



**JHULY ELY SANTOS PEREIRA**

**SENSORIAMENTO REMOTO PARA A MODELAGEM DA  
BIOMASSA E BIODIVERSIDADE ARBÓREA EM MINAS  
GERAIS: CONTEXTO TEMPORAL E ESPACIAL**

**LAVRAS - MG  
2021**

**JHULY ELY SANTOS PEREIRA**

**SENSORIAMENTO REMOTO PARA A MODELAGEM DA BIOMASSA E  
BIODIVERSIDADE ARBÓREA EM MINAS GERAIS: CONTEXTO TEMPORAL E  
ESPACIAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, para a obtenção do título de Mestre.

Prof. Dr. Fausto Weimar Acerbi Junior  
Orientador  
Dra. Eduarda Martiniano de Oliveira Silveira  
Dra. Marcela de Castro Nunes Santos Terra  
Coorientadoras

**LAVRAS - MG  
2021**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Pereira, Jhuly Ely Santos.

Sensoriamento Remoto Para a Modelagem da Biomassa e  
Biodiversidade Arbórea em Minas Gerais : Contexto Temporal e  
Espacial / Jhuly Ely Santos Pereira. - 2021.

96 p. : il.

Orientador(a): Fausto Weimar Acerbi Junior.

Coorientador(a): Eduarda Martiniano de Oliveira Silveira,  
Marcela de Castro Nunes Santos Terra.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2021.

Bibliografia.

1. Produtividade. 2. Temperatura. 3. Random Forests. I. Acerbi  
Junior, Fausto Weimar. II. Silveira, Eduarda Martiniano de  
Oliveira. III. Terra, Marcela de Castro Nunes Santos.

**JHULY ELY SANTOS PEREIRA**

**SENSORIAMENTO REMOTO PARA A MODELAGEM DA BIOMASSA E  
BIODIVERSIDADE ARBÓREA EM MINAS GERAIS: CONTEXTO TEMPORAL E  
ESPACIAL  
REMOTE SENSING FOR MODELING ABOVEGROUND BIOMASS AND  
BIODIVERSITY IN MINAS GERAIS: THE TEMPORAL AND SPATIAL CONTEXT**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, para a obtenção do título de Mestre.

APROVADA em 31 de março de 2021.  
Dra. Marcela de Castro Nunes Santos Terra – UFLA  
Dra. Aliny Aparecida dos Reis – UNICAMP

Prof. Dr. Fausto Weimar Acerbi Junior  
Orientador  
Dra. Eduarda Martiniano de Oliveira Silveira  
Dra. Marcela de Castro Nunes Santos Terra  
Coorientadoras

**LAVRAS - MG  
2021**

*À memória de Ademar e Francisco, meus queridos avôs.  
Dedico.*

## AGRADECIMENTOS

A Deus, porque não rejeitou as minhas orações e nunca me negou o seu amor (Salmos 66:20). Sem Ele, eu nada seria!

Aos meus pais, Osmária e José Luiz, pelo apoio e incentivo, não apenas dos últimos dois anos de mestrado, mas desde o dia em que escolhi a Engenharia Florestal. Obrigada por todo o esforço que fizeram e fazem por mim, eu devo tudo a vocês. Aos meus irmãos, Kaio e Lulu, e a todos os meus familiares pelo carinho e por sempre se alegrarem por minhas conquistas. Eu amo vocês e serei eternamente grata.

Ao meu orientador, Fausto, e coorientadoras, Eduarda e Marcela, pelo conhecimento compartilhado e por confiarem no meu trabalho. Se cheguei até aqui, foi porque me apoiei em ombros de gigantes.

A Vanessa, pois foi muito importante ter embarcado nessa aventura “em dupla”. Obrigada por estar no mesmo barco que eu, pelas tardes, noites e finais de semana estudando, pelos ouvidos emprestados aos meus desabafos, pelo consolo nos momentos de angústia e saudades de casa e, claro, pela amizade de longa data.

A Universidade Federal de Lavras e ao Departamento de Ciências Florestais pela oportunidade de me tornar Mestre em Engenharia Florestal. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pela concessão da bolsa de estudos durante o período do curso. E aos professores que contribuíram com minha formação acadêmica.

Aos amigos e colegas que fiz durante esses dois anos, aos companheiros de laboratório, e aos técnicos e demais funcionários do Laboratório de Estudos e Projetos em Manejo Florestal. Especialmente à Alisson, Luiz Otávio, Isaíra, Laís, Lorena, Maria, Inácio, Evandro, Rafael Menali, Flávio, Déborah, Celina, Luís Paulo, Dayane, Anny, Rapha, Daniel, Rafael Lucas e todos com quem tive contato durante esta etapa tão importante da minha vida. Obrigada pela companhia em todos os encontros (acadêmicos ou não), pelos momentos no sofá, pelas dicas e conselhos, pelos dias estudando biometria, pelos scripts compartilhados e dúvidas esclarecidas. Vocês também fizeram parte dessa jornada.

A Anna Clara, pois depois de tantos anos, pudemos morar na mesma cidade ao mesmo tempo mais uma vez. Obrigada por ter sido refúgio e família para mim em Lavras, Nina.

A Maísa, minha colega de apartamento, pela convivência e pelas longas conversas filosóficas sobre tantos assuntos aleatórios. Foi muito bom dividir essa fase contigo também.

A Andressa e Olímpia, minhas amigas de infância, e aos amigos que ganhei durante a graduação, Maicon, Luma, Mari e Monalisa, que mesmo longe se fizeram presentes através de uma mensagem, vídeo ou ligação e sempre torceram por mim.

E finalmente, a todas as pessoas que colaboraram e seguraram as minhas mãos para que eu chegasse até aqui.

De todo o meu coração, muito obrigada!

## RESUMO GERAL

O monitoramento da vegetação em grandes extensões territoriais é imprescindível para a definição de estratégias de manejo e conservação dos serviços ecossistêmicos, e o sensoriamento remoto por satélite consiste em uma ferramenta valiosa para essa tarefa. Neste sentido, é fundamental o desenvolvimento de métodos de modelagem baseados em variáveis de sensoriamento remoto que forneçam estimativas confiáveis de parâmetros da vegetação, como biomassa e biodiversidade arbórea, com rapidez e a baixo custo. Neste trabalho foram propostos e avaliados o desempenho preditivo de modelos de florestas aleatórias baseados em variáveis espaciais e temporais derivadas do Índice de Vegetação Melhorado (EVI) e da Temperatura da Superfície Terrestre (LST) para estimar a biomassa arbórea acima do solo (AGB) e a diversidade de espécies de árvores (TSD) nas florestas tropicais de Minas Gerais, Brasil. Essa dissertação está dividida em duas partes. Na primeira parte (Introdução Geral), buscou-se situar o leitor diante dos objetivos da pesquisa, fazendo uma abordagem teórica sobre os temas trabalhados. Na segunda parte foram apresentados dois artigos. No artigo 1 (Índices Anuais de Sensoriamento Remoto na Modelagem da Biomassa e Biodiversidade Arbórea em Minas Gerais), foram utilizadas imagens do sensor MODIS para modelar a AGB e a TSD a partir da variação temporal ao longo do ano nos valores do EVI e da LST. No artigo 2 (Métricas Texturais na Modelagem da Biomassa e da Biodiversidade Arbórea em Minas Gerais), foram utilizadas imagens do sensor TM, a bordo do Landsat 5, para modelar a AGB e a TSD a partir da variação espacial do EVI e da LST nas áreas estudadas. De modo geral, em ambos os artigos, os resultados indicam que o desempenho dos modelos de predição é afetado principalmente pelo grau de complexidade da estrutura da vegetação.

**Palavras-chave:** Produtividade. Temperatura. Random Forests.



## GENERAL ABSTRACT

Monitoring vegetation over large territorial extensions is essential to define management strategies for ecosystem services conservation, and remote sensing by satellite is a valuable tool for this task. In this sense, it is essential to develop modeling methods based on remote sensing variables that provide reliable estimates of vegetation parameters, such as aboveground biomass and tree biodiversity, quickly and at low cost. In this work, the predictive performance of random forest models, based on spatial and temporal variables derived from the enhanced vegetation index (EVI) and the land surface temperature (LST), was evaluated to estimate the aboveground biomass (AGB) and the tree species diversity (TSD) in the tropical forests of Minas Gerais, Brazil. This dissertation is divided into two parts. In the first part (General Introduction), we tried to situate the reader in front of the research objectives, making a theoretical approach on the themes worked. In the second part, two articles were presented. In article 1 (Annual Indices of Remote Sensing for Modeling Aboveground Biomass and Biodiversity in Minas Gerais), images from the MODIS sensor were used to model AGB and TSD based on the time variation over the year in the values of EVI and LST. In Article 2 (Textural Metrics for Modeling Aboveground Biomass and Biodiversity in Minas Gerais), TM sensor images were used on board Landsat 5 to model AGB and TSD from the spatial variation of EVI and LST in the studied areas. In general, in both articles, the results indicate that the performance of the prediction models is mainly affected by the degree of complexity of the vegetation structure.

**Keywords:** Productivity. Temperature. Random Forests.

## SUMÁRIO

<b>PRIMEIRA PARTE</b> .....	11
<b>1 INTRODUÇÃO GERAL</b> .....	12
<b>2 REFERENCIAL TEÓRICO</b> .....	14
<b>2.1 Aprendizagem de Máquina para Modelagem da Biomassa e da Biodiversidade</b> .....	14
<b>2.2 Sensoriamento Remoto para Modelagem da Biomassa e da Biodiversidade</b>	18
<b>3 CONSIDERAÇÕES FINAIS</b> .....	23
<b>SEGUNDA PARTE – ARTIGOS</b> .....	31
<b>ARTIGO 1 – ÍNDICES ANUAIS DE SENSORIAMENTO REMOTO NA MODELAGEM DA BIOMASSA E BIODIVERSIDADE ARBÓREA EM MINAS GERAIS</b> .....	32
<b>1 INTRODUÇÃO</b> .....	34
<b>2 MATERIAL E MÉTODOS</b> .....	36
<b>2.1 Área de Estudo</b> .....	37
<b>2.2 Inventário Florestal: Biomassa e Biodiversidade</b> .....	38
<b>2.3 Índices de Sensoriamento Remoto</b> .....	39
<b>2.4 Análises Exploratórias</b> .....	40
<b>2.5 Modelagem da Biomassa e da Biodiversidade</b> .....	41
<b>3 RESULTADOS</b> .....	42
<b>3.1 Padrões de Biomassa, Biodiversidade e ISR em Minas Gerais</b> .....	42
<b>3.2 Random Forest</b> .....	43
<b>4 DISCUSSÃO</b> .....	48
<b>5 CONCLUSÃO</b> .....	52
<b>REFERÊNCIAS</b> .....	53
<b>APÊNDICE A – Material Suplementar</b> .....	58
<b>ARTIGO 2 – MÉTRICAS TEXTURAIS NA MODELAGEM DA BIOMASSA E DA BIODIVERSIDADE ARBÓREA EM MINAS GERAIS</b> .....	60
<b>1 INTRODUÇÃO</b> .....	62
<b>2 MATERIAL E MÉTODOS</b> .....	65
<b>2.1 Área de Estudo</b> .....	65
<b>2.2 Base de Dados</b> .....	67
<b>2.2.1 Medições de Campo</b> .....	67

2.2.2	Variáveis de Sensoriamento Remoto.....	68
2.3	<b>Análises Exploratórias</b> .....	70
2.4	<b>Modelagem de Biomassa e Biodiversidade da Vegetação</b> .....	71
3	<b>RESULTADOS</b> .....	73
3.1	<b>Análises Exploratórias das Texturas das Imagens, Biomassa e Diversidade</b> 73	
3.2	<b>Heterogeneidade da Vegetação Capturada pelas Métricas Texturais</b> .....	75
3.3	<b>Random Forests</b> .....	76
4	<b>DISCUSSÃO</b> .....	79
4.1	<b>Métricas Texturais de Produtividade e Temperatura e a Biomassa e a Diversidade</b> .....	79
4.2	<b>Avaliação dos Modelos Random Forests de Biomassa e Diversidade</b> .....	80
5	<b>CONCLUSÃO</b> .....	83
	<b>REFERÊNCIAS</b> .....	84
	<b>APÊNDICE A – Material Suplementar</b> .....	91
	<b>APÊNDICE B – Material Suplementar</b> .....	93

**PRIMEIRA PARTE**

## 1 INTRODUÇÃO GERAL

O planeta Terra abriga 4,06 bilhões de hectares de florestas nativas, dos quais 45% ocorrem em domínios de climas tropicais ( FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO, 2020). A conservação das florestas tropicais é fundamental à manutenção de diferentes funções ecossistêmicas essenciais à vida, tais como abrigar parte significativa da biodiversidade global, sequestrar carbono da atmosfera, proteger o solo e os recursos hídricos e fornecer serviços sociais. Apesar disso, no Brasil, o avanço das fronteiras agrícolas, resultante de práticas de desmatamento ilegal, é um dos principais fatores responsáveis por intensificar os processos de fragmentação florestal. Diante do cenário alarmante de contínua perda de habitat da fauna e flora silvestre e de redução do estoque de carbono presente na biomassa viva das florestas nativas brasileiras, o desenvolvimento de métodos que viabilizem o acesso a informações úteis para o monitoramento de parâmetros da vegetação é indispensável à definição e implementação de políticas de conservação e estratégias sustentáveis de utilização dos recursos florestais.

Os inventários florestais consistem na ferramenta tradicionalmente utilizada para se obter informações confiáveis sobre a vegetação, como estimativas da biomassa arbórea acima do solo e da diversidade de espécies de árvores. Geralmente, em grandes áreas, os inventários florestais são desenvolvidos por meio da definição de um método de amostragem, e a partir das campanhas de campo, as informações amostrais obtidas são extrapoladas através de técnicas estatísticas. Sendo assim, além de serem suscetíveis a erros de amostragem e não amostragem, os inventários florestais tradicionais possuem custo elevado, pois são dependentes das atividades de campo, que demandam grande disponibilidade de recursos, como tempo e mão de obra qualificada. Neste contexto, os procedimentos de mensuração de parâmetros florestais baseados em dados de sensoriamento remoto por satélite surgem como uma alternativa mais viável e muito valiosa para o monitoramento da vegetação em áreas extensas, como em níveis regionais e globais.

Nas últimas décadas, os avanços nas tecnologias de sensoriamento remoto disponibilizaram uma ampla gama de produtos, a partir dos quais, é possível extrair informações capazes de descrever características da vegetação, para complementar a base de dados de inventários de campo e prever parâmetros florestais ao longo do tempo e do espaço (DUBE; MUTANGA, 2016; HOGGLAND et al., 2020; MADONSELA et al., 2017; MURA et al., 2018; ROCCHINI et al., 2018). Por outro lado, a determinação do conjunto ideal de preditores para compor um modelo, visando explicar maior quantidade da variação nas

variáveis dependentes e, conseqüentemente, alcançar melhores desempenhos, é um dos pontos mais críticos dos processos de modelagem, e deve ser considerado cuidadosamente, pois a qualidade do ajuste depende, dentre outros fatores, das relações entre as variáveis do conjunto de treinamento. Paralelamente, graças aos esforços desenvolvidos na área da computação, os processos de modelagem podem ser implementados a partir de algoritmos com excelentes capacidades de aprendizado. Os algoritmos de aprendizagem de máquina possuem habilidade suficiente para modelar conjuntos de dados complexos, podem aceitar múltiplas classes de preditores de entrada e dispensam suposições sobre a distribuição de dados, pois não são paramétricos (MAXWELL; WARNER; FANG, 2018).

O algoritmo de Florestas Aleatórias (RF, do inglês *Random Forests*) desenvolvido por Leo Breiman (BREIMAN, 2001), por exemplo, têm sido cada vez mais aplicado em estudos de modelagem baseados em variáveis espectrais e ambientais, demonstrando sua eficiência em prever diferentes características florestais a partir de conjuntos de dados derivados de múltiplas fontes (FRANKLIN; AHMED, 2017; REIS et al., 2018; SILVEIRA et al., 2019a; VINCENZI et al., 2011; ZHANG et al., 2019). Além disso, é válido ressaltar que o RF também pode ser utilizado durante a fase de mineração de dados, por meio do procedimento de remoção recursiva, que de forma iterativa seleciona o conjunto de variáveis de maior valor de importância para a modelagem (PULLANAGARI; KERESZTURI; YULE, 2018; REIS et al., 2018). Portanto, com base no exposto, ressalta-se a importância do desenvolvimento de estudos que considerem os contextos temporal e espacial de dados de sensoriamento remoto, representativos dos aspectos bioclimáticos da vegetação, em modelos RF de predição de biomassa e diversidade arbórea em florestas tropicais.

Nesta dissertação, o objetivo é utilizar variáveis temporais e espaciais derivadas do índice de vegetação melhorado e da temperatura da superfície terrestre para modelar a biomassa arbórea acima do solo e a diversidade de espécies de árvores em Minas Gerais. Para isto, foram desenvolvidos 2 artigos. No artigo 1, para englobar o contexto temporal, foram utilizados Índices de Sensoriamento Remoto (ISR) derivados de estatísticas anuais dos produtos do sensor MODIS. No artigo 2, foram utilizadas métricas texturais de imagens do sensor TM a bordo do Landsat 5 visando englobar o aspecto espacial.

## 2 REFERENCIAL TEÓRICO

### 2.1 Aprendizagem de Máquina para Modelagem da Biomassa e da Biodiversidade

Os ecossistemas florestais desempenham um importante papel nos ciclos biogeoquímicos que regulam a vida na Terra e influenciam a condução das mudanças ambientais e climáticas numa escala global (LU et al., 2016). Diante do atual cenário de perdas de ecossistemas naturais (LIANG et al., 2016), estudos relacionados ao monitoramento, detecção e mapeamento de mudanças ambientais (ACERBI JÚNIOR et al., 2015; BUENO et al., 2019; REZENDE et al., 2018; SILVEIRA et al., 2019b), bem como à obtenção de estimativas de parâmetros florestais como biomassa e biodiversidade (GHOLIZADEH et al., 2018; JETZ et al., 2016; RIBEIRO et al., 2011; SILVEIRA et al., 2019c, 2020), dão suporte ao Manejo Florestal Sustentável, à conservação e à manutenção dos serviços prestados.

As estimativas da biomassa por unidade de área são muito utilizadas para avaliar a capacidade de armazenamento e a quantidade de carbono emitido à atmosfera, na forma de gases ( $\text{CO}_2$ ,  $\text{CO}$  e  $\text{CH}_4$ ) causadores do efeito estufa (GEE), por consequência das atividades de supressão da vegetação e modificação do uso do solo (HOUGHTON; HALL; GOETZ, 2009; ROQUETTE, 2018; SILVEIRA et al., 2020). Essas estimativas são utilizadas pela política de Redução de Emissões por Desmatamento e Degradação Florestal (REDD+), conjunto de incentivos econômicos integrantes do Protocolo de Kyoto (DJOMO et al., 2010). A biomassa também está associada ao ciclo global do carbono, à ciclagem de nutrientes pela vegetação e à produtividade florestal (ABREU et al., 2016; HOUGHTON; HALL; GOETZ, 2009; LU, 2005), podendo ser, portanto, considerada um indicador ecológico de sustentabilidade, por estar relacionada à biodiversidade (HOUGHTON; HALL; GOETZ, 2009).

