Amazonian forests: implications for dynamic global vegetation models. **Global Change Biology**, v. 22, n. 12, p. 3996–4013, dez. 2016.

KUMAR, L. et al. Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 1–34, 16 jun. 2015.

LAIRD, N. M.; WARE, J. H. Random-Effects Models for Longitudinal Data. **Biometrics**, v. 38, p. 963–974, 1982.

- LEAL, F. A. et al. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, v. 33, n. 2, p. 233–249, 2015.
- LEITÃO, P. J. et al. From sample to pixel: multi-scale remote sensing data for upscaling aboveground carbon data in heterogeneous landscapes. **Ecosphere**, v. 9, n. 8, p. e02298, ago. 2018.
- LI, C. et al. Comparative Analysis of Seasonal Landsat 8 Images for Forest Aboveground Biomass Estimation in a Subtropical Forest. **Forests**, v. 11, n. 1, p. 45, 31 dez. 2019.
- LU, D. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 26, n. 12, p. 2509–2525, 2005.
- 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, 2 jan. 2014.
- 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, p. 1–21, 8 set. 2017.
- MASEK, J. G. et al. A Landsat Surface Reflectance Dataset for North America, 1990–2000. **IEEE Geoscience and Remote Sensing Letters**, v. 3, n. 1, p. 68–72, jan. 2006.
- MEIRA JUNIOR, M. S. DE. **Mudanças florísticas, estruturais e funcionais da vegetação lenhosa ao longo de 20 anos em uma Floresta Estacional, Mato Grosso**. [s.l.] Tese de doutorado, Universidade de Brasília, 2019.
- MENESES, P.R., ALMEIDA, T, BAPTISTA, G. M. M. **Reflectância dos materiais terrestres - Análise e Interpretação**. Brasília: Oficina de textos, 2019.
- 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.
- NOVO, E. M. L. DE M. **Sensoriamento Remoto: Princípios e Aplicações**. 4^a ed. São Paulo: Edgard Blücher, 2008.
- NOVO, E. M. L. DE M.; PONZONI, F. J. **Introdução ao Sensoriamento Remoto**. São José

dos Campos: DGI/INPE, 2001.

OMETTO, J. P. et al. Amazon forest biomass density maps: tackling the uncertainty in carbon emission estimates. **Climatic Change**, v. 124, n. 3, p. 545–560, 11 jun. 2014.

PAN, Y. et al. The Structure, Distribution, and Biomass of the World's Forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 44, n. 1, p. 593–622, 23 nov. 2013.

PEEK, M. S. et al. Physiological response curve analysis using nonlinear mixed models. **Oecologia**, v. 132, n. 2, p. 175–180, 1 jul. 2002.

PÉLLICO NETTO, S.; BRENA, D. A. **Inventário florestal**. 1997. ed. Curitiba: editorado, 1997.

PINTO, J. R. R. **Levantamento florístico, estrutura da comunidade arbóreo-arbustiva e suas correlações com variáveis ambientais**. [s.l.] Universidade Federal de Lavras - UFLA, 1997.

PINTO, J. R. R.; HAY, J. D. V. Mudanças florísticas e estruturais na comunidade arbórea de uma floresta de vale no Parque Nacional da Chapada dos Guimarães, Mato Grosso, Brasil. **Revista Brasileira de Botânica**, v. 28, n. 3, p. 523–539, 2005.

PINTO, J. R. R.; OLIVEIRA-FILHO, A. T.; HAY, J. D. V. Influence of soil and topography on the composition of a tree community in a central brazilian valley forest. **Edinburgh Journal of Botany**, v. 62, n. 1–2, p. 69–90, 20 mar. 2005.

PINTO, J. R. R.; OLIVEIRA-FILHO, A. T. DE. Perfil florístico e estrutura da comunidade arbórea de uma floresta de vale no Parque Nacional da Chapada dos Guimarães, Mato Grosso, Brasil. **Revista Brasileira de Botânica**, v. 22, n. 1, p. 53–67, abr. 1999.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. São Paulo: Oficina de textos, 2007.

POWELL, S. L. et al. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: A comparison of empirical modeling approaches. **Remote Sensing of Environment**, v. 114, n. 5, p. 1053–1068, maio 2010.

PROPASTIN, P. Large-scale mapping of aboveground biomass of tropical rainforest in Sulawesi, Indonesia, using Landsat ETM+ and MODIS data. **GIScience & Remote Sensing**, v. 50, n. May 2014, p. 633–651, 2013.