A associação entre biomassa e biodiversidade tem sido amplamente estudada (LIANG et al., 2016; YANG et al., 2019). Miguel et al. (2015), por exemplo, explicaram que a degradação ou a conversão de ecossistemas naturais para outras formas de uso do solo resultam na fragmentação dos ambientes, e segundo Silveira et al. (2020), a perda de biomassa está intrinsecamente ligada à elevadas perdas de biodiversidade. Jetz et al. (2016) relataram que a partir de informações sobre a funcionalidade e diversidade de comunidades vegetais é possível monitorar, entender e prever a produtividade dos ecossistemas. Apesar dos esforços científicos, muitos pesquisadores não veem a avaliação da biodiversidade como uma tarefa fácil, uma vez que inclui estruturas e processos que variam nas escalas temporal e espacial, e apresentam

diferentes níveis de organização biológica, do genético ao ecossistêmico (GHOLIZADEH et al., 2018; JETZ et al., 2016; ROCCHINI et al., 2018; VAN DER SANDE et al., 2017).

A abordagem mais comum é medir a biodiversidade composicional, pois presume-se que as diversidades estrutural e funcional dos ecossistemas, de alguma forma, refletem no número de espécies presentes (DUELLI; OBRIST, 2003). Na fitossociologia, os índices de diversidade de espécies estão entre os componentes mais importantes na caracterização das comunidades (THUKRAL, 2017) e, dentre os índices mais conhecidos está o índice alfa de Fisher (MAGURRAN, 1988). O alfa de Fisher é capaz de captar o grau de diversidade de uma população a partir da classificação dos indivíduos em grupos, como grupos de espécies, por exemplo, não apresenta restrições quanto ao número de indivíduos que compõe a amostra, discrimina bem entre comunidades e permite a comparação entre as parcelas amostradas (COLWELL, 2009; MAGURRAN, 2004; SIMPSON, 1949).

Dada a complexidade dos processos dinâmicos que ocorrem entre e dentro dos ecossistemas florestais (MORO et al., 2016; RIBEIRO et al., 2011; SANTOS et al., 2011; TERRA et al., 2018), é importante a execução de pesquisas voltadas ao desenvolvimento e aperfeiçoamento de estratégias que facilitem o entendimento e a identificação dos fatores determinantes dos padrões de biomassa e biodiversidade. Normalmente, os métodos para obtenção de estimativas de parâmetros florestais são dependentes de modelagem a partir de dados de inventários de campo. Todavia, as campanhas de campo para coleta de dados, frequentemente estão associadas a problemas logísticos, uma vez que envolvem alta disponibilidade recursos (GHOSH; BEHERA, 2018; ROCCHINI et al., 2018). Neste sentido, modelos preditivos dos parâmetros da vegetação, baseados em dados de sensoriamento remoto, se apresentam como uma alternativa promissora em estudos sobre a biomassa e a biodiversidade, e são fundamentais para a compreensão dos efeitos resultantes dos estresses causados por mudanças climáticas e antrópicas, pois podem fornecer informações em largas extensões territoriais.

Não obstante, a escolha de preditores adequados, diante da grande abundância de dados contemporâneos, é uma das tarefas mais difíceis associadas à construção dos modelos de predição, pois envolve a utilização de técnicas de mineração de dados, que englobam métodos para selecionar variáveis capazes de explicar o máximo possível das variações na variável de interesse (JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015). Para Adame-Campos et al. (2019), em relação à utilização de variáveis obtidas a partir de imagens de satélites para modelar parâmetros ambientais, a escolha de um bom conjunto preditor é determinante na precisão da estimativa da biomassa arbórea acima do solo. Schindler et al. (2015), estudando o desempenho de métodos



de seleção de variáveis para modelagem da riqueza de espécies, também concordam que a identificação prévia de indicadores apropriados é uma condição ao desenvolvimento de modelos com bom desempenho preditivo. Além disso, a seleção de variáveis adequadas promove a melhor visualização e compreensão dos dados, a redução da capacidade de armazenamento e processamento, a atenuação do efeito da maldição da dimensionalidade e o maior desempenho do sistema preditor (CHANDRASHEKAR; SAHIN, 2014; GUYON; ELISSEEFF, 2003).

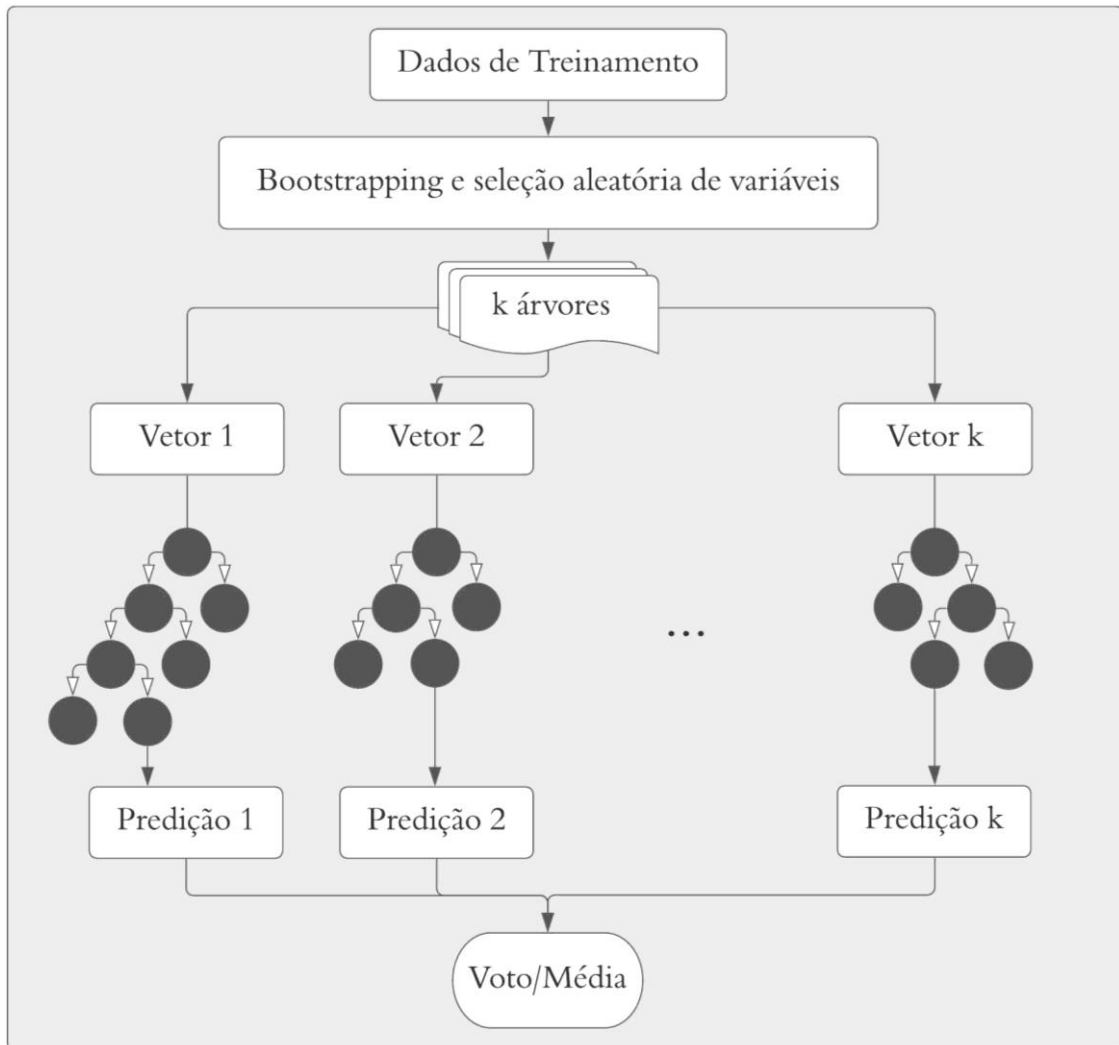
Os métodos de seleção de variáveis podem ser classificados de diversas formas, porém uma divisão científica muito comum consiste na separação em: *Filter*, *Wrapper* e *Embedded* (CHANDRASHEKAR; SAHIN, 2014; GUYON; ELISSEEFF, 2003). Os métodos do tipo *Filter* frequentemente são utilizados na etapa de pré-processamento (STAŃCZYK, 2015). Por meio destes, as variáveis explicativas são selecionadas com base em um critério de desempenho (ganho de informação, similaridade, consistência, distância ou estatístico), independentemente do algoritmo de modelagem empregado, por processos de regressão, classificação ou agrupamento (JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015). Um critério de desempenho muito utilizado para seleção de variáveis é o coeficiente de Correlação de Pearson, considerado um dos métodos mais simples de filtragem, é capaz de detectar a existência de relações de dependências lineares entre pares de variáveis individuais (CHANDRASHEKAR; SAHIN, 2014; GUYON; ELISSEEFF, 2003).

Os métodos *Wrapper* avaliam o desempenho de subconjuntos de variáveis preditoras em um algoritmo de modelagem (JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015), ou seja, utilizam aprendizagem de máquina para avaliar o poder preditivo dos subconjuntos gerados, o que os tornam métodos simples e universais (GUYON; ELISSEEFF, 2003). Stańczyk (2015) explicou que *Wrappers* tendem a construir subconjuntos personalizados, adaptados às condições de treinamento às quais foram submetidos. Já os métodos *Embedded* possuem mecanismos embutidos no algoritmo de aprendizado capazes de selecionar variáveis durante a execução, como parte do processo de treinamento, o que aumenta a eficiência em relação ao uso dos dados disponíveis e à redução do tempo de busca pela solução (CHANDRASHEKAR; SAHIN, 2014; GUYON; ELISSEEFF, 2003; JOVIĆ; BRKIĆ; BOGUNOVIĆ, 2015; STAŃCZYK, 2015).

Neste contexto, o algoritmo de Florestas Aleatórias (RF, do inglês *Random Forests*), desenvolvido por Breiman (2001), tem sido utilizado tanto como método *Wrapper*, quanto como *Embedded* em diferentes abordagens para seleção de variáveis (RODRIGUEZ-GALIANO et al., 2018). Sumariamente, o RF consiste em um conjunto de classificadores do tipo árvores de decisão aleatórias definidos por  $h(\mathbf{x}, \Theta_k)$ , com  $k = 1, \dots$ , sendo:  $\Theta_k$  vetores

independentes, com distribuição idêntica, gerados aleatoriamente que governam o crescimento da árvore; e  $\mathbf{x}$  o vetor contendo todas as variáveis de entrada. Assim, depois que várias árvores são formadas, cada árvore  $k$  retorna um voto unitário para a classe mais popular em termos de classificação, ou a média para regressão (Figura 1) (BREIMAN, 2001; JAMES et al., 2013; WANG, J. et al., 2019).

Figura 1 – Esquemática simplificada do funcionamento do *Random Forests*.



Fonte: Adaptado de Rodriguez-Galiano et al. (2016).

O RF é baseado no princípio da decorrelação entre as árvores de decisão, permitindo a redução da variância e a obtenção de resultados mais confiáveis (BREIMAN, 2001; JAMES et al., 2013). É demasiadamente utilizado em estudos florestais tanto por sua capacidade de selecionar e classificar as variáveis de maior valor de importância, como por fornecer modelos mais precisos e menos sensíveis à ruídos nos dados de entrada, quando comparado a outros algoritmos de modelagem baseados em árvores (BACCINI et al., 2004; BUENO et al., 2019;

CARVALHO, 2019; MUTANGA; ADAM; AZONG CHO, 2012; SCHWIEDER et al., 2018; SILVEIRA et al., 2019b, 2019a, 2019c).

Um dos maiores desafios relatados em estudos de modelagem, a partir de dados de sensoriamento remoto, é definir o conjunto de preditores e o algoritmo de modelagem adequados para a obtenção de estimativas confiáveis de biomassa (LU et al., 2016). E, conseqüentemente, a partir das características do habitat, medidas remotamente, também acessar as variações espaciais de biodiversidade (HERNÁNDEZ-STEFANONI et al., 2012). Entretanto, a utilização do algoritmo de RF e de conjuntos de dados de sensoriamento remoto, sumarizados ao longo do tempo (RADELOFF et al., 2019) e do espaço (FARWELL et al., 2020), sobre os aspectos biofísicos da superfície terrestre, pode ser uma metodologia promissora para modelagem de parâmetros da vegetação.

## **2.2 Sensoriamento Remoto para Modelagem da Biomassa e da Biodiversidade**

O sensoriamento remoto é definido como a ciência que visa a obtenção de imagens da superfície da Terra, por meio da detecção e medição quantitativa dos resultados das interações entre a radiação eletromagnética e os objetos terrestres (MENESES; ALMEIDA, 2012), ou seja, a resposta espectral. Há mais de 150 anos, cientistas vêm desenvolvendo técnicas para coletar e analisar dados de sensoriamento remoto (JENSEN, 2015), que cada vez mais, têm se mostrado uma ferramenta eficiente para monitorar fenômenos ambientais (BEZERRA et al., 2014) e tem sido amplamente utilizada em projetos e pesquisas relacionados à vegetação (AGARWAL et al., 2016; MATASCI et al., 2018; MENG et al., 2016; SILVEIRA et al., 2019a).

De acordo com Adame-Campos et al. (2019), muitas variáveis biofísicas, espectrais e texturais podem ser adquiridas a partir de dados de sensoriamento remoto. A possibilidade de quantificar variações na resposta espectral, graças às diferentes propriedades bioquímicas, estruturais ou fenológicas das plantas, permite que pesquisadores utilizem métricas espectrais em estudos de modelagem da biodiversidade (GHOLIZADEH et al., 2018; JETZ et al., 2016; RADELOFF et al., 2019) e da biomassa arbórea acima do solo a partir de imagens de satélite e amostras de campo (ADAME-CAMPOS et al., 2019; LU et al., 2016).

Muitas vezes, a interpretação quantitativa das informações de sensoriamento remoto da vegetação é considerada uma tarefa desafiadora e alguns estudos são baseados apenas em bandas individuais ou em um conjunto delas (XUE; SU, 2017), o que caracteriza as abordagens que frequentemente assumem modelos estatísticos baseados em índices de vegetação, por sua simplicidade e confiabilidade (WANG, G. et al., 2019). Os índices de vegetação consistem em

medições radiométricas adimensionais que indicam a quantidade e a atividade da vegetação verde, incluindo o índice de área foliar, cobertura vegetal, conteúdo de clorofila, biomassa verde, radiação fotossinteticamente ativa absorvida (JENSEN, 2015), vigor, dinâmica de crescimento e outras (XUE; SU, 2017).

O Índice de Vegetação Melhorado (EVI, do inglês *Enhanced Vegetation Index*), por exemplo, desenvolvido por pesquisadores do MODIS *Land Discipline Group*, possui boa sensibilidade em florestas muito densas, com grande aporte de biomassa, e ainda minimiza as influências do solo e da atmosfera (JIANG et al., 2008). O EVI é calculado a partir dos níveis de reflectância da vegetação nas bandas do infravermelho próximo ( $\rho_{IVP}$ ), vermelho ( $\rho_V$ ) e azul ( $\rho_A$ ), e conta com fatores de correção para o espalhamento atmosférico ( $C_1$  e  $C_2$ ) e um fator de ajuste dos solos ( $L$ ) (Equação 1) (JENSEN, 2015; JIANG et al., 2008). Os valores de  $C_1$ ,  $C_2$  e  $L$  são determinados empiricamente e correspondem a 6,0, 7,5 e 1,0, respectivamente (JENSEN, 2015; XUE; SU, 2017).

$$EVI = 2,5 \frac{(\rho_{IVP} - \rho_V)}{(\rho_{IVP} + C_1 * \rho_V - C_2 * \rho_A + L)} \quad (1)$$

Muitos estudos comprovam a eficiência do uso de dados de sensoriamento remoto na modelagem de características da vegetação, como diversidade e biomassa. Entre os quais destacam-se os de Dube e Mutanga (2016), onde os autores verificaram que a integração entre dados multiespectrais e variáveis ambientais forneceram estimativas precisas e confiáveis da biomassa arbórea acima do solo em florestas densas. Já os resultados de Barbosa et al. (2014) indicaram que a utilização de bandas espectrais na região do infravermelho médio e variáveis geomorfométricas podem melhorar as estimativas de biomassa em áreas montanhosas. Silveira et al. (2019b) também usaram dados de sensoriamento remoto, em conjunto com variáveis ambientais e relacionadas ao terreno, para modelar a biomassa arbórea em remanescentes florestais da Mata Atlântica em Minas Gerais.

Em relação à biodiversidade, Gholizadeh et al. (2018) concluíram que métricas de sensoriamento remoto têm o potencial de prever a riqueza de espécies por meio da quantificação da variação na resposta espectral da vegetação. Rocchini et al. (2018) sugeriram a utilização de métodos multivariados e multidimensionais baseados na resposta espectral para otimizar medidas de diversidade  $\beta$  a partir de dados coletados remotamente. Waring et al. (2006) afirmaram que índices de vegetação de sensoriamento remoto, como o EVI, ofereceram estimativas da produtividade equivalentes ou superiores àquelas obtidas por amostragem no

campo ou por modelos baseados em processos, dependentes de extrapolação de dados climáticos e fisiográficos.

Apesar de constatada a eficácia dos índices de vegetação em avaliações quantitativas e qualitativas das características da cobertura vegetal (XUE; SU, 2017), autores apontam que sua utilização em combinação com conjuntos de dados climáticos podem promover resultados melhores em relação a predição de padrões de diversidade (SAATCHI et al., 2008). Por outro lado, o problema é que, normalmente, conjuntos de dados climáticas são baseados em interpolações e, portanto, podem apresentar vieses inerentes a quantidade e a localização das estações meteorológicas (RADELOFF et al., 2019). Todavia, nas últimas décadas, conjuntos de dados globais da temperatura da superfície terrestre (LST, do inglês *Land Surface Temperature*) têm sido registrados por meio de sensoriamento remoto por satélite (PEDE; MOUNTRAKIS, 2018) e pesquisadores já sugeriram a utilização da LST para estimar precisamente a temperatura do ar próximo à superfície terrestre (YANG; CAI; YANG, 2017).

Outro aspecto interessante em relação a utilização de dados de sensoriamento é a possibilidade de construção de métricas resumidas ao longo do tempo. Recentemente, Radeloff et al. (2019) afirmaram que índices de dinâmica de habitat (DHI, do inglês *Dynamic Habitat Indices*), compostos de estatísticas anuais de dados de vegetação do sensor MODIS, são relevantes para o estudo da biodiversidade, pois apresentaram boa correlação com a riqueza de espécies de animais, e podem ser úteis para o planejamento da conservação de habitats naturais mundialmente. Os DHI foram inicialmente propostos por Mackey, Bryan e Randall (2004) para o continente australiano. Em seguida, DHI derivados de séries temporais do NDVI (*Normalized Difference Vegetation Index*) foram utilizados para obtenção de informações sobre a dinâmica de disponibilidade de habitat para a fauna dispersiva (BERRY; MACKKEY; BROWN, 2007). Posteriormente, DHI baseados em séries temporais de observações de satélite da fPAR (*Fraction of Photosynthetically Active Radiation*) foram atualizados para a América do Norte (COOPS et al., 2008, 2009; COOPS; WULDER; IWANICKA, 2009), e os resultados também demonstraram forte relação entre os DHI e os padrões de variação da riqueza de espécies de aves. Desde então, a relação entre os DHI e os padrões de biodiversidade, relacionados à dinâmica da produtividade vegetal, tem sido bastante estudada (ANDREW et al., 2012; COOPS et al., 2018; HOBI et al., 2017; RADELOFF et al., 2019), pois as pesquisas anteriores sobre sua aplicabilidade mostraram que eles se correlacionam bem com a riqueza de espécies em estudos regionais e globais.

Os estudos de Radeloff et al. (2019) consideraram DHI que fornecem medidas integradas: a) da produtividade anual acumulada da vegetação; b) do nível mínimo de cobertura

vegetal; e c) do grau de sazonalidade anual (BERRY; MACKEY; BROWN, 2007; MACKEY; BRYAN; RANDALL, 2004) para avaliar teorias ecológicas baseadas na disponibilidade de energia, no estresse ambiental e na estabilidade ambiental, respectivamente. Logo, os DHI representam um novo conjunto de dados de sensoriamento remoto e são uma alternativa aos índices simples de vegetação, por exemplo, pois permitem a mensuração da produtividade vegetal ao longo do ano, oferecendo uma oportunidade para examinar padrões geográficos de características ambientais, particularmente relevantes para a biodiversidade (BERRY; MACKEY; BROWN, 2007; COOPS et al., 2018; RADELOFF et al., 2019). Wu e Liang (2018), por exemplo, desenvolveram um índice de biodiversidade baseado na integração multivariada de métricas de sensoriamento remoto altamente correlacionadas, incluindo os DHI, que explicou 20% a mais da variação global da riqueza de espécies de mamíferos, pássaros e anfíbios, quando comparado a métricas univariadas.

Além do contexto temporal, abordado anteriormente, a partir de dados de sensoriamento remoto também é possível analisar as propriedades texturais das imagens. As variáveis texturais descrevem as relações espaciais entre pixels vizinhos e indicam diretamente a variabilidade espacial dos níveis de reflectância em uma banda da imagem (HARALICK; SHANMUGAM; DINSTEIN, 1973). Muitos estudos apresentam diferentes abordagens (semivariogramas, dimensão fractal, *wavelet* e outras) para caracterização da textura das imagens de sensoriamento remoto, porém as medidas mais utilizadas são derivadas da Matriz de Coocorrência de Nível de Cinza (GLCM, do inglês *Grey Level Co-occurrence Matrix*) (HALL-BEYER, 2017; LU et al., 2016).

Os cálculos para obtenção das texturas derivadas da GLCM usados em sensoriamento remoto foram estruturados, em sua maioria, nos anos 70 (HARALICK, 1979; HARALICK; SHANMUGAM; DINSTEIN, 1973), e dividem-se em funções definidas por medidas estatísticas de primeira (ocorrência) e segunda ordem (coocorrência) (HOFMANN et al., 2017). As texturas de primeira ordem, como média, desvio padrão e variância, por exemplo, não consideram as relações entre pixels e consistem em estatísticas resumidas, que são calculadas a partir dos valores da imagem original; enquanto as texturas de segunda ordem consideram a relação entre dois pixels (referência e vizinho) a partir da probabilidade de ocorrência conjunta dos valores dos pixels que estão a determinada distância e orientação entre si (FARWELL et al., 2020; HALL-BEYER, 2017; HOFMANN et al., 2017).

Alguns pesquisadores relataram que as texturas compõem um importante grupo de variáveis de sensoriamento remoto para a modelagem da biomassa acima do solo, podendo apresentar relações mais fortes com a biomassa em sítios florestais de estrutura complexa em

comparação às bandas espectrais originais (GAO et al., 2018; LU; BATISTELLA, 2005). Por outro lado, em florestas secundárias, com vegetação em diferentes estágios sucessionais, as texturas tendem a suavizar as diferenças entre as características espectrais do dossel, resultando em relações pobres com a biomassa (LU; BATISTELLA, 2005). Já em relação à biodiversidade, outros autores demonstraram que métricas de textura de imagens de satélite, uma vez que refletem a heterogeneidade espacial, podem indicar padrões de diversidade e riqueza de espécies (FARWELL et al., 2020; HOFMANN et al., 2017) e caracterizar até 70% da diversidade da altura da folhagem e estrutura horizontal da vegetação (WOOD et al., 2012). Todavia, apesar dos estudos citados e de Hernández-Stefanoni et al. (2012) terem afirmado que dados espectrais e de textura podem ser usados como substitutos da produtividade e da estrutura da vegetação, pois capturam uma ampla gama da variação ambiental na paisagem e podem auxiliar a compreensão sobre a manutenção da diversidade em diferentes áreas, para Farwell et al. (2020), a complexidade da relação entre a heterogeneidade do habitat e a diversidade de espécies ressalta a necessidade de investigações mais profundas sobre o tema, considerando diferentes níveis espaciais e os contextos dentro e entre habitats.

Nota-se, portanto, que dados de sensoriamento remoto são poderosos para caracterizar a vegetação em diferentes extensões espaciais e temporais. Todavia, dados são registrados em resoluções espaciais, temporais e espectrais específicas, o que implica em desafios e suposições que são determinantes no que se refere a como devem ser utilizados em estudos sobre a biomassa e a biodiversidade florestal (LU et al., 2016; PETTORELLI et al., 2016). Portanto, fica evidente a importância do desenvolvimento de estudos que preencham a lacuna científica quanto a utilização combinada de métricas anuais da produtividade e sazonalidade dos habitats para melhorar os resultados da modelagem da biodiversidade (RADELOFF et al., 2019); bem como, a que está relacionada a capacidade potencial das imagens texturais de caracterizar a estrutura vertical e horizontal de diferentes tipos de vegetação (WOOD et al., 2012) e, conseqüentemente, aumentar a precisão das estimativas de biomassa, uma vez que consiste em uma metodologia que ainda não recebeu a devida atenção (LU et al., 2016).

### **3 CONSIDERAÇÕES FINAIS**

Biomassa e biodiversidade florestal são parâmetros essenciais ao monitoramento da vegetação. Apesar da alta demanda por recursos, associada a coleta de dados de campo em inventários florestais de grandes áreas, o sensoriamento remoto surge como uma ferramenta complementar, capaz de fornecer uma ampla gama de produtos com potencial de caracterizar diferentes tipos de vegetação. Todavia, observa-se que o desenvolvimento de métodos para a obtenção de estimativas de biomassa e biodiversidade, a partir de modelos de florestas aleatórias baseados apenas em variáveis derivadas de dados de sensoriamento remoto sumarizados no tempo e no espaço, representativos dos aspectos de produtividade e do clima, em fitofisionomias tropicais, ainda é um tema pouco abordado e carece de estudos científicos.



## REFERÊNCIAS

- ABREU, J. C. DE et al. Ajuste de modelos matemáticos lineares e não lineares para estimativa de biomassa e nutrientes de *Anadenanthera colubrina* var. *cebil* no semiárido pernambucano. **Scientia Forestalis**, v. 44, n. 111, p. 739–750, 2016.
- ACERBI JÚNIOR, F. W. et al. Change Detection in Brazilian Savannas Using Semivariograms Derived From NDVI Images. **Ciencia e Agrotecnologia**, v. 39, n. 2, p. 103–109, 2015.
- ADAME-CAMPOS, R. L. et al. Variables selection for aboveground biomass estimations using satellite data: A comparison between relative importance approach and stepwise Akaike's information criterion. **International Journal of Geo-Information**, v. 8, n. 6, p. 1–23, 2019.
- AGARWAL, S. et al. Exploring the relationship between remotely-sensed spectral variables and attributes of tropical forest vegetation under the influence of local forest institutions. **International Journal of Geo-Information**, v. 5, n. 7, p. 1–16, 2016.
- ANDREW, M. E. et al. Beta-diversity gradients of butterflies along productivity axes. **Global Ecology and Biogeography**, v. 21, n. 2012, p. 352–364, 2012.
- BACCINI, A. et al. Forest biomass estimation over regional scales using multisource data. **Geophysical Research Letters**, v. 31, n. 10, p. 2–5, 2004.
- BARBOSA, J. M. et al. Remotely sensed biomass over steep slopes: An evaluation among successional stands of the Atlantic Forest, Brazil. **ISPRS International Journal of Photogrammetry and Remote Sensing**, v. 88, p. 91–100, 2014.
- BERRY, S.; MACKEY, B.; BROWN, T. Potential applications of remotely sensed vegetation greenness to habitat analysis and the conservation of dispersive fauna. **Pacific Conservation Biology**, v. 13, n. 2, p. 120–127, 2007.
- BEZERRA, J. M. et al. Parâmetros biofísicos obtidos por sensoriamento remoto em região semiárida do estado do Rio Grande do Norte, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 1, p. 73–84, jan. 2014.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.
- BUENO, I. T. et al. Object-based change detection in the cerrado biome using landsat time series. **Remote Sensing**, v. 11, n. 5, p. 1–14, 2019.
- CARVALHO, M. C. **ABORDAGENS DA INTELIGÊNCIA COMPUTACIONAL PARA QUESTÕES FLORESTAIS: CLASSIFICAÇÃO E REGRESSÃO VIA ALGORITMOS DE APRENDIZAGEM DE MÁQUINA**. [s.l.] Universidade Federal de Lavras, 2019.
- CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. **Computers and Electrical Engineering**, v. 40, p. 16–28, 2014.
- COLWELL, R. K. Biodiversity: Concepts, Patterns, and Measurement. In: LEVIN, S. A. (Ed.). **The Princeton Guide to Ecology**. New Jersey: Princeton University Press, 2009. p. 257–263.

COOPS, N. C. et al. The development of a Canadian dynamic habitat index using multi-temporal satellite estimates of canopy light absorbance. **Ecological Indicators**, v. 8, n. 5, p. 754–766, 2008.

COOPS, N. C. et al. Bird diversity: A predictable function of satellite-derived estimates of seasonal variation in canopy light absorbance across the United States. **Journal of Biogeography**, v. 36, n. 5, p. 905–918, 2009.

COOPS, N. C. et al. Remotely-sensed productivity clusters capture global biodiversity patterns. **Scientific Reports**, v. 8, p. 1–12, 2018.

COOPS, N. C.; WULDER, M. A.; IWANICKA, D. Exploring the relative importance of satellite-derived descriptors of production, topography and land cover for predicting breeding bird species richness over Ontario, Canada. **Remote Sensing of Environment**, v. 113, n. 3, p. 668–679, 2009.

DJOMO, A. N. et al. Allometric equations for biomass estimations in Cameroon and pan moist tropical equations including biomass data from Africa. **Forest Ecology and Management**, v. 260, n. 2010, p. 1873–1885, 2010.

DUBE, T.; MUTANGA, O. The impact of integrating WorldView-2 sensor and environmental variables in estimating plantation forest species aboveground biomass and carbon stocks in uMgeni Catchment, South Africa. **ISPRS International Journal of Photogrammetry and Remote Sensing**, v. 119, n. 2016, p. 415–425, 2016.

DUELLI, P.; OBRIST, M. K. Biodiversity indicators: the choice of values and measures. **Agriculture, Ecosystems and Environment**, v. 98, n. 2003, p. 87–98, 2003.

FARWELL, L. S. et al. Habitat heterogeneity captured by 30-m resolution satellite image texture predicts bird richness across the United States. **Ecological Applications**, v. 0, n. 0, p. 1–17, 2020.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **Global Forest Resources Assessment 2020: Key findings**. . Rome: FAO, 2020.

FRANKLIN, S. E.; AHMED, O. S. Object-based Wetland Characterization Using Radarsat-2 Quad-Polarimetric SAR Data, Landsat-8 OLI Imagery, and Airborne Lidar-Derived Geomorphometric Variables. 2017.

GAO, Y. et al. Comparative Analysis of Modeling Algorithms for Forest Aboveground Biomass Estimation in a Subtropical Region. **Remote Sensing**, v. 10, n. 4, p. 627, 18 abr. 2018.

GHOLIZADEH, H. et al. Remote sensing of biodiversity Soil correction and data dimension reduction methods improve assessment of  $\alpha$ -diversity (species richness) in prairie ecosystems. **Remote Sensing of Environment**, v. 206, n. 2018, p. 240–253, 2018.

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

GUYON, I.; ELISSEEFF, A. An Introduction to Variable and Feature Selection. **Journal of Machine Learning Research**, v. 3, n. 2003, p. 1157–1182, 2003.

HALL-BEYER, M. **GLCM TEXTURE: A TUTORIAL v. 3.0**. 3. ed. Calgary: PRISM - University of Calgary's Digital Repository Arts, 2017.

HARALICK, R. M. Statistical and Structural Approaches to Texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786–804, 1979.

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

HERNÁNDEZ-STEFANONI, J. L. et al. Modeling-and-diversity in a tropical forest from remotely sensed and spatial data. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, n. 2012, p. 359–368, 2012.

HOBBI, M. L. et al. A comparison of DHIs derived from different MODIS products as predictors of avian species richness. **Remote Sensing of Environment**, v. 195, n. 2017, p. 142–152, 2017.

HOFMANN, S. et al. Modelling patterns of pollinator species richness and diversity using satellite image texture. **PLOS ONE**, v. 12, n. 10, p. 1–17, 3 out. 2017.

HOGLAND, J. et al. Estimating forest characteristics for longleaf pine restoration using normalized remotely sensed imagery in Florida USA. **Forests**, v. 11, n. 4, p. 426, 1 abr. 2020.

HOUGHTON, R. A.; HALL, F.; GOETZ, S. J. Importance of biomass in the global carbon cycle. **Journal of Geophysical Research**, v. 114, n. G00E03, p. 1–13, 2009.

JAMES, G. et al. **An Introduction to Statistical Learning with Applications in R**. New York: Springer, 2013.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. 4. ed. Chicago: Pearson Series in Geographic Information Science, 2015.

JETZ, W. et al. Monitoring plant functional diversity from space. **Nature Plants**, v. 2, n. 3, p. 1–5, 2016.

JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 2008, p. 3833–3845, 2008.

JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. **A review of feature selection methods with applications**. International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2015 - Proceedings. **Anais...Opatija, Croatia: MIPRO**, 2015.

LIANG, J. et al. Positive biodiversity-productivity relationship predominant in global forests. **Science**, v. 354, n. 6309, 2016.

- 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. et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016.
- LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, jun. 2005.
- MACKEY, B. G.; BRYAN, J.; RANDALL, L. **Australia's Dynamic Habitat Template for 2003**. MODIS Vegetation Workshop. **Anais...** Missoula: University of Montana, 2004.
- MADONSELA, S. et al. Remote sensing of species diversity using Landsat 8 spectral variables. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 133, p. 116–127, 2017.
- MAGURRAN, A. E. **Ecological Diversity and Its Measurement**. Londres: Croom Helm Limited, 1988.
- MAGURRAN, A. E. **Measuring Biological Diversity**. Oxford, UK: Blackwell Science Ltd, 2004.
- MATASCI, G. et al. Large-area mapping Canadian boreal forest, height, biomass and structural attributes using Landsat composites and lidar plots. **Remote Sensing of Environment**, v. 209, n. 2018, p. 90–106, 2018.
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. **Implementation of machine-learning classification in remote sensing: An applied review** **International Journal of Remote Sensing** Taylor and Francis Ltd., , 3 maio 2018.
- MENESES, P. R.; ALMEIDA, T. DE. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. 1. ed. Brasília, DF: CNPq/UnB, 2012.
- MENG, J. et al. Estimation of forest structural diversity using the spectral and textural information derived from SPOT-5 satellite images. **Remote Sensing**, v. 8, n. 2, 2016.
- MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829–839, 2015.
- MORO, M. F. et al. A Phytogeographical Metaanalysis of the Semiarid Caatinga Domain in Brazil. **Botanical Review**, v. 82, n. 2, p. 91–148, 2016.
- MURA, M. et al. Exploiting the capabilities of the Sentinel-2 multi spectral instrument for predicting growing stock volume in forest ecosystems. **International Journal of Applied Earth Observation and Geoinformation**, v. 66, p. 126–134, 1 abr. 2018.
- MUTANGA, O.; ADAM, E.; AZONG CHO, M. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. **International Journal of Applied Earth Observation and Geoinformation**, v. 18, n. 2012, p. 399–406,

2012.

PEDE, T.; MOUNTRAKIS, G. An empirical comparison of interpolation methods for MODIS 8-day land surface temperature composites across the conterminous United States. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 142, n. 2018, p. 137–150, 2018.

PETTORELLI, N. et al. Framing the concept of satellite remote sensing essential biodiversity variables: challenges and future directions. **Remote Sensing in Ecology and Conservation**, v. 2, n. 3, p. 122–131, 2016.

PULLANAGARI, R.; KERESZTURI, G.; YULE, I. Integrating Airborne Hyperspectral, Topographic, and Soil Data for Estimating Pasture Quality Using Recursive Feature Elimination with Random Forest Regression. **Remote Sensing**, v. 10, n. 7, p. 1117, 13 jul. 2018.

RADELOFF, V. C. et al. The Dynamic Habitat Indices (DHIs) from MODIS and global biodiversity. **Remote Sensing of Environment**, v. 222, p. 204–214, 1 mar. 2019.

REIS, A. A. DOS et al. International Journal of Remote Sensing Volume estimation in a Eucalyptus plantation using multi-source remote sensing and digital terrain data: a case study in Minas Gerais State, Brazil Volume estimation in a Eucalyptus plantation using multi-source rem. 2018.

REZENDE, C. L. et al. From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 16, n. 2018, p. 208–214, 2018.

RIBEIRO, S. C. et al. Above- and belowground biomass in a Brazilian Cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 2011.

ROCCHINI, D. et al. Measuring  $\beta$ -diversity by remote sensing: A challenge for biodiversity monitoring. **Methods in Ecology and Evolution**, v. 9, n. 8, p. 1787–1798, 2018.

RODRIGUEZ-GALIANO, V. F. et al. Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. **Science of the Total Environment**, v. 624, n. 2018, p. 661–672, 2018.

ROQUETTE, J. G. DISTRIBUIÇÃO DA BIOMASSA NO CERRADO E A SUA IMPORTÂNCIA NA ARMAZENAGEM DO CARBONO. **Ciência Florestal**, v. 28, n. 3, p. 1350–1363, 2018.

SAATCHI, S. et al. Modeling distribution of Amazonian tree species and diversity using remote sensing measurements. **Remote Sensing of Environment**, v. 112, n. 2008, p. 2000–2017, 2008.

SANTOS, R. M. DOS et al. Structure and floristics of a remnant of arboreous caatinga in juvenília, northern minas gerais, Brazil. **Cerne**, v. 17, n. 2, p. 247–258, 2011.

SCHINDLER, S. et al. Performance of methods to select landscape metrics for modelling species richness. **Ecological Modelling**, v. 295, n. 2015, p. 107–112, 2015.

SCHWIEDER, M. et al. Landsat phenological metrics and their relation to aboveground carbon

in the Brazilian Savanna. **Carbon Balance and Management**, v. 13, n. 7, p. 1–15, 2018.

SILVEIRA, E. M. O. et al. Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. 2019, p. 175–188, 2019a.

SILVEIRA, E. M. O. et al. Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, p. 1–18, 2019b.

SILVEIRA, E. M. O. et al. Carbon-diversity hotspots and their owners in Brazilian southeastern Savanna, Atlantic Forest and Semi-Arid Woodland domains. **Forest Ecology and Management**, v. 452, n. May, p. 1–12, 2019c.

SILVEIRA, E. M. O. et al. Estimating Aboveground Biomass Loss from Deforestation in the Savanna and Semi-arid Biomes of Brazil between 2007 and 2017. In: SURATMAN, M. N. et al. (Eds.). . **Forest Degradation Around the World**. [s.l.] IntechOpen, 2020. p. 1–17.