- RÉJOU-MÉCHAIN, M. et al. Biomass: An R package for estimating above-ground biomass and its uncertainty in tropical forests. **Methods in Ecology and Evolution**, v. 8, n. 9, p. 1163–1167, set. 2017.
- RENZA, D. et al. Drought Estimation Maps by Means of Multidate Landsat Fused Images. **Department of Architecture and Technology of Computer Systems. Polytechnic University of Madrid (Spain). Campus de Montegancedo, 28660 Boadilla del Monte, Madrid, Spain**, p. 1–8, 2010.
- 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 sua importância na armazenagem do carbono. **Ciência Florestal**, v. 28, n. 3, p. 1350, 1 out. 2018.
- ROUSE, J. W. et al. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation**. Greenbelt, MD: [s.n.]. Disponível em: <<https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19740022555.pdf>>.
- ROY, P. S.; RAVAN, S. A. Biomass estimation using satellite remote sensing data—An investigation on possible approaches for natural forest. **J. Biosci**, v. 21, n. 4, p. 535–561, 1996.
- SANQUETTA, C. R. Metodologias para determinação de biomassa florestal. In: **As florestas e o carbono**. Curitiba: UFPR, 2002. p. 119–140.
- SANQUETTA, C. R. et al. Estimativa de carbono individual para araucaria angustifolia. **Pesquisa Agropecuária Tropical**, v. 44, n. 1, p. 1–8, 2014.
- SARMIENTO, G.; PINILLOS, M.; GARAY, I. Biomass Variability in Tropical American Lowland Rainforests. **Ecotropicos**, v. 18, n. 1, p. 1–20, 2005.
- 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.
- SILVA, C. V. J. et al. Drought-induced Amazonian wildfires instigate a decadal-scale disruption of forest carbon dynamics. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 373, n. 1760, p. 20180043, 19 nov. 2018.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. 2^a ed. São Paulo: Artliber Editora Ltda., 2016.

SOARES, P.; TOMÉ, M. Analysis of the effectiveness of biomass expansion factors to estimate stand biomass. **Proceedings of the International Conference on Moedling Forest Production, 19-22 April. Austria.**, n. January, p. 19–22, 2004.

SOMOGYI, Z. et al. Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, v. 126, n. 2, p. 197–207, 2007.

SOUZA, A. L. DE et al. Estrutura fitossociológica, estoques de volume, biomassa, carbono e dióxido de carbono em Floresta Estacional Semidecidual. **Revista Árvore**, v. 36, n. 1, p. 169–179, 2012.

VENABLES, W. N.; RIPLEY, B. D. **Modern Applied Statistics with S**. 4^a ed. New York, NY: Springer New York, 2002.

VERMOTE, E. et al. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, nov. 2016.

WALLIS, C. I. B. et al. Modeling tropical montane forest biomass, productivity and canopy traits with multispectral remote sensing data. **Remote Sensing of Environment**, v. 225, p. 77–92, maio 2019.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucaria utilizando imagens do satélite ikonos II. **Ciencia Florestal**, v. 19, n. 2, p. 169–181, 2009.

ZEVIANI, W. M.; RIBEIRO JÚNIOR, P. J.; BONAT, W. H. **Modelos de regressão não linear**. Disponível em:
<<https://www.ime.unicamp.br/~cnaber/cursomodelosnaolinearesR.pdf>>.

ZHENG, D. et al. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. **Remote Sensing of Environment**, v. 93, n. 3, p. 402–411, nov. 2004.

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, abr. 2015.

ZUUR, A. F. et al. **Mixed effects models and extensions in ecology with R**. New York, NY: Springer New York, 2009.

Anexo I

Rotina do software R

```
read.table("dados.txt",header = T)->dados

head(dados)

#Ajuste do modelo

require(MASS)

w1<-lm(bio~ano+swir1+evi+ndvi+nddi+ndwi+verde+sr+nir+vermelho-1,dados)

stepAIC(w1,direction="both")

m1<-stepAIC(w1)

#Visualização dos melhores estimadores

m1$coefficients

#Ajuste do modelo selecionado

w2<-lm(bio~ano+swir1+evi+nddi+ndwi-1,data=dados)

summary(w2)

#Teste de normalidade dos resíduos

shapiro.test(resid(w2))

#Teste de correlação entre os erros

library(lmtest)

dwtest(lm(bio~ano+swir1+evi+ndwi+nddi-1,data=dados))

#Gráfico de Resíduos

windowsFonts(A=windowsFont("Times New Roman"))

plot(resid(w2)~fitted(w2),xlab="Biomassa estimada (Mg.ha-1)",ylab="Resíduos (%)",
      family="A", ylim=c(-150,150),xlim=c(0,250),pch=c(19),cex=0.8)

abline(h=0)

#Teste de homocedasticidade de Goldfeld-Quandt

gqtest(lm(bio~ano+swir1+evi+nddi+ndwi-1,data))

#Resíduos são homocedasticos

#RSE: 62.94

summary(w2)

#RSE%

62.94/(mean(dados$bio))
```

```
#R2
```

```
0.8467
```

```
#Construção do gráfico para biomassa observada em relação a biomassa estimada
```

```
windowsFonts(A=windowsFont("Times New Roman"))
```

```
plot(dados$bio~fitted(w2), xlab="Biomassa estimada (Mg.ha-1)",
```

```
ylab="Biomassa observada (Mg.ha-1)", family="A",xlim=c(0,250),
```

```
pch=c(19),cex=0.8)
```

```
abline(lm(dados$bio~fitted(w2)))
```