SIMPSON, E. H. Measurement of Diversity. **Nature**, v. 163, n. 4148, p. 688, 1949.

STAŃCZYK, U. Feature evaluation by filter, Wrapper and embedded approaches. **Studies in Computational Intelligence**, v. 584, p. 29–44, 2015.

TERRA, M. DE C. N. S. et al. Water availability drives gradients of tree diversity, structure and functional traits in the Atlantic-Cerrado-Caatinga transition, Brazil. **Journal of Plant Ecology**, v. 11, n. 6, p. 803–814, 2018.

THUKRAL, A. K. A review on measurement of Alpha diversity in biology. **Agricultural Research Journal**, v. 54, n. 1, p. 1–10, 2017.

VAN DER SANDE, M. T. et al. Biodiversity in species, traits, and structure determines carbon stocks and uptake in tropical forests. **Biotropica**, v. 49, n. 5, p. 593–603, 2017.

VINCENZI, S. et al. Application of a Random Forest algorithm to predict spatial distribution of the potential yield of *Ruditapes philippinarum* in the Venice lagoon, Italy. **Ecological Modelling**, v. 222, n. 8, p. 1471–1478, 24 abr. 2011.

WANG, G. et al. Modelling above-ground biomass based on vegetation indexes: a modified approach for biomass estimation in semi-arid grasslands. **International Journal of Remote Sensing**, v. 40, n. 10, p. 3835–3854, 2019.

WANG, J. et al. Prediction of forest unit volume based on hybrid feature selection and ensemble learning. **Evolutionary Intelligence**, v. 13, n. 1, p. 21–32, 2019.

WARING, U. S. A. R. H. et al. MODIS enhanced vegetation index predicts tree species richness across forested ecoregions in the contiguous. 2006.

WOOD, E. M. et al. Image texture as a remotely sensed measure of vegetation structure. **Remote Sensing of Environment**, v. 121, n. 2012, p. 516–526, 2012.

WU, J.; LIANG, S. Developing an integrated remote sensing based biodiversity index for predicting animal species richness. **Remote Sensing**, v. 10, n. 5, 2018.

XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of Sensors**, v. 2017, 2017.

YANG, X. et al. Comparing the effects species diversity and the dominant species (*Stipa grandis*) genotypic diversity on the biomass explained by plant functional trait. **Ecological Engineering**, v. 136, n. 2019, p. 17–22, 2019.

YANG, Y.; CAI, W.; YANG, J. Evaluation of MODIS Land Surface Temperature Data to Estimate Near-Surface Air Temperature in Northeast China. **Remote Sensing**, v. 9, n. 5, p. 410, 27 abr. 2017.

ZHANG, J. et al. Estimating aboveground biomass of *Pinus densata*-dominated forests using Landsat time series and permanent sample plot data. **Journal of Forestry Research**, v. 30, n. 5, p. 1689–1706, 1 out. 2019.

**SEGUNDA PARTE – ARTIGOS**

**Artigos formatados conforme a NBR 6022 (ABNT, 2018) e adaptados às exigências do  
Manual de Normalização de Trabalhos Acadêmicos da UFLA.**



**ARTIGO 1 – ÍNDICES ANUAIS DE SENSORIAMENTO REMOTO NA  
MODELAGEM DA BIOMASSA E BIODIVERSIDADE ARBÓREA EM MINAS  
GERAIS**

ARTICLE 1 – ANNUAL INDEXES OF REMOTE SENSING FOR MODELING  
ABOVEGROUND BIOMASS AND BIODIVERSITY IN MINAS GERAIS

**RESUMO**

A produtividade e a sazonalidade da vegetação, assim como variáveis ambientais são fatores que influenciam tanto a distribuição de biomassa, quanto da biodiversidade florestal. O objetivo desse estudo foi modelar a biomassa arbórea acima do solo (AGB) e a diversidade de espécies de árvores (TSD) nas fitofisionomias arbóreas do estado de Minas Gerais (MG), Brasil, utilizando dados de sensoriamento remoto baseados na produtividade e sazonalidade da vegetação e na temperatura. Para isso, utilizamos como preditores índices de sensoriamento remoto (ISR) baseados em métricas anuais derivadas do EVI e da LST do sensor MODIS. Na fase de análise exploratória, as relações entre os ISR e a AGB e a TSD foram avaliadas por meio do coeficiente de correlação de Pearson e de Regressão Linear Simples. O algoritmo *Random Forests* (RF) foi utilizado para selecionar o conjunto ótimo de variáveis e ajustar modelos de predição da AGB e da TSD para as fitofisionomias de forma individual e agrupadas (global). Os resultados indicaram que os ISR derivados de um mesmo produto MODIS são fortemente correlacionados entre si, como era esperado. Por outro lado, as relações lineares entre os ISR e a AGB ou TSD nas áreas estudadas foram inexistentes, fracas ou moderadas. O procedimento de remoção recursiva foi útil para indicar o conjunto de preditores mais relevantes para a modelagem. Em geral, os modelos RF baseados nos ISR conseguiram capturar melhor a variação da TSD do que da AGB. Em relação a modelagem por fitofisionomia, os modelos RF demonstraram diferentes capacidades para explicar a variação na AGB e na TSD. Todavia, os modelos globais forneceram melhores estimativas das variáveis dependentes, do que a maioria dos modelos por fitofisionomias. Além disso, destacamos que modelos RF baseados nos ISR derivados da LST de baixa resolução espacial (1 km) podem fornecer estimativas confiáveis da TSD em estudos regionais e incentivamos maiores discussões sobre a utilização dos ISR para modelagem de AGB e TSD em diferentes escalas espaciais.

**Palavras-chave:** Índice de Vegetação Melhorado. Temperatura da Superfície Terrestre. Random Forests. Índice Alfa de Fisher. Produtividade da Vegetação. Sazonalidade da Vegetação.

**ABSTRACT**

The productivity and seasonality of vegetation, as well as environmental variables are factors that influence both the distribution of biomass and forest biodiversity. The objective of this study was to model the aboveground biomass (AGB) and the tree species diversity (TSD) in the tree phytophysionomies of the state of Minas Gerais (MG), Brazil, using remote sensing data based on the productivity and seasonality of the vegetation and the temperature. For that,

we used remote sensing indices (RSI) as predictors based on annual metrics derived from the EVI and LST of the MODIS sensor. In the exploratory analysis phase, the relationships between RSI and AGB and TSD were assessed using Pearson's correlation coefficient and Simple Linear Regression. The Random Forests (RF) algorithm was used to select the optimal set of variables to fit prediction models for AGB and TSD for phytophysiognomies individually and in groups (global). The results indicated that the RSI derived from the same MODIS product are strongly correlated with each other, as expected. On the other hand, the linear relationships between RSI and AGB or TSD in the studied areas were nonexistent, weak, or moderate. The recursive removal procedure was useful to indicate the set of most relevant predictors for modeling. In general, RSI-based RF models were able to better capture the variation of TSD than AGB. Regarding phytophysiognomies modeling, the RF models demonstrated different abilities to explain the variation in AGB and TSD. However, the global models provided better estimates of the dependent variables, than most of the models by phytophysiognomies. In addition, we highlight that RF models based on RSI derived from low spatial resolution LST (1 km) can provide reliable estimates of TSD in regional studies and encourage further discussions about the use of RSI for modeling AGB and TSD at different spatial scales.

**Keywords:** Enhanced Vegetation Index. Land Surface Temperature. Random forests. Fisher's Alpha Index. Vegetation Productivity. Vegetation Seasonality.

## 1 INTRODUÇÃO

As florestas tropicais abrigam grande parte da biodiversidade e da biomassa terrestre do planeta (ANDRESEN; ARROYO-RODRÍGUEZ; ESCOBAR, 2018; FUJII et al., 2018) e são responsáveis por serviços ecossistêmicos essenciais à sobrevivência e bem-estar humano (COSTANZA et al., 2014; MILHEIRAS; MACE, 2018). Todavia, além de ameaças constantes como pressões antrópicas e mudanças climáticas (BARLOW et al., 2018; VOIGHT et al., 2018), os mecanismos de adaptação das espécies arbóreas aos gradientes de disponibilidade de recursos e processos sucessionais e fenológicos também determinam os padrões geográficos estruturais da vegetação nas florestas tropicais (FUJII et al., 2018; PAN et al., 2013; TERRA et al., 2018). Portanto, modelos matemáticos de predição, baseados em sensoriamento remoto, são ferramentas essenciais à obtenção de informações rápidas e economicamente viáveis, sobre a distribuição de biomassa e biodiversidade terrestre em diferentes resoluções espaciais e temporais (SAATCHI et al., 2008; WANG, G. et al., 2019).

Nas florestas tropicais, as associações entre a diversidade de espécies de árvores (TSD) e a produção de biomassa arbórea acima do solo (AGB) são complexas e altamente variáveis (DAY et al., 2014; SILVEIRA et al., 2019a). No entanto, compreender os padrões espaciais de distribuição de AGB e TSD é crucial para o desenvolvimento de ações de conservação e estratégias de manejo florestal, visando a potencialização das funções e dos serviços oferecidos por ecossistemas florestais. Estudos sobre a biodiversidade terrestre mostraram que os Índices de Dinâmica de Habitat (DHI, do inglês *Dynamic Habitat Indices*) (MACKEY; BRYAN; RANDALL, 2004) baseados em medidas anuais de sensoriamento remoto da produtividade e sazonalidade da vegetação possuem fortes relações com os padrões de diversidade e riqueza de espécies de animais (HOBİ et al., 2017; RADELOFF et al., 2019; RAZENKOVA et al., 2020; SUTTIDATE et al., 2019). Empiricamente, medidas da produtividade e variáveis ambientais estão entre os principais fatores determinantes da disponibilidade de recursos para as interações tróficas ecossistêmicas, pois tanto a biomassa, quanto a biodiversidade florestal são influenciadas por aspectos climáticos, como temperatura e precipitação (ALI et al., 2020; FINE, 2015; MORANDI et al., 2020; TERRA et al., 2018).

Dentro da ampla gama de produtos de sensoriamento remoto com potencial para uso em estudos de vegetação, os dados do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) destacam-se por fornecer produtos capazes de gerar informações globais sobre inúmeros aspectos da superfície terrestre. O índice de vegetação melhorado (EVI, do inglês *Enhanced Vegetation Index*) do MODIS tem potencial para capturar os padrões regionais

de produtividade e sazonalidade da vegetação de forma equivalente, e possivelmente melhor, do que os métodos de amostragem local, ou baseados em modelos dependentes de extrapolação de informações climáticas e fisiográficas (WARING et al., 2006). O sensor MODIS também detecta remotamente dados da temperatura da superfície terrestre (LST, do inglês *Land Surface Temperature*), os quais têm sido frequentemente utilizados em publicações científicas de diferentes áreas, incluindo as ciências ambientais, agrícolas, biológicas, sociais e da saúde (PHAN; KAPPAS, 2018).

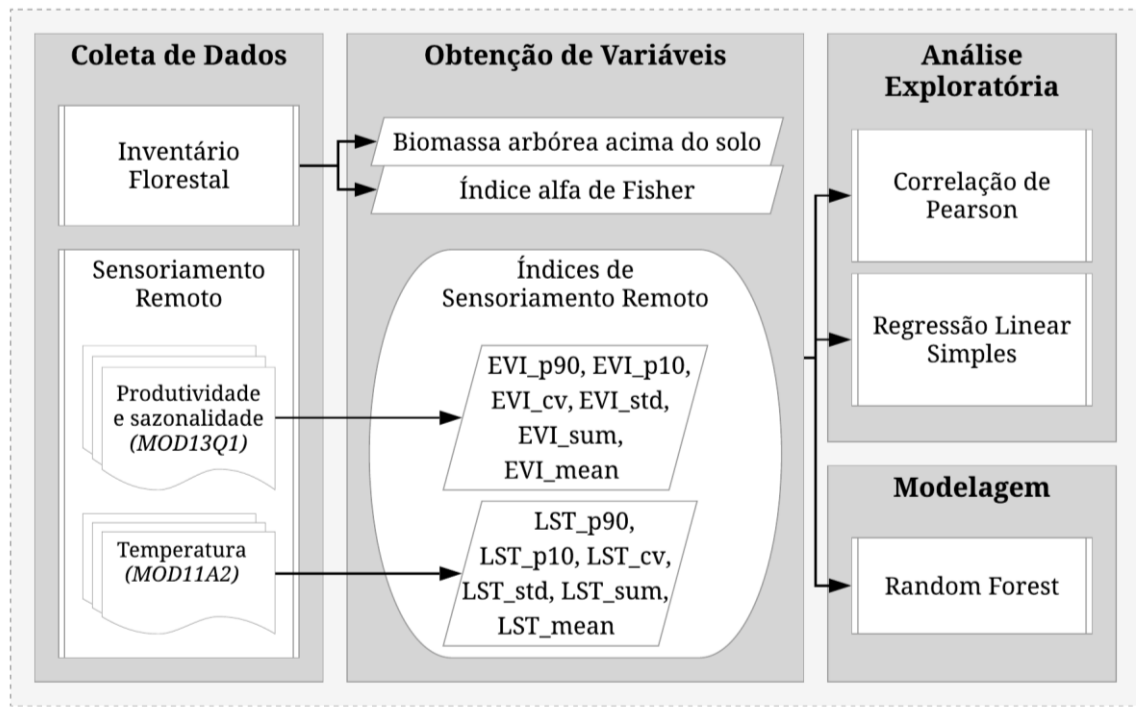
Estudos anteriores destacam que índices anuais derivados de medições de reflectância de satélite possuem uma vantagem sobre conjuntos de dados ambientais interpolados derivados de estações meteorológicas de resoluções semelhantes, uma vez que os primeiros são baseados em medições reais obtidas na mesma resolução do conjunto de dados final (RADELOFF et al., 2019). Entretanto, ainda existe uma lacuna científica quanto à compreensão das relações entre métricas anuais de sensoriamento remoto (como os DHI), representativas das características de produtividade e sazonalidade da vegetação (EVI) e dos aspectos climáticos (LST) das florestas tropicais, e a distribuição da AGB e da TSD em nível regional ou por fitofisionomia. Logo, é evidente a importância do desenvolvimento de métricas de sensoriamento remoto e da utilização de métodos de modelagem que forneçam estimativas adequadas dos parâmetros florestais de relevância econômica e conservacionista, como AGB e TSD, a um baixo custo.

Partindo dos conceitos que fundamentam a construção dos DHI e da premissa de que a produtividade e a sazonalidade da vegetação, assim como as variações climáticas são características particulares de cada tipo de formação florestal, e direcionam as variações de biomassa e biodiversidade, assume-se a hipótese de que os índices de sensoriamento remoto (ISR) baseados em métricas anuais do EVI e da LST do sensor MODIS são capazes de descrever os padrões de AGB e TSD nas fitofisionomias arbóreas de MG. Desse modo, o objetivo deste artigo é modelar a AGB e a TSD das fitofisionomias de MG utilizando dados de sensoriamento remoto baseados: (1) na produtividade da vegetação, (2) na sazonalidade da vegetação e (3) temperatura da superfície terrestre.

## 2 MATERIAL E MÉTODOS

Os ISR utilizados como preditores foram derivados do EVI (*MOD13Q1*) e da LST (*MOD11A2*), ambos produtos do sensor MODIS. Estes índices são fundamentados nos Índices de Dinâmica de Habitat (BERRY; MACKEY; BROWN, 2007; MACKEY; BRYAN; RANDALL, 2004), que expressam três medidas chave da produtividade da vegetação: a) a produtividade cumulativa anual, b) a produtividade mínima ao longo do ano e c) a sazonalidade da vegetação (RADELOFF et al., 2019). Os dados de campo foram obtidos durante a execução do “Inventário Florestal de Minas Gerais” (IFMG), realizado entre os anos de 2006 e 2008. Para entender as relações entre as variáveis e modelar a AGB e a TSD nas fitofisionomias de MG utilizou-se o Coeficiente de Correlação de Pearson, a Regressão Linear Simples (RLS) e o algoritmo *Random Forests* (RF) (BREIMAN, 2001). As etapas da metodologia são apresentadas na Figura 1.

Figura 1 – Fluxograma das principais etapas para modelagem da biomassa arbórea acima do solo e da diversidade de espécies de árvores a partir de índices de sensoriamento remoto nos domínios tropicais de Minas Gerais de Cerrado, Mata Atlântica e Caatinga.



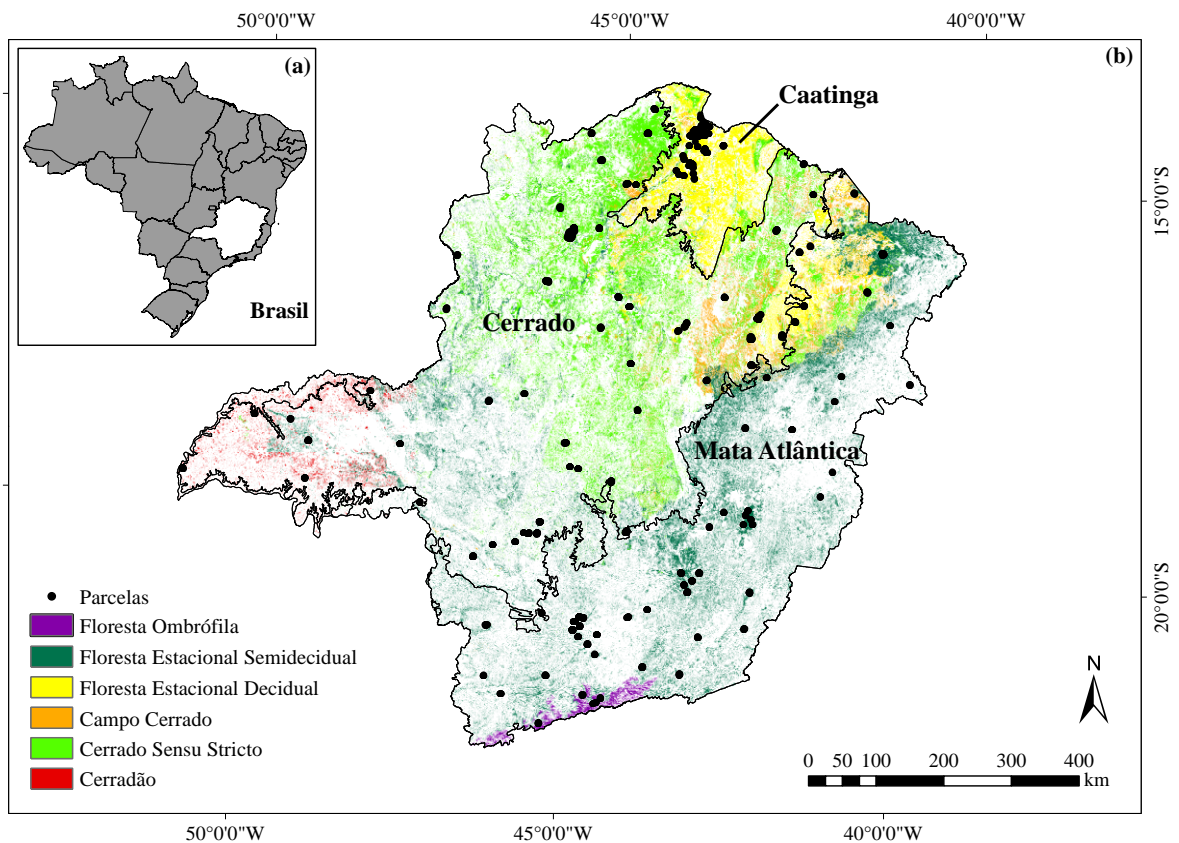
Legenda: Os sufixos associados aos Índices de Sensoriamento Remoto derivados do EVI e da LST são abreviações de percentil 90 (p90), percentil 10 (p10), coeficiente de variação (cv), desvio padrão (std), somatório (sum) e média (mean).

Fonte: Do autor (2021).

## 2.1 Área de Estudo

O estado de MG está localizado na região sudeste do Brasil (Figura 2a). Seu extenso território é marcado por grande variação de clima, solo e relevo. Considerando a classificação de Koppen, o estado apresenta quatro tipos de climas: Aw (clima tropical de savana com estação seca de inverno), Cfa (clima subtropical) e Cwa e Cwb (climas tropicais de altitude) (DAVID et al., 2017; PEEL; FINLAYSON; MCMAHON, 2007). A vegetação do estado é composta por diferentes fitofisionomias de três grandes domínios, o Cerrado, a Mata Atlântica e a Caatinga (Figura 2b) (SCOLFORO et al., 2015).

Figura 2 – Localização da área de estudo e distribuição das parcelas do Inventário Florestal de Minas Gerais.



Legenda: a) Localização do estado de Minas Gerais no Sudeste do Brasil; b) Distribuição das parcelas do Inventário Florestal de Minas Gerais nas fitofisionomias dos domínios Cerrado, Caatinga e Mata Atlântica.

Fonte: Do autor (2021).

A vegetação xeromorfa do Cerrado compreende formações campestres, savânicas e florestais, que ocorrem predominantemente nas regiões Centro, Noroeste e Oeste, sob condições regulares de sazonalidade climática. Fisionomicamente, o Cerradão (Cdao), o Campo

Cerrado (CCer) e o Cerrado *Sensu Stricto* (CSS) são marcados pela predominância de arbustos e espécies arbóreas, que constituem dossel contínuo ou descontínuo (HOUSE et al., 2003; RIBEIRO; WALTER, 2008). A Mata Atlântica, que ocupa as regiões centro-sul e leste do estado, de climas chuvosos e com temperaturas mais amenas, é representada pelas fitofisionomias de Floresta Estacional Semidecidual (FES), nas regiões que possuem de 2 a 5 meses de estação seca, e de Floresta Ombrófila (FOM), perene e de clima sem período seco definido (COLOMBO; JOLY, 2010; SCOLFORO et al., 2015; SILVEIRA et al., 2019a). A Caatinga, por sua vez, é representada pela Floresta Estacional Decidual (FED), que ocorre no norte e nordeste de MG, onde predominam climas semiáridos e subúmidos, com estação seca bem definida, temperaturas elevadas e baixa precipitação anual, com chuvas distribuídas irregularmente no verão (ARAÚJO; CASTRO; ALBUQUERQUE, 2007; OLIVEIRA FILHO et al., 2006; SCOLFORO et al., 2015).

## **2.2 Inventário Florestal: Biomassa e Biodiversidade**

Para obtenção da AGB e da TSD foram utilizados dados das parcelas de campo (10 x 100 m), lançadas de 2006 a 2008 durante a execução do IFMG, realizado pela Universidade Federal de Lavras em parceria com o Instituto Estadual de Florestas. As parcelas foram georreferenciadas e o procedimento de amostragem adotado foi o sistemático em dois estágios (SCOLFORO et al., 2015). Foram utilizadas 2755 parcelas (Figura 2b), destas 846 pertencem ao domínio do Cerrado, 1475 da Mata Atlântica e 434 da Caatinga. A distribuição amostral por fitofisionomia adotada foi: no domínio Cerrado foram distribuídas 229 parcelas no CCer, 52 no Cdao e 565 parcelas no CSS; na Caatinga as 434 parcelas foram distribuídas na FED; e na Mata Atlântica, 1372 parcelas foram distribuídas na FES e 103 na FOM.

Em cada parcela, todas as árvores com no mínimo 5 cm de diâmetro a altura do peito (DAP), medido a 1,30 m do nível do solo, foram medidas e identificadas taxonomicamente de acordo com o Serviço de Resolução de Nomes Taxonômicos (TNRS) (BOYLE et al., 2013). A determinação da AGB em campo foi feita pelo método destrutivo, considerando indivíduos representativos de cada fitofisionomia e das diferentes classes de diâmetro e altura. Os indivíduos selecionados foram georreferenciados, cortados e cubados pelo método de Huber. Em seguida, a partir das equações ajustadas com os dados de campo, foram obtidas as estimativas de AGB de cada parcela. Por fim, a quantidade de AGB por parcela foi convertida para hectares (Mg/ha). Scolforo et al. (2008) descrevem detalhadamente a metodologia utilizada para quantificação da biomassa durante o IFMG. O alfa de Fisher (FISHER;

CORBET; WILLIAMS, 1943), determinado pela relação entre o número de indivíduos e o número de espécies de uma amostra, utilizado para representar a TSD, foi calculado para cada parcela pela equação 1, onde  $S$  é o número de espécies por parcela,  $n$  é o número de indivíduos por parcela e  $\alpha$  é o alfa de Fisher.

$$S = \alpha * \ln \left( 1 + \frac{n}{\alpha} \right) \quad (1)$$

### 2.3 Índices de Sensoriamento Remoto

Diferentemente dos índices espectrais tradicionais utilizados na análise da vegetação, os ISR fornecem medidas integradas dos padrões dinâmicos de produtividade e sazonalidade da vegetação e do clima. O EVI foi utilizado para capturar e representar aspectos da produtividade e sazonalidade da vegetação e dele foram derivados três ISR, baseados nos DHI (MACKEY; BRYAN; RANDALL, 2004): a) medida anual acumulativa (ISR\_sum), que representa a capacidade produtiva da vegetação em um ano e está relacionada à quantidade de energia disponível; b) medida anual mínima (ISR\_p10), que captura os pontos mais baixos em termos de produtividade durante o ano, e está relacionada às condições de estresse ambiental; e c) medida de variação sazonal, representada pelo coeficiente de variação (ISR\_cv), que reflete o quanto a produtividade em um determinado pixel varia no período de um ano, estando, portanto, associada às características de estabilidade ambiental. Outros três ISR foram calculados, sendo dois caracterizando a produtividade da vegetação e representados pela produtividade média anual (ISR\_mean) e máxima (ISR\_p90), e um de sazonalidade, representado pelo desvio padrão (ISR\_std). Com o objetivo de integrar os aspectos climáticos da área de estudo, essas mesmas seis métricas anuais também foram calculadas para a LST. Assim, para modelar a AGB (Mg/ha) e a TSD foram utilizados como variáveis preditoras doze ISR (Tabela 1).

Tabela 1 – Variáveis de sensoriamento remoto usadas para modelagem da biomassa arbórea acima do solo e da diversidade de espécies arbóreas nas florestas de Minas Gerais (Continua).

Produto MODIS	ISR	Resolução	
		Espacial	Temporal
Produtividade e sazonalidade – MOD13Q1	EVI_p10	250 m	16 dias
	EVI_cv		
	EVI_p90		
	EVI_mean		
	EVI_std		
	EVI_sum		



Tabela 1 – Variáveis de sensoriamento remoto usadas para modelagem da biomassa arbórea acima do solo e da diversidade de espécies arbóreas nas florestas de Minas Gerais (Conclusão).

Produto MODIS	ISR	Resolução	
		Espacial	Temporal
Clima – MOD11A2	LST_p10 LST_cv LST_p90 LST_mean LST_std LST_sum	1 km	8 dias

Nota: Os sufixos associados aos Índices de Sensoriamento Remoto derivados do EVI e da LST são abreviações de percentil 10 (p10), coeficiente de variação (cv), percentil 90 (p90), média (mean), desvio padrão (std) e somatório (sum).

Fonte: Do autor (2021).

O cálculo dos ISR foi realizado a partir de redutores estatísticos e matemáticos no ambiente do Google Earth Engine, uma plataforma de computação em nuvem, que possibilita a realização de análises geoespaciais em escala planetária gratuitamente (GORELICK et al., 2017). Nas imagens do EVI, empregamos máscaras para remoção de nuvens com base nos indicadores de qualidade dos índices de vegetação do produto. Em ambos os conjuntos de imagens foram aplicados os recursos de filtragem temporal e espacial para atender especificamente o intervalo de tempo (01 de janeiro de 2007 a 31 de dezembro de 2007) e a área geográfica (MG) considerados neste estudo. Os valores dos pixels, tanto do EVI, quanto da LST, foram convertidos de acordo com a escala de cada produto (0,0001 e 0,02, respectivamente). Além disso, no caso da LST, subtraímos 273,15 de cada pixel para transformar de Kelvin para graus Celsius. Por fim, os valores dos pixels de cada ISR foram associados às coordenadas das parcelas de campo do IFMG.

## 2.4 Análises Exploratórias

Visando à compreensão do comportamento dos dados, verificamos a tendência e o grau de associação entre todas as variáveis do conjunto de dados, por meio do coeficiente de correlação de Pearson. Em seguida, as variáveis preditoras foram avaliadas uma a uma, a partir do desempenho de equações lineares simples, que foram ajustadas tanto para todas as parcelas do IFMG, englobando as seis fitofisionomias arbóreas do estado (equações globais), quanto de forma estratificada (equações por fitofisionomia). O poder de explicação dos ISR sobre a variabilidade das variáveis dependentes foi medido pelo coeficiente de determinação ( $R^2$ ).

Além disso, consideramos o nível de probabilidade de significância da regressão (p-valor) para confirmar a existência da relação linear entre as variáveis.

## 2.5 Modelagem da Biomassa e da Biodiversidade

A modelagem da AGB e da TSD foi conduzida tanto para as seis fitofisionomias arbóreas de MG agrupadas (modelos globais), quanto de forma estratificada (modelos por fitofisionomia). Utilizamos o algoritmo RF (BREIMAN, 2001) com seleção de variáveis por remoção recursiva (MILLARD; RICHARDSON, 2015; SILVEIRA et al., 2019b), por meio do pacote *randomForest* (LIAW; WIENER, 2002), disponível no software R (R CORE TEAM, 2019). O número de árvores de decisão (*n*tree) cultivadas para regressão foi 1000. Da base de dados, 70% foram selecionados aleatoriamente para compor a amostra de treinamento e ajustar o modelo, os outros 30% restantes foram reservados para teste. O procedimento de remoção recursiva acontece de maneira iterativa. Os doze ISR foram utilizados como entrada e, com base no incremento do erro médio quadrático em porcentagem (%IncMSE, do inglês *Mean-Squared Error*) associado à sua não utilização, foram ranqueados em ordem crescente de importância. A cada iteração, os ISR de menor relevância foram eliminados sucessivamente e o valor do %IncMSE foi computado para avaliação do conjunto de preditores. Ao final, o conjunto dos ISR da iteração de menor erro foi utilizado para treinar um novo RF.

A avaliação da performance preditiva dos modelos resultantes foi conduzida com base na análise gráfica dos resíduos; no erro médio absoluto (MAE, do inglês *Mean Absolute Error*) que indica a tendência média de subestimação ou superestimação dos modelos, em porcentagem (Equação 2); na raiz do erro médio quadrático (RMSE, do inglês *Root-Mean-Squared Error*) calculado pelo desvio médio, em Mg/ha, entre os valores estimados e os observados (Equação 3); e no coeficiente de determinação ajustado ( $R^2_{aj}$ ) que representa a porcentagem da variabilidade dos dados que é explicada pelo modelo (SILVEIRA et al., 2019b). Nas equações 2 e 3,  $n$  corresponde ao número de parcelas; e  $O_i$  e  $E_i$  representam os valores observados e estimados, respectivamente.

$$MAE(\%) = \frac{1}{n} \sum_i^n \frac{O_i - E_i}{O_i} 100 \quad (2)$$

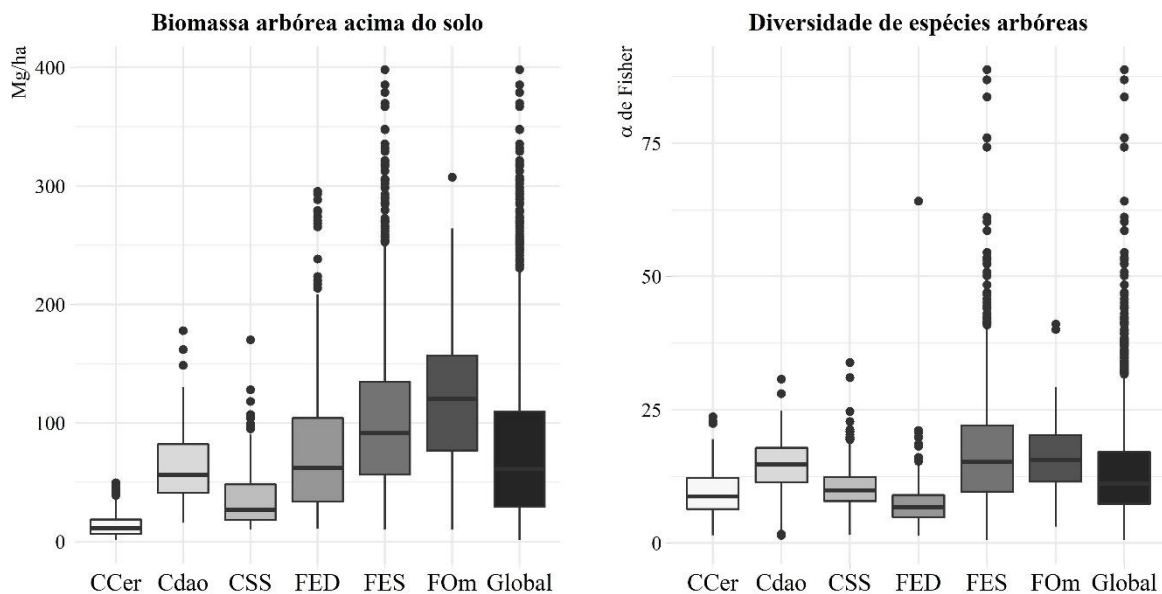
$$RMSE \left( \frac{Mg}{ha} \right) = \sqrt{\frac{\sum_i^n (E_i - O_i)^2}{n}} \quad (3)$$

### 3 RESULTADOS

#### 3.1 Padrões de Biomassa, Biodiversidade e ISR em Minas Gerais

Os dados de AGB e TSD das fitofisionomias obtidos e calculados a partir das campanhas de campo do IFMG se aproximam de uma distribuição unimodal, geralmente assimétrica à direita (Figura 3). As fitofisionomias FOM e FES apresentaram as maiores médias e a maior variação tanto de AGB quanto de TSD. A FED apresentou valores relativamente moderados para AGB, porém baixos valores para a diversidade de espécies, enquanto o Cdao apresentou valores relativamente moderados para AGB e TSD. Além disso, ao observar a cauda das distribuições, nota-se grande quantidade de valores extremos (outliers) em alguns conjuntos de dados.

Figura 3 – Amplitude de variação e distribuição da biomassa arbórea acima do solo e da diversidade de espécies de árvores nas parcelas do Inventário Florestal de Minas Gerais.



Nota: Global: Todas as fitofisionomias em conjunto; CCer: Campo Cerrado; Cdao: Cerradão; CSS: Cerrado *Sensu Stricto*; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOM: Floresta Ombrófila.

Fonte: Do autor (2021).

Avaliando as associações dos preditores com as variáveis dependentes, comparando os diferentes grupos de ISR, é notável a existência de uma tendência de correlações mais fortes entre ISR derivados do EVI e a AGB, e entre ISR derivados da LST e a TSD. Nas correlações

globais, os ISR do EVI apresentaram correlações fracas ( $\rho$  em torno de 0,15), na maioria das vezes positivas, com a AGB e TSD; enquanto os ISR da LST exibiram correlações um pouco mais fortes com a TSD ( $\rho = |0,25|$ ), do que com a AGB ( $\rho = |0,14|$ ). Nas fitofisionomias do Cerrado (CCer, Cdao e CSS), a maioria dos ISR do EVI possuem correlações moderadas com a AGB ( $-0,53 \leq \rho \leq 0,48$ ), enquanto os ISR derivados da LST possuem correlações mais fracas ( $-0,35 \leq \rho \leq 0,34$ ); com a TSD, a maioria dos ISR do EVI têm correlações fracas ( $-0,41 \leq \rho \leq 0,06$ ), e os da LST, correlações mais fortes ( $-0,34 \leq \rho \leq 0,45$ ). Na Mata Atlântica, os ISR derivados da LST, tanto com AGB, quanto com a TSD, possuem correlações moderadas ( $-0,55 \leq \rho \leq 0,47$ ) na FOM, e mais fracas na FES ( $-0,34 \leq \rho \leq 0,13$ ); quanto aos ISR do EVI, estes não têm correlações moderadas ou fortes com a AGB ou TSD no bioma. Por fim, na FED da Caatinga, os ISR do EVI e da LST apresentaram correlações fracas ( $-0,24 \leq \rho \leq 0,20$ ) com a AGB e TSD.

Em relação aos resultados da RLS (Tabela S1, Apêndice A), considerando as equações globais para a TSD, apesar dos baixos valores do  $R^2$ , todas representam relações lineares significativas entre as variáveis, sendo que o LST\_p10 e o LST\_p90 apresentaram os melhores resultados. Por outro lado, os valores dos  $R^2$  obtidos nos ajustes globais para a AGB foram baixos, o melhor desempenho ocorreu em função do EVI\_p90. Por fitofisionomia, as equações significativas na FED não apresentaram valores de  $R^2$  maiores do que 6,08%, além disso alguns ISR não possuem relação linear com as variáveis resposta, corroborando com os baixos valores das correlações mencionadas anteriormente. Na Mata Atlântica, alguns ISR derivados da LST forneceram bons ajustes para a AGB (LST\_mean, LST\_p10 e LST\_p90) e TSD (LST\_mean, LST\_p10 e LST\_cv) na FOM e para TSD (LST\_mean e LST\_p10) na FES, com equações lineares significativas capazes de explicar até 31,12% da variação na variável dependente. Nas fitofisionomias do Cerrado, as equações geradas em função dos ISR derivados do EVI, de modo geral, demonstraram melhor desempenho em relação a capacidade de explicação da variação na AGB, com coeficientes de determinação de até 28,22%; enquanto, os índices derivados da LST geraram as melhores equações para a TSD.

### 3.2 Random Forest

Os modelos de regressão entre a AGB ou TSD e os ISR preditores, resultantes do RF com remoção recursiva, retornaram os subconjuntos com número mínimo de variáveis de maior importância para a modelagem. Sendo estas, responsáveis por maiores %IncMSE, quando não utilizadas (Tabela 2). Em todos os modelos, pelo menos um dos ISR derivados da LST, que

capturam os aspectos temporais relacionados às variações de temperatura de cada tipo de vegetação, foi selecionado para compor os subconjuntos de preditores. Por outro lado, os ISR derivados do EVI não foram incluídos nos subconjuntos de preditores nos modelos da AGB nas fisionomias da Mata Atlântica (FOm e FES), nem da TSD global, da FES e do CSS.

Tabela 2 – Valores de importância (%IncMSE) dos Índices de Sensoriamento Remoto na modelagem da biomassa arbórea acima do solo e da diversidade de espécies de árvores nas florestas de Minas Gerais.

ISR	Global	FES	FED	FOm	CSS	Cdao	CCer
----- Biomassa -----							
<b>EVI_p10</b>	17,14	-	28,05	-	25,94	-	-
<b>EVI_cv</b>	39,32	-	-	-	17,94	-	-
<b>EVI_p90</b>	41,84	-	36,37	-	-	-	-
<b>EVI_mean</b>	37,63	-	-	-	27,76	-	23,27
<b>EVI_std</b>	37,69	-	34,77	-	21,60	-	-
<b>EVI_sum</b>	39,92	-	31,18	-	24,73	16,70	-
<b>LST_p10</b>	36,28	-	30,21	-	26,11	19,46	-
<b>LST_cv</b>	39,13	-	31,51	-	15,38	-	-
<b>LST_p90</b>	37,91	51,25	28,64	-	-	17,14	-
<b>LST_mean</b>	34,36	67,25	-	22,59	22,43	18,34	24,24
<b>LST_std</b>	46,41	83,38	28,49	-	18,91	-	-
<b>LST_sum</b>	-	-	-	26,63	30,26	-	-
----- $\alpha$ de Fisher -----							
<b>EVI_p10</b>	-	-	-	-	-	-	22,39
<b>EVI_cv</b>	-	-	-	14,87	-	-	-
<b>EVI_p90</b>	-	-	24,84	17,48	-	-	-
<b>EVI_mean</b>	-	-	15,61	-	-	-	19,03
<b>EVI_std</b>	-	-	23,11	-	-	-	-
<b>EVI_sum</b>	-	-	16,99	-	-	11,33	-
<b>LST_p10</b>	88,92	-	23,65	16,69	29,44	8,43	22,23
<b>LST_cv</b>	92,79	99,50	-	25,14	-	-	19,36
<b>LST_p90</b>	-	92,25	28,66	16,37	20,75	5,69	17,12
<b>LST_mean</b>	-	-	-	17,50	22,49	5,66	16,75
<b>LST_std</b>	91,76	-	22,30	-	-	-	18,17
<b>LST_sum</b>	92,89	81,67	20,05	18,72	24,15	-	21,80

Nota: Global: Todas as fitofisionomias em conjunto; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOm: Floresta Ombrófila; Cdao: Cerradão; CCer: Campo Cerrado; CSS: Cerrado *Sensu Stricto* (CSS); Os sufixos associados aos Índices de Sensoriamento Remoto derivados do EVI e da LST são abreviações de percentil 10 (p10), coeficiente de variação (cv), percentil 90 (p90), média (mean), desvio padrão (std) e somatório (sum).

Fonte: Do autor (2021).

No geral, os modelos para TSD apresentaram melhor desempenho do que os modelos para AGB. Em relação ao MAE%, por exemplo, os modelos de TSD apresentaram valores entre 20,11 e 34,15%, enquanto os de AGB variam de 32,57 a 49,50% (Tabela 3). Já os valores do  $R^2_{aj}$  podem ser maiores ou menores em decorrência da adição ou remoção de variáveis. No

entanto, a utilização de dois ou mais ISR, mesmo que sejam relevantes e com elevados poderes explicativos individualmente, não garante aumento no percentual da variância explicada pelos modelos. Os modelos Global, do CCer, FED e FES foram os que apresentaram melhor desempenho preditivo para TSD em termos da quantidade da variação explicada. Enquanto maiores quantidades da variação na AGB foram explicadas pelos modelos do CSS, FED e Global (Tabela 3).

Tabela 3 – Indicadores de qualidade dos modelos Random Forests obtidos para a biomassa arbórea acima do solo e diversidade de espécies de árvores nas florestas de Minas Gerais.

ISR	Global	FES	FED	FOM	CSS	Cdao	CCer
<b>Biomassa</b>							
<b>RMSE (Mg/ha)</b>	51,17	50,83	43,65	54,52	16,76	29,21	8,75
<b>MAE%</b>	44,46	38,27	34,86	32,57	32,96	43,39	49,50
<b>R<sup>2</sup><sub>aj</sub></b>	30,81	21,12	40,31	9,05	44,49	-7,32	9,67
<b><math>\alpha</math> de Fisher</b>							
<b>RMSE</b>	5,94	8,41	2,51	3,65	3,47	4,84	2,80
<b>MAE%</b>	30,09	34,15	28,09	20,11	26,02	33,33	24,83
<b>R<sup>2</sup><sub>aj</sub></b>	55,10	39,42	39,47	16,55	11,15	24,57	39,88

Nota: Global: Todas as fitofisionomias em conjunto; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOM: Floresta Ombrófila; Cdao: Cerradão; CCer: Campo Cerrado; CSS: Cerrado *Sensu Stricto* (CSS); RMSE: Raiz do Erro Médio Quadrático; MAE%: Erro Médio Absoluto em porcentagem; R<sup>2</sup><sub>aj</sub> = Coeficiente de determinação ajustado em porcentagem.

Fonte: Do autor (2021).

Os valores da RMSE dos modelos de AGB e TSD mostraram resultados representativos das características dos padrões de distribuição dos respectivos dados de campo, oriundos do IFMG. Analisando os modelos obtidos e os gráficos da Figura 3, é possível perceber que os valores da RMSE (Tabela 3) fornecidos a partir das estimativas de AGB são proporcionais ao aporte médio de biomassa por unidade de área em cada fitofisionomia. Em relação à TSD, os valores de RMSE também estão de acordo com as médias do alfa de Fisher (Figura 3) nos modelos das fitofisionomias do Cerrado, da Caatinga e Global.

Adicionalmente, a avaliação gráfica mostrou que os resíduos apresentaram forte comportamento de dispersão em torno das estimativas (Figura 4). Nota-se que os modelos tendem a maximizar os resíduos, superestimando ou subestimando os resultados preditos nas parcelas com maiores aportes de biomassa por hectare e índices de diversidade mais altos. Todavia, de modo geral, os modelos globais podem fornecer melhores estimativas da AGB e da TSD em Minas Gerais, do que a maioria dos modelos ajustados para as fitofisionomias.

Figura 4 – Gráficos de distribuição de resíduos dos modelos *Random Forests* obtidos para a biomassa arbórea acima do solo e diversidade de espécies de árvores nas parcelas do Inventário Florestal de Minas Gerais (Continua).


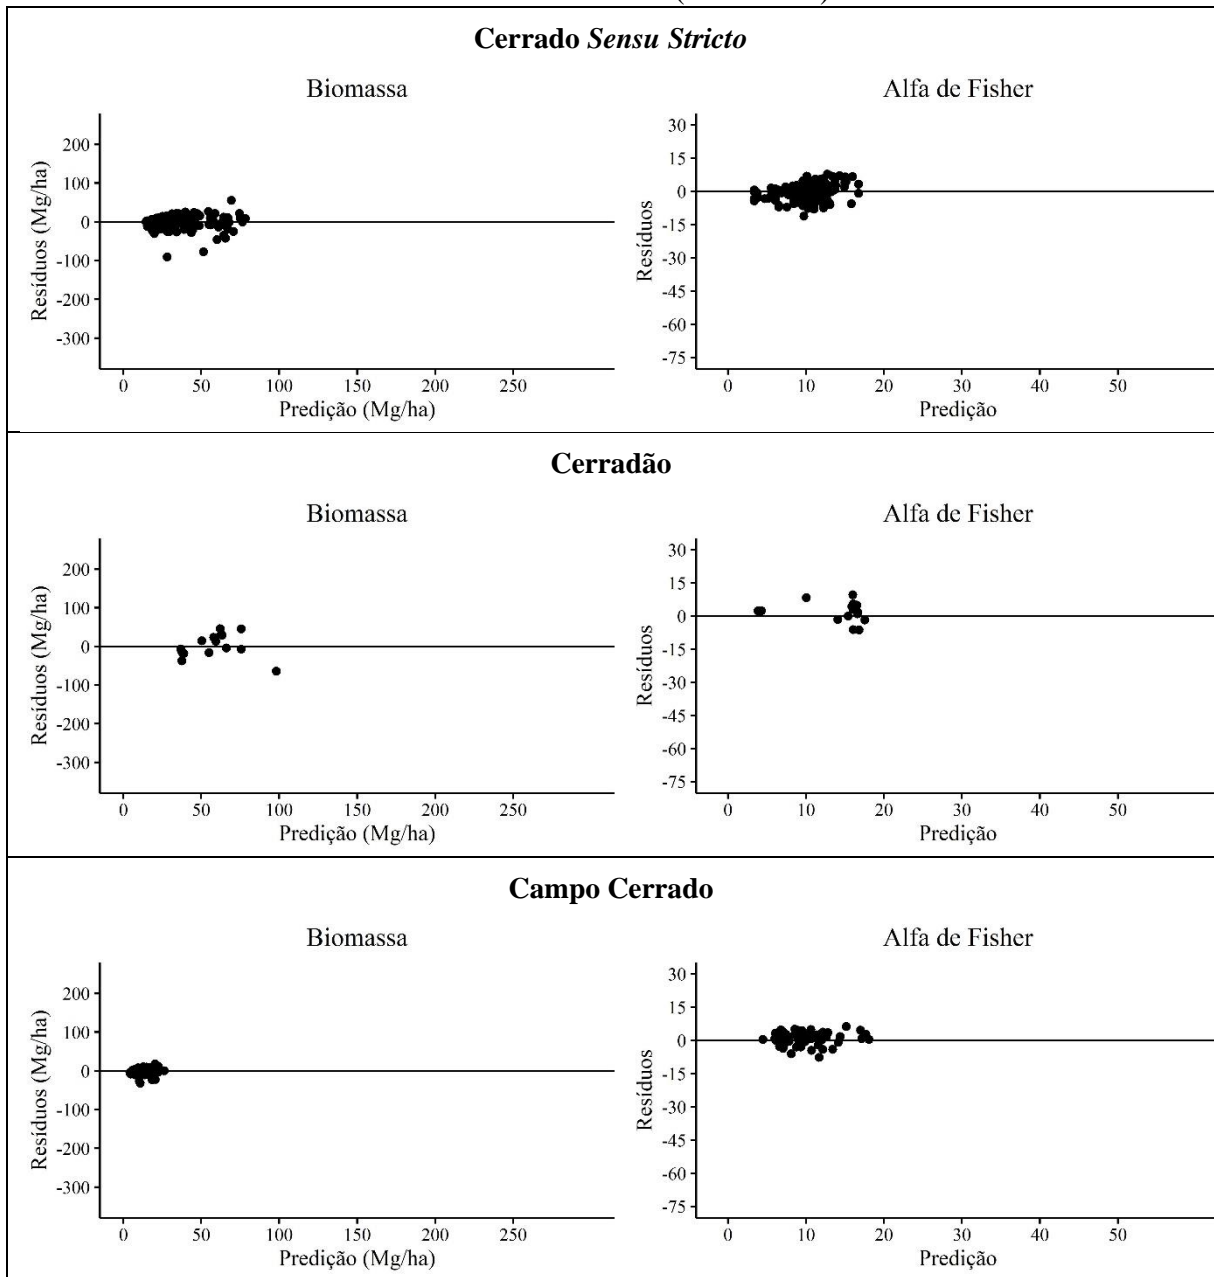


Figura 4 – Gráficos de distribuição de resíduos dos modelos *Random Forests* obtidos para a biomassa arbórea acima do solo e diversidade de espécies de árvores nas parcelas do Inventário Florestal de Minas Gerais (Conclusão).



Fonte: Do autor (2021).



## 4 DISCUSSÃO

As análises de correlação e de RLS indicam que as relações lineares entre métricas temporais da produtividade e sazonalidade da vegetação e da temperatura da superfície terrestre, derivadas de produtos do sensor MODIS, e a AGB ou TSD nas fitofisionomias arbóreas de MG são inexistentes, fracas ou moderadas. Por outro lado, os valores dos coeficientes de Pearson entre os ISR, geralmente altos, corroboraram com resultados de outros estudos, que também destacaram a existência de fortes correlações entre índices resultantes de métricas anuais dos produtos de vegetação do MODIS (HOBI et al., 2017; RADELOFF et al., 2019).

Alguns autores apontam os sensores remotos por satélite como a principal fonte de dados para obtenção de variáveis com potencial para serem usadas em estudos globais sobre a biomassa e a biodiversidade terrestre (LU et al., 2014; ROCCHINI et al., 2016). No entanto, a intensidade e a direção das relações entre os ISR e as variáveis de interesse variaram entre os tipos de vegetação estudados, e de modo geral, as análises globais, englobando todas as fitofisionomias de MG, forneceram melhores resultados. As resoluções espaciais, temporais e espectrais dos sensores são pontos críticos a serem considerados durante a obtenção de informações sobre parâmetros dos ecossistemas terrestres, como a biodiversidade (PETTORELLI et al., 2016) e a biomassa. Galidaki et al. (2017), por exemplo, afirmaram que é improvável que dados de resolução espacial grosseira (200 – 1000 m) possam fornecer estimativas adequadas de biomassa ao nível de parcela ou de talhão.

Neste sentido, os baixos valores do  $R^2$  das equações lineares significativas resultantes das regressões univariadas, provavelmente, estão associados não somente à grande variação no conjunto de dados, como também à moderada resolução espacial dos produtos MODIS. Apesar disso, outros pesquisadores afirmam que modelos preditivos, baseados em estatísticas anuais de produtos de vegetação, fornecem melhores estimativas de parâmetros da vegetação do que os modelos baseados em medições únicas na data mais próxima (TSALYUK; KELLY; GETZ, 2017). Outros aspectos também podem ter influenciado as relações entre os ISR e a AGB ou a TSD, e conseqüentemente a qualidade das estimativas obtidas pelos modelos RF, como o grau de antropização da vegetação, as características decíduais das fitofisionomias de FES e FED, a variação da densidade arbórea entre as fitofisionomias do Cerrado e as variações estruturais internas associadas à topografia e relevo.

Todavia, os resultados fornecidos por nossos modelos de RF para AGB não diferem muito dos obtidos por Silveira et al. (2019c), que utilizando apenas medições de índices de

vegetação nas datas mais próximas das campanhas de campo, conseguiram explicar 28% da variação da AGB em remanescentes da Mata Atlântica. As estimativas de biomassa a partir de dados de bandas originais, índices de vegetação e outras transformações de imagem são frequentemente avaliadas cientificamente (GALIDAKI et al., 2017; LU et al., 2014). Ogaya et al. (2015), por exemplo, sinalizaram boas correlações entre as métricas anuais derivadas do EVI e do NDVI do sensor MODIS e a variação da biomassa em florestas mediterrâneas. Nossos resultados indicaram que os ISR derivados do EVI tendem a apresentar correlações ligeiramente mais fortes e captar maior quantidade da variação da AGB, em relação aos ISR da LST.

No Cerrado, onde as equações lineares univariadas apresentaram maior sucesso em relação às dos outros domínios (Caatinga e Mata Atlântica), o maior valor de  $R^2$  gerado indica que um único ISR conseguiu explicar até 28% da variação da biomassa no Cerradão. Comparativamente, Tsalyuk, Kelly e Getz (2017) utilizaram estatísticas resumidas de séries temporais anuais dos produtos de vegetação do MODIS em regressões univariadas e explicaram até 37% (p-valor < 0,001) da variação da biomassa na savana africana. Os autores ainda afirmaram que englobar a variabilidade sazonal da vegetação das savanas é um desafio inerente à utilização de sensoriamento remoto nesses ecossistemas (TSALYUK; KELLY; GETZ, 2017).

Na Mata Atlântica, as equações univariadas para AGB demonstraram relações mais significativas com ISR derivados da LST, que também apresentaram maiores valores de %IncMSE na modelagem. Em estudos anteriores, Silveira et al. (2019c) observaram que alguns índices de vegetação, como o EVI, não apresentaram relações lineares com a AGB em remanescentes da Mata Atlântica. Anaya, Chuvieco e Palacios-Orueta (2009) também não detectaram nenhuma relação empírica significativa entre o EVI e os valores de biomassa em florestas tropicais na Colômbia, uma vez que a magnitude de variação dos valores de EVI é menor em comparação às florestas temperadas. Já Gusso et al. (2016) optaram por utilizar o EVI-2 (sem a reflectância na banda do azul), para representar o perfil de desenvolvimento da biomassa da folhagem do pinheiro vermelho na Coreia do Sul, e encontraram uma relação polinomial de segunda ordem negativa entre as variáveis.

Os modelos RF indicam que os ISR representados pelos valores do desvio-padrão (LST\_std), média (LST\_mean), máxima (LST\_p90) e somatório (LST\_sum) anual das temperaturas fornecem melhores estimativas da AGB, nas fitofisionomias de Mata Atlântica, em relação aos ISR de sazonalidade e produtividade da vegetação. A relação entre a produtividade da vegetação e a temperatura é complexa. No entanto, os dados da LST consistem em um meio independente de avaliar as relações entre anomalias térmicas, precipitação e ecofisiologia florestal, e portanto podem ser associados às perdas de AGB (TOOMEY et al.,

2011). Se por um lado, as perdas de biomassa amplificam a variação da temperatura diurna e aumentam as temperaturas média e máxima do ar (ALKAMA; CESCATTI, 2016), por outro lado, as florestas promovem o resfriamento local da temperatura acima do dossel durante o dia em comparação as áreas mais abertas adjacentes (DUVEILLER; HOOKER; CESCATTI, 2018; LEE et al., 2011; LI et al., 2015, 2016).

De modo geral, os ISR derivados da LST, que representam as temperaturas mínimas, máximas e médias anuais nas avaliações Globais, no Cerrado *Sensu Stricto*, no Campo Cerrado e nas fitofisionomias da Mata Atlântica, demonstraram relações mais fortes com a TSD, do que os ISR do EVI. Outros estudos também apontam associações entre variáveis climáticas, como temperatura e precipitação, e os gradientes de composição e diversidade de espécies de árvores (CHAPUNGU et al., 2020; SILVEIRA et al., 2019a; WANG, G. et al., 2019; WANG, Z. et al., 2009). Comparativamente, entre as fitofisionomias do Cerrado, no Cerradão, cuja vegetação é mais densa (NERI et al., 2013), a TSD apresentou relações lineares moderadas e foi bem explicada tanto por ISR derivados do EVI, quanto da LST. Já na Caatinga, a ausência de relação linear entre os ISR da LST e a TSD pode estar associada, mais uma vez, à moderada resolução espacial dos produtos utilizados (1 km). Nas florestas tropicais sazonalmente secas, a TSD sofre maior influência do gradiente de disponibilidade de água, determinado pela sazonalidade da precipitação e umidade do solo (TERRA et al., 2018), do que da temperatura. Após a estação seca, a vegetação responde rapidamente às chuvas, aumentando significativamente a densidade do dossel e diminuindo a incidência de luz no solo (AMORIM; SAMPAIO; ARAÚJO, 2009; ARAÚJO; CASTRO; ALBUQUERQUE, 2007), justificando a existência de algumas relações lineares com os ISR derivados do EVI, que está bem associado à produtividade da vegetação (WARING et al., 2006) e à biodiversidade, de acordo com a teoria da energia das espécies (WRIGHT, 1983).

Provavelmente, a utilização de equações lineares para investigar as associações entre os ISR e a AGB e a TSD, também tenha prejudicado a compreensão das relações entre as variáveis. Observamos que o padrão de seleção dos ISR pelos modelos de RF, com base na %IncMSE, não necessariamente concorda com os resultados obtidos nas análises de correlação e RLS. Uma razão que apoia estes resultados é o fato do RF consistir em um método de aprendizado de máquina capaz de modelar relacionamentos complexos (PRASAD; IVERSON; LIAW, 2006). Alguns pesquisadores relataram que funções polinomiais podem descrever bem as relações entre métricas derivadas do EVI e a TSD (WARING et al., 2006). Resultados de pesquisas anteriores apontaram que a associação entre temperatura e biodiversidade é dependente do gradiente latitudinal. Na Ásia e na América do Norte, por exemplo, foram

observadas relações fortes e consistentes entre o logaritmo da riqueza de espécies e a temperatura recíproca (WANG, Z. et al., 2009).

Utilizando apenas dados de sensoriamento remoto, as estimativas de TSD podem ser obtidas a partir de quatro métricas anuais da temperatura por meio do modelo RF, que foi capaz de explicar 55% da variação da TSD em MG. Em outra abordagem, modelos RF, baseados em um conjunto bem mais complexo de preditores, composto de variáveis ambientais, de cobertura do terreno e mudanças climáticas, justificaram em média 59,5% da variação na diversidade alfa de plantas vasculares (VEČEŘA et al., 2019). Portanto, incentivamos o desenvolvimento de novos estudos, e recomendamos a utilização de ISR derivados dos produtos do MODIS para modelagem de parâmetros da vegetação, como biomassa e biodiversidade, em níveis globais e regionais.

## 5 CONCLUSÃO

Nossas descobertas mostraram que as estatísticas anuais derivadas dos produtos do MODIS (EVI e LST) geralmente apresentam associações de fracas a moderadas com a AGB e com a TSD nas seis fitofisionomias predominantes do estado de Minas Gerais, Brasil. Adicionalmente, mostramos que o desempenho preditivo de modelos RF baseados nos ISR variou entre os tipos de vegetação, devido aos gradientes estruturais entre e dentro de cada fitofisionomia associados à fatores ambientais e antrópicos. Destacamos que modelos RF baseados nos ISR derivados da LST de baixa resolução espacial (1 km) podem fornecer estimativas satisfatórias da TSD em estudos regionais. Nossos resultados incentivam maiores discussões sobre a utilização de índices temporais de sensoriamento remoto para modelagem de biomassa e da diversidade florestal, considerando outras técnicas de aprendizado de máquina e/ou produtos de vegetação, em diferentes escalas espaciais, uma vez que são variáveis particularmente relevantes ao monitoramento dos estoques de carbono e da biodiversidade terrestre.

## REFERÊNCIAS

- ALI, A. et al. Impacts of climatic and edaphic factors on the diversity, structure and biomass of species-poor and structurally-complex forests. **Science of the Total Environment**, v. 706, n. 2020, p. 1–12, 2020.
- ALKAMA, R.; CESCATTI, A. Biophysical climate impacts of recent changes in global forest cover. **Science**, v. 351, n. 6273, p. 600–604, 2016.
- AMORIM, I. L. DE; SAMPAIO, E. V. DE S. B.; ARAÚJO, E. DE L. Fenologia de Espécies Lenhosas da Caatinga do Seridó, RN. **Revista Árvore**, v. 33, n. 3, p. 491–499, 2009.
- ANAYA, J. A.; CHUVIECO, E.; PALACIOS-ORUETA, A. Aboveground biomass assessment in Colombia: A remote sensing approach. **Forest Ecology and Management**, v. 257, n. 2009, p. 1237–1246, 2009.
- ANDRESEN, E.; ARROYO-RODRÍGUEZ, V.; ESCOBAR, F. Tropical Biodiversity: The Importance of Biotic Interactions for Its Origin, Maintenance, Function, and Conservation. In: DÁTILLO, W.; RICO-GRAY, V. (Eds.). . **Ecological Networks in the Tropics**. Cham, Switzerland: Springer, 2018. p. 1–13.
- ARAÚJO, E. L.; CASTRO, C. C.; ALBUQUERQUE, U. P. Dynamics of Brazilian Caatinga - A Review Concerning the Plants, Environment and People. **Functional Ecosystems and Communities**, v. 1, n. 1, p. 15–28, 2007.
- BARLOW, J. et al. The future of hyperdiverse tropical ecosystems. **Nature**, v. 559, n. 7715, p. 517–526, jul. 2018.
- BERRY, S.; MACKEY, B.; BROWN, T. Potential applications of remotely sensed vegetation greenness to habitat analysis and the conservation of dispersive fauna. **Pacific Conservation Biology**, v. 13, n. 2, p. 120–127, 2007.
- BOYLE, B. et al. The taxonomic name resolution service: An online tool for automated standardization of plant names. **BMC Bioinformatics**, v. 14, n. 16, p. 1–14, 2013.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.
- CHAPUNGU, L. et al. Quantifying Changes in Plant Species Diversity in a Savanna Ecosystem Through Observed and Remotely Sensed Data. **Sustainability**, v. 12, n. 6, p. 1–18, 17 mar. 2020.
- COLOMBO, A. F.; JOLY, C. A. Brazilian Atlantic Forest lato sensu: The most ancient Brazilian forest, and a biodiversity hotspot, is highly threatened by climate change. **Brazilian Journal of Biology**, v. 70, n. 3 (supl.), p. 697–708, 2010.
- COSTANZA, R. et al. Changes in the global value of ecosystem services. **Global Environmental Change**, v. 26, p. 152–158, 2014.
- DAVID, H. C. et al. Carbon stock classification for tropical forests in Brazil: Understanding the effect of stand and climate variables. **Forest Ecology and Management**, v. 404, p. 241–

250, 15 nov. 2017.

DAY, M. et al. Relationships between tree species diversity and above-ground biomass in Central African rainforests: Implications for REDD. **Environmental Conservation**, v. 41, n. 1, p. 64–72, 2014.

DUVEILLER, G.; HOOKER, J.; CESCATTI, A. The mark of vegetation change on Earth's surface energy balance. **Nature Communications**, v. 9, n. 679, p. 1–12, 2018.

FINE, P. V. A. Ecological and Evolutionary Drivers of Geographic Variation in Species Diversity. **Annu. Rev. Ecol. Evol. Syst.**, v. 46, p. 369–92, 2015.

FISHER, R. A.; CORBET, A. S.; WILLIAMS, C. B. The Relation Between the Number of Species and the Number of Individuals in a Random Sample of an Animal Population. **Journal of Animal Ecology**, v. 12, n. 1, p. 42–58, 1943.

FUJII, K. et al. Plant–soil interactions maintain biodiversity and functions of tropical forest ecosystems. **Ecological Research**, v. 33, n. 1, p. 149–160, 1 jan. 2018.

GALIDAKI, G. et al. Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem. **International Journal of Remote Sensing**, v. 38, n. 7, p. 1940–1966, 3 abr. 2017.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 1 dez. 2017.

GUSSO, A. et al. **EMPIRICAL RELATIONSHIP BETWEEN LEAF BIOMASS OF RED PINE FORESTS AND ENHANCED VEGETATION INDEX IN SOUTH KOREA USING LANDSAT-5 TM**. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. **Anais...Prague, Czech Republic: XXIII ISPRS Congress, 2016** Disponível em: <<https://www.researchgate.net/publication/307530802>>. Acesso em: 25 ago. 2020

HOBİ, M. L. et al. A comparison of DHIs derived from different MODIS products as predictors of avian species richness. **Remote Sensing of Environment**, v. 195, n. 2017, p. 142–152, 2017.

HOUSE, J. I. et al. Conundrums in mixed woody – herbaceous plant systems. **Journal of Biogeography**, v. 30, p. 1763–1777, 2003.

LEE, X. et al. Observed increase in local cooling effect of deforestation at higher latitudes. **Nature**, v. 479, 2011.

LI, Y. et al. Local cooling and warming effects of forests based on satellite observations. **Nature Communications**, v. 6, n. 6603, p. 1–8, 2015.

LI, Y. et al. Potential and Actual impacts of deforestation and afforestation on land surface temperature. **Journal of Geophysical Research: Atmospheres**, v. 121, n. 24, p. 14,372–14,386, 27 dez. 2016.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, v. 2, n. 3,

p. 18–22, 2002.

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, 2014.

MACKEY, B. G.; BRYAN, J.; RANDALL, L. **Australia's Dynamic Habitat Template for 2003**. MODIS Vegetation Workshop. **Anais...**Missoula: University of Montana, 2004

MILHEIRAS, S. G.; MACE, G. M. Assessing ecosystem service provision in a tropical region with high forest cover: Spatial overlap and the impact of land use change in Amapá, Brazil. **Ecological Indicators**, v. 99, n. 2019, p. 12–18, 2018.

MILLARD, K.; RICHARDSON, M. On the Importance of Training Data Sample Selection in Random Forest Image Classification: A Case Study in Peatland Ecosystem Mapping. **Remote Sensing**, v. 7, p. 8489–8515, 2015.

MORANDI, P. S. et al. Tree diversity and above-ground biomass in the South America Cerrado biome and their conservation implications. **Biodiversity and Conservation**, v. 29, n. 5, p. 1519–1536, 2020.

NERI, A. V et al. Pedology and plant physiognomies in the cerrado, Brazil. **An Acad Bras Cienc**, v. 85, n. 1, 2013.

OGAYA, R. et al. Satellite data as indicators of tree biomass growth and forest dieback in a Mediterranean holm oak forest. **Annals of Forest Science**, v. 72, n. 1, p. 135–144, 2015.

OLIVEIRA FILHO, A. T. et al. Definição e delimitação de domínios e subdomínios das paisagens naturais do estado de Minas Gerais. In: SCOLFORO, J. R.; CARVALHO, L. M. T. (Eds.). **Mapeamento e Inventário da Flora e dos Reflorestamentos de Minas Gerais**. Lavras: UFLA, 2006. p. 21–35.

PAN, Y. et al. The structure, distribution, and biomass of the world's forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 44, p. 593–622, 2013.

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Long-term rates of mass wasting in Mesters Vig, northeast Greenland: Notes on a re-survey. **Hydrology and Earth System Sciences**, v. 11, p. 1633–1644, 2007.

PETTORELLI, N. et al. Framing the concept of satellite remote sensing essential biodiversity variables: challenges and future directions. **Remote Sensing in Ecology and Conservation**, v. 2, n. 3, p. 122–131, 2016.

PHAN, T. N.; KAPPAS, M. Application of MODIS land surface temperature data: a systematic literature review and analysis. **Journal of Applied Remote Sensing**, v. 12, n. 04, p. 1, 25 out. 2018.

PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. **Ecosystems**, v. 9, n. 2, p. 181–199, 15 mar. 2006.



RADELOFF, V. C. et al. The Dynamic Habitat Indices (DHIs) from MODIS and global biodiversity. **Remote Sensing of Environment**, v. 222, p. 204–214, 1 mar. 2019.

RAZENKOVA, E. et al. Vegetation productivity summarized by the Dynamic Habitat Indices explains broad-scale patterns of moose abundance across Russia. **Scientific Reports**, v. 10, n. 1, p. 1–12, 1 dez. 2020.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna: R Foundation for Statistical Computing, 2019.

RIBEIRO, J. F.; WALTER, B. M. T. As Principais Fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Eds.). . **Cerrado: ecologia e flora**. 1. ed. Brasília, DF: Embrapa Informação Tecnológica, 2008. p. 151–212.

ROCCHINI, D. et al. Satellite remote sensing to monitor species diversity: potential and pitfalls. **Remote Sensing in Ecology and Conservation**, v. 2, n. 1, p. 25–36, 2016.

SAATCHI, S. et al. Modeling distribution of Amazonian tree species and diversity using remote sensing measurements. **Remote Sensing of Environment**, v. 112, n. 2008, p. 2000–2017, 2008.

SCOLFORO, J. R. et al. Amostragem e coleta de dados para equações de volume, peso de matéria seca, tanino, cortiça, óleo, sistema radicular, conversão de volumes e carbono. In: SCOLFORO, J. R.; OLIVEIRA, A. D.; ACERBI JÚNIOR, F. W. A. (Eds.). **Inventário florestal de Minas Gerais: equações de volume, peso de matéria seca e carbono para diferentes fisionomias da flora nativa**. Lavras: Ed. UFLA, 2008. cap. 1, p. 1-65.

SCOLFORO, H. F. et al. Spatial distribution of aboveground carbon stock of the arboreal vegetation in Brazilian Biomes of Savanna, Atlantic Forest and Semi-arid woodland. **PLoS ONE**, v. 10, n. 6, p. 1–20, 2015.

SILVEIRA, E. M. O. et al. Carbon-diversity hotspots and their owners in Brazilian southeastern Savanna, Atlantic Forest and Semi-Arid Woodland domains. **Forest Ecology and Management**, v. 452, n. May, p. 1–12, 2019a.

SILVEIRA, E. M. O. et al. Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. 2019, p. 175–188, 2019b.

SILVEIRA, E. M. O. et al. Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, p. 1–18, 2019c.

SUTTIDATE, N. et al. Tropical bird species richness is strongly associated with patterns of primary productivity captured by the Dynamic Habitat Indices. 2019.

TERRA, M. DE C. N. S. et al. Water availability drives gradients of tree diversity, structure and functional traits in the Atlantic-Cerrado-Caatinga transition, Brazil. **Journal of Plant Ecology**, v. 11, n. 6, p. 803–814, 2018.

TOOMEY, M. et al. Remotely sensed heat anomalies linked with Amazonian forest biomass declines. **Geophysical Research Letters**, v. 38, n. 19, p. n/a-n/a, 1 out. 2011.

TSALYUK, M.; KELLY, M.; GETZ, W. M. Improving the prediction of African savanna vegetation variables using time series of MODIS products. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, n. 2017, p. 77–91, 2017.

VEČEŘA, M. et al. Alpha diversity of vascular plants in European forests. **Journal of Biogeography**, v. 46, p. 1919–1935, 7 set. 2019.

VOIGHT, C. et al. Utilizing GIS and Remote Sensing to Inform Spatial Conservation Planning: Assessing Vulnerability to Future Tropical Forest Loss in Southern Belize. **Proceedings**, v. 2, n. 7, p. 337, 22 mar. 2018.

WANG, G. et al. Modelling above-ground biomass based on vegetation indexes: a modified approach for biomass estimation in semi-arid grasslands. **International Journal of Remote Sensing**, v. 40, n. 10, p. 3835–3854, 2019.

WANG, Z. et al. Temperature dependence, spatial scale, and tree species diversity in eastern Asia and North America. **Proceedings of the National Academy of Sciences**, v. 106, n. 32, p. 13388–13392, 2009.

WARING, U. S. A. R. H. et al. MODIS enhanced vegetation index predicts tree species richness across forested ecoregions in the contiguous. 2006.

WRIGHT, D. H. Species-Energy Theory: An Extension of Species-Area Theory. **Oikos**, v. 41, n. 3, p. 496–506, 1983.

**APÊNDICE A – Material Suplementar**

Tabela S1 – Indicadores de qualidade dos ajustes de regressão linear simples para biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais (Continua).

Equações	ISR	AGB		Fisher	
		R <sup>2</sup>	p-valor	R <sup>2</sup>	p-valor
<b>Globais</b>	<b>EVI_sum</b>	2,45	0,00	3,96	0,00
	<b>EVI_std</b>	3,55	0,00	0,58	0,00
	<b>EVI_mean</b>	2,76	0,00	4,17	0,00
	<b>EVI_p10</b>	0,44	0,00	3,88	0,00
	<b>EVI_p90</b>	5,07	0,00	0,94	0,00
	<b>EVI_cv</b>	1,51	0,00	1,44	0,00
	<b>LST_sum</b>	2,72	0,00	9,22	0,00
	<b>LST_std</b>	1,39	0,00	3,32	0,00
	<b>LST_mean</b>	2,76	0,00	9,01	0,00
	<b>LST_p10</b>	3,36	0,00	10,09	0,00
	<b>LST_p90</b>	3,23	0,00	10,42	0,00
	<b>LST_cv</b>	0,04	0,31	0,44	0,00
	<b>FED</b>	<b>EVI_sum</b>	0,28	0,27	0,43
<b>EVI_std</b>		6,08	0,00	2,27	0,00
<b>EVI_mean</b>		0,27	0,28	0,42	0,18
<b>EVI_p10</b>		4,12	0,00	1,85	0,00
<b>EVI_p90</b>		2,77	0,00	1,47	0,01
<b>EVI_cv</b>		4,90	0,00	1,64	0,01
<b>LST_sum</b>		2,58	0,00	0,13	0,45
<b>LST_std</b>		0,01	0,83	0,03	0,74
<b>LST_mean</b>		2,59	0,00	74,11	0,30
<b>LST_p10</b>		3,19	0,00	29,82	0,22
<b>LST_p90</b>		1,01	0,04	0,07	0,59
<b>LST_cv</b>		0,35	0,22	0,07	0,58
<b>FES</b>		<b>EVI_sum</b>	1,32	0,00	0,89
	<b>EVI_std</b>	1,59	0,00	0,13	0,19
	<b>EVI_mean</b>	1,16	0,00	0,88	0,00
	<b>EVI_p10</b>	1,81	0,00	0,54	0,01
	<b>EVI_p90</b>	0,25	0,07	0,88	0,00
	<b>EVI_cv</b>	2,45	0,00	0,03	0,54
	<b>LST_sum</b>	0,12	0,21	9,26	0,00
	<b>LST_std</b>	0,01	0,67	1,63	0,00
	<b>LST_mean</b>	0,04	0,46	10,10	0,00
	<b>LST_p10</b>	0,21	0,09	11,42	0,00
	<b>LST_p90</b>	0,04	0,43	9,20	0,00
	<b>LST_cv</b>	0,11	0,22	1,61	0,00
	<b>F0m</b>	<b>EVI_sum</b>	1,90	0,17	0,83
<b>EVI_std</b>		1,51	0,22	4,56	0,03
<b>EVI_mean</b>		2,07	0,15	0,88	0,35
<b>EVI_p10</b>		0,19	0,66	0,18	0,67
<b>EVI_p90</b>		2,51	0,11	6,65	0,01
<b>EVI_cv</b>		0,00	0,96	1,05	0,30
<b>LST_sum</b>		4,61	0,03	2,62	0,10
<b>LST_std</b>		1,07	0,30	6,19	0,01

Tabela S1 – Indicadores de qualidade dos ajustes de regressão linear simples para biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais (Conclusão).

Equações	ISR	AGB		Fisher		
		R <sup>2</sup>	p-valor	R <sup>2</sup>	p-valor	
<b>F0m</b>	<b>LST_mean</b>	10,54	0,00	11,30	0,00	
	<b>LST_p10</b>	10,52	0,00	21,84	0,00	
	<b>LST_p90</b>	11,30	0,00	6,65	0,01	
	<b>LST_cv</b>	5,33	0,02	31,12	0,00	
<b>Cdao</b>	<b>EVI_sum</b>	28,22	0,00	14,06	0,01	
	<b>EVI_std</b>	0,89	0,51	2,35	0,28	
	<b>EVI_mean</b>	19,96	0,00	13,33	0,01	
	<b>EVI_p10</b>	14,77	0,00	3,07	0,21	
	<b>EVI_p90</b>	16,48	0,00	16,59	0,00	
	<b>EVI_cv</b>	9,61	0,03	0,36	0,67	
	<b>LST_sum</b>	8,43	0,04	2,08	0,31	
	<b>LST_std</b>	1,07	0,46	0,47	0,63	
	<b>LST_mean</b>	5,59	0,09	13,46	0,01	
	<b>LST_p10</b>	6,79	0,06	11,98	0,01	
	<b>LST_p90</b>	11,37	0,01	14,69	0,01	
	<b>LST_cv</b>	0,02	0,92	5,31	0,10	
	<b>CCer</b>	<b>EVI_sum</b>	8,01	0,00	0,05	0,73
		<b>EVI_std</b>	1,66	0,05	3,49	0,00
<b>EVI_mean</b>		8,68	0,00	0,03	0,80	
<b>EVI_p10</b>		4,35	0,00	0,31	0,40	
<b>EVI_p90</b>		6,52	0,00	1,15	0,11	
<b>EVI_cv</b>		0,20	0,50	3,82	0,00	
<b>LST_sum</b>		1,63	0,05	13,88	0,00	
<b>LST_std</b>		0,84	0,17	1,14	0,11	
<b>LST_mean</b>		2,20	0,02	10,76	0,00	
<b>LST_p10</b>		2,07	0,03	14,72	0,00	
<b>LST_p90</b>		2,95	0,03	5,93	0,00	
<b>LST_cv</b>		3,90	0,00	11,78	0,00	
<b>CSS</b>		<b>EVI_sum</b>	22,10	0,00	6,27	0,00
		<b>EVI_std</b>	6,08	0,00	1,70	0,00
	<b>EVI_mean</b>	21,82	0,00	6,36	0,00	
	<b>EVI_p10</b>	16,00	0,00	3,24	0,00	
	<b>EVI_p90</b>	23,07	0,00	5,66	0,00	
	<b>EVI_cv</b>	0,02	0,76	0,00	0,92	
	<b>LST_sum</b>	12,11	0,00	16,48	0,00	
	<b>LST_std</b>	3,34	0,00	7,57	0,00	
	<b>LST_mean</b>	5,11	0,00	19,19	0,00	
	<b>LST_p10</b>	6,22	0,00	18,94	0,00	
	<b>LST_p90</b>	4,89	0,00	20,22	0,00	
	<b>LST_cv</b>	0,01	0,79	0,65	0,05	

Nota: Globais: Todas as fitofisionomias em conjunto; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; F0m: Floresta Ombrófila; Cdao: Cerradão; CCer: Campo Cerrado; CSS: Cerrado *Sensu Stricto* (CSS); R<sup>2</sup><sub>aj</sub> = Coeficiente de determinação ajustado em porcentagem; p-valor: nível de probabilidade de significância dos ajustes; Os sufixos associados aos Índices de Sensoriamento Remoto (ISR) derivados do EVI e da LST são abreviações de percentil 10 (p10), coeficiente de variação (cv), percentil 90 (p90), média (mean), desvio padrão (std) e somatório (sum).

Fonte: Do autor (2021).

## ARTIGO 2 – MÉTRICAS TEXTURAIS NA MODELAGEM DA BIOMASSA E DA BIODIVERSIDADE ARBÓREA EM MINAS GERAIS

### ARTICLE 2 – TEXTURAL METRIC FOR MODELING ABOVEGROUND BIOMASS AND BIODIVERSITY IN MINAS GERAIS

#### RESUMO

Métricas texturais de imagens de sensoriamento remoto tem demonstrado grande potencial para caracterizar padrões espaciais da vegetação e podem ser bons preditores da biomassa (AGB) e da biodiversidade florestal (TSD). Logo, o objetivo deste estudo foi modelar a AGB e a TSD nas fitofisionomias arbóreas de Minas Gerais (MG), utilizando dados de sensoriamento remoto baseados na variabilidade espacial da produtividade da vegetação, representada pelo EVI (*Enhanced Vegetation Index*), e da temperatura (LST – *Land Surface Temperature*). Para isso, utilizamos como preditores medidas de texturas (média, desvio-padrão, contraste e homogeneidade) de imagens do EVI e da LST derivados do sensor TM do Landsat 5. Na fase de análise exploratória, as relações entre as métricas texturais e a AGB e a TSD foram avaliadas por meio das análises dos coeficientes de correlação de Pearson e de regressão linear simples. O algoritmo *Random Forests* (RF) foi utilizado para selecionar o conjunto ótimo de preditores e modelar a AGB e a TSD nas seis fitofisionomias arbóreas de forma estratificada e não estratificada (global). De modo geral, os resultados indicaram que as texturas de primeira ordem (média e desvio-padrão) derivadas do EVI e da LST exibiram padrões de distribuição similares aos dados de biomassa e diversidade do Inventário Florestal de Minas Gerais. Verificou-se que o procedimento de remoção recursiva foi útil para indicar o conjunto de preditores de maior importância para os modelos. Os modelos RF baseados apenas em métricas texturais do EVI e da LST apresentaram um razoável desempenho preditivo para a AGB e TSD nas fitofisionomias estudadas. As melhores estimativas de AGB foram fornecidas pelos modelos desenvolvidos para o Cerrado *Sensu Stricto* ( $R^2_{aj} = 33,81\%$ ; RMSE = 18,47 Mg/ha; MAE% = 35,87%); em relação à TSD, o modelo global ( $R^2_{aj} = 26,15\%$ ; RMSE = 7,62; MAE% = 39,46%) foi o que demonstrou melhor desempenho. Concluímos que o desempenho preditivo de modelos RF baseados em métricas texturais de imagens do EVI e da LST é moderado e que outros estudos devem ser incentivados, aprimorando a extração de métricas texturais de imagens de sensores com diferentes resoluções espaciais, espectrais e temporais.

**Palavras-chave:** Produtividade da Vegetação. Índice de Vegetação Melhorado. Temperatura da Superfície Terrestre. Matriz de Cooorrência de Nível de Cinza. Landsat. Random Forest.

#### ABSTRACT

Textural metrics of remote sensing images have demonstrated great potential to characterize spatial patterns of vegetation and can be good predictors of biomass (AGB) and forest biodiversity (TSD). Therefore, the aim of this study was to model AGB and TSD in tree phytophysionomies in Minas Gerais (MG), using remote sensing data based on the spatial variability of vegetation productivity, represented by EVI (*Enhanced Vegetation Index*), and temperature (LST - *Land Surface Temperature*). For this, we used as predictors textures

measurements (mean, standard deviation, contrast, and homogeneity) of EVI and LST images derived from the Landsat 5 TM sensor. In the exploratory analysis phase, the relationships between textural metrics and AGB and TSD were evaluated through the analysis of Pearson's correlation coefficients and simple linear regression. The Random Forests (RF) algorithm was used to select the optimal set of predictors and model the AGB and TSD in the six tree phytophysionomies in a stratified and non-stratified (global) manner. In general, the results indicated that the first order textures (mean and standard deviation) derived from EVI and LST exhibited distribution patterns similar to the biomass and diversity data from the Minas Gerais Forest Inventory. It was found that the recursive feature selection procedure was useful to indicate the set of predictors of the greatest importance for the models. The RF models based only on textural metrics from EVI and LST demonstrated a reasonable predictive performance for AGB and TSD in the studied physiognomies. The best estimates of AGB were provided by the models developed for Cerrado *Sensu Stricto* ( $R^2_{aj} = 33.81\%$ ; RMSE = 18.47 Mg / ha; MAE% = 35.87%); in relation to TSD, the global model ( $R^2_{aj} = 26.15\%$ ; RMSE = 7.62; MAE% = 39.46%) was the one that showed the best performance. We conclude that the predictive performance of RF models based on textural metrics of EVI and LST images is moderate, and that other studies should be encouraged, improving the extraction of textural metrics from sensor images with different spatial, spectral, and temporal resolutions.

**Keywords:** Vegetation Productivity. Enhanced Vegetation Index. Land Surface Temperature. Gray Level Co-occurrence Matrix. Landsat. Random Forests.

## 1 INTRODUÇÃO

O aumento das pressões antrópicas sobre os ecossistemas do planeta Terra, em número e em intensidade, tem acelerado fenômenos de mudanças globais, que tem como consequência grandes impactos ambientais. Dentre os impactos ambientais gerados, destaca-se a elevação das taxas de extinção (BARNOSKY et al., 2011), provavelmente associada as mudanças climáticas e perdas de habitat (TRAVIS, 2003). Nesse contexto, muitos esforços têm sido feitos quanto ao desenvolvimento e aperfeiçoamento de métodos para monitorar a biodiversidade (ARAÚJO et al., 2019; ROCCHINI et al., 2018; SAATCHI et al., 2008) e caracterizar a qualidade de habitats baseados nas características da vegetação (PARKES; NEWELL; CHEAL, 2003; WOOD et al., 2012). A quantificação da biomassa acima do solo é uma atividade fundamental para a obtenção de medidas da produtividade florestal e dos estoques de carbono na vegetação (DUFFY; GODWIN; CARDINALE, 2017; LECINA-DIAZ et al., 2018). Adicionalmente, é válido ressaltar que o contexto ambiental influencia diretamente as relações entre a produtividade florestal e a diversidade de árvores (JUCKER et al., 2016). Desse modo, a compreensão dos padrões espaciais das características da vegetação é a base para o planejamento de ações de conservação que priorizem não apenas a manutenção dos estoques de carbono, mas também da biodiversidade.

Mensurar parâmetros ambientais como biomassa e biodiversidade, em grandes áreas, a partir de métodos dependentes de campanhas de campo é uma atividade de alto custo e logisticamente desafiadora. Uma alternativa eficiente consiste na utilização de dados coletados por sensores remotos, uma vez que podem fornecer informações rápidas, gratuitas e globais da superfície terrestre, que são muito úteis à quantificação tanto da biomassa (MIGUEL et al., 2015; SILVEIRA et al., 2019a, 2019b, 2020), quanto da biodiversidade (MENG et al., 2016; ROCCHINI et al., 2018; SILVEIRA et al., 2019c; WU; LIANG, 2018). No entanto, dois pontos críticos devem ser definidos com cautela em estudos de modelagem a partir de dados de sensoriamento remoto. Primeiro, diante da grande abundância de dados disponíveis, existe a necessidade de sumarizar as variáveis mais importantes (ADAME-CAMPOS et al., 2019; RADELOFF et al., 2019; SCHINDLER et al., 2015); e segundo, é preciso escolher algoritmos apropriados, capazes de capturar as relações complexas entre as variáveis preditoras e resposta, para a construção de modelos com bom desempenho preditivo (ARAÚJO et al., 2019; LU et al., 2016).

Diferentes fontes de dados de sensoriamento remoto podem ser utilizadas para estudar as características da cobertura vegetal com diversos objetivos, entre as quais destacam-se os

produtos do programa de satélites Landsat (NASA/USGS) (FARWELL et al., 2020; SILVEIRA et al., 2019b; WOOD et al., 2012). As imagens Landsat são disponibilizadas gratuitamente e fornecem dados de resolução espacial média, que estão entre os mais utilizados para obtenção de estimativas de biomassa (SILVEIRA et al., 2019a, 2019b, 2019d; WAN et al., 2019; ZHU; LIU, 2015) e diversidade arbórea (MADONSELA et al., 2017; MOHAMMADI; SHATAEE, 2010). Diferentes técnicas podem ser utilizadas para extrair variáveis de dados ópticos multiespectrais. Dentre elas, as métricas texturais de imagens tem demonstrado grande potencial para caracterizar padrões de vegetação (GE et al., 2006).

Métricas texturais são determinadas a partir da distribuição espacial e da variação dos valores espectrais dos pixels da imagem (HALL-BEYER, 2017; HARALICK; SHANMUGAM; DINSTEN, 1973). Resultados de pesquisas anteriores apontam que texturas de imagens de satélite têm a capacidade de capturar diferentes aspectos da diversidade estrutural da vegetação (MENG et al., 2016; WOOD et al., 2012). Como variáveis predictoras, têm sido empregadas com sucesso em estudos de modelagem, para obtenção de estimativas rápidas e confiáveis da diversidade de árvores (AKBARI; KALBI, 2017; MADONSELA et al., 2017; OZKAN et al., 2016). Além disso, também possuem maior valor de importância e elevada capacidade de aumentar a performance preditiva de modelos de predição da biomassa, em relação a utilização apenas de variáveis derivadas diretamente de respostas espectrais (DUBE; MUTANGA, 2015; KELSEY; NEFF, 2014; LU, 2005).

Por outro lado, é importante ressaltar que a qualidade das estimativas fornecidas pelos modelos depende principalmente da compreensão das relações entre as informações espectrais e os parâmetros da vegetação medidos no campo, ou seja, quais são os principais fatores e como influenciam a distribuição espacial dos parâmetros avaliados (HERNÁNDEZ-STEFANONI et al., 2012). Por exemplo, a temperatura da superfície terrestre (LST, do inglês *Land Surface Temperature*), apresenta relações intrínsecas com características da cobertura vegetal, governadas pela disponibilidade de água (HOLZMAN; RIVAS; PICCOLO, 2014; SIMS et al., 2008), e pode ser obtida a partir de valores de reflectância do infravermelho termal (CRISTÓBAL et al., 2018; WANG, M. et al., 2016). Já o índice de vegetação melhorado (EVI, do inglês *Enhanced Vegetation Index*) fornece estimativas de produtividade da vegetação equivalentes, e até superiores, àquelas obtidas a partir de métodos baseados em amostragem de campo ou da extrapolação de dados climáticos e fisiográficos (WARING et al., 2006).

Embora as relações entre parâmetros florestais e variáveis derivadas de sensoriamento remoto, como EVI e LST, sejam frequentemente muito complexas, algoritmos não paramétricos possuem a habilidade de construir estruturas de modelagem de forma orientada



pelo conjunto de dados. O algoritmo de florestas aleatórias (RF, do inglês *Random Forests*), desenvolvido por Breiman (2001), está entre os métodos de aprendizado de máquina mais comumente utilizados para obtenção de estimativas de biomassa (SILVEIRA et al., 2019a, 2019b, 2019d, 2020; WAN et al., 2019; WANG, L. et al., 2016) e diversidade (DIVÍŠEK; CHYTRÝ, 2017; PRASAD; IVERSON; LIAW, 2006; SILVEIRA et al., 2019c; VEČEŘA et al., 2019). Em síntese, a abrangente aplicação do RF em pesquisas florestais está associada às possibilidades de modelar interações não lineares no conjunto de dados, ranquear e classificar as variáveis mais importantes, dispensar as pressuposições de distribuições de frequência e ausência de multicolinearidade e lidar com alta dimensionalidade de dados, além de ser relativamente robusto em relação à presença de ruídos nos dados de treinamento e retornar modelos com bom desempenho preditivo (BELGIU; DRAGUT, 2016; BREIMAN, 2001).

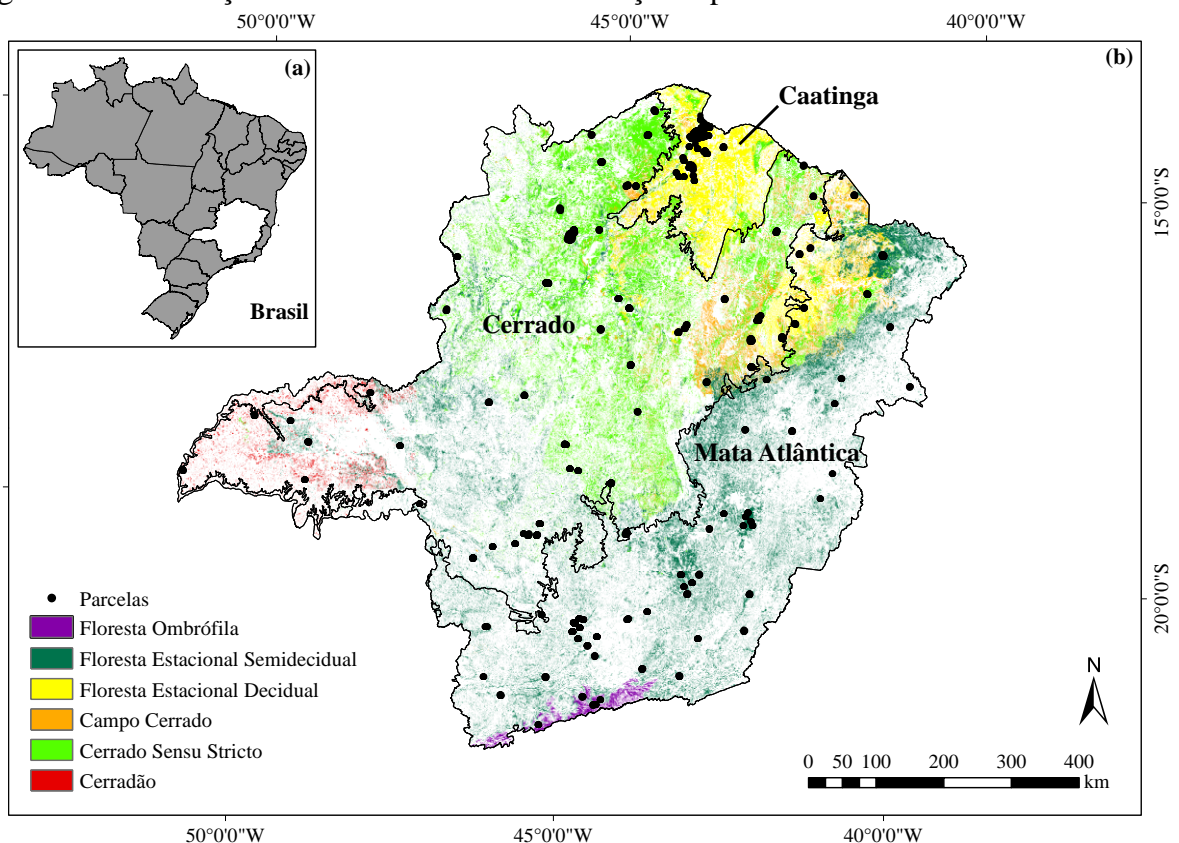
Com base no exposto, e considerando que a heterogeneidade espacial da produtividade da vegetação, assim como as variações de temperatura são aspectos particulares de cada tipo de vegetação, que podem ser capturados por métricas texturais de imagens do EVI e da LST, assume-se a seguinte questão: Texturas de imagens do EVI e da LST são capazes de explicar as variações dos padrões de distribuição e fornecer estimativas confiáveis da biomassa arbórea acima do solo (AGB) e diversidade de espécies de árvores (TSD) da vegetação de florestas tropicais? Visando solucionar a pergunta científica anterior, o objetivo desta pesquisa foi modelar a AGB e a TSD em Minas Gerais (MG) e em cada fitofisionomia individualmente (Cerradão, Campo Cerrado, Cerrado *Sensu Stricto*, Floresta Estacional Decidual, Floresta Estacional Semidecidual e Floresta Ombrófila), utilizando o algoritmo RF e dados de sensoriamento remoto baseados na variabilidade espacial da produtividade (EVI) e da temperatura da superfície terrestre (LST).

## 2 MATERIAL E MÉTODOS

### 2.1 Área de Estudo

O estudo foi conduzido nas fitofisionomias arbóreas dos biomas Cerrado, Mata Atlântica e Caatinga no estado de Minas Gerais (MG), pertencente à região Sudeste do Brasil (Figura 1a). O território mineiro tem área de aproximadamente 586.521 km<sup>2</sup> e apresenta grande variação de clima, solo e relevo (INSTITUTO BRASILEIRO DE GEORGRAFIA E ESTATÍSTICA – IBGE, 2018). À alta diversidade ambiental estão associadas a predominância espacial dos biomas e a ocorrência das zonas de transição entre eles no estado (Figura 1b) (SILVEIRA et al., 2019d; TERRA et al., 2018).

Figura 1 – Localização da área de estudo e distribuição espacial dos biomas em Minas Gerais.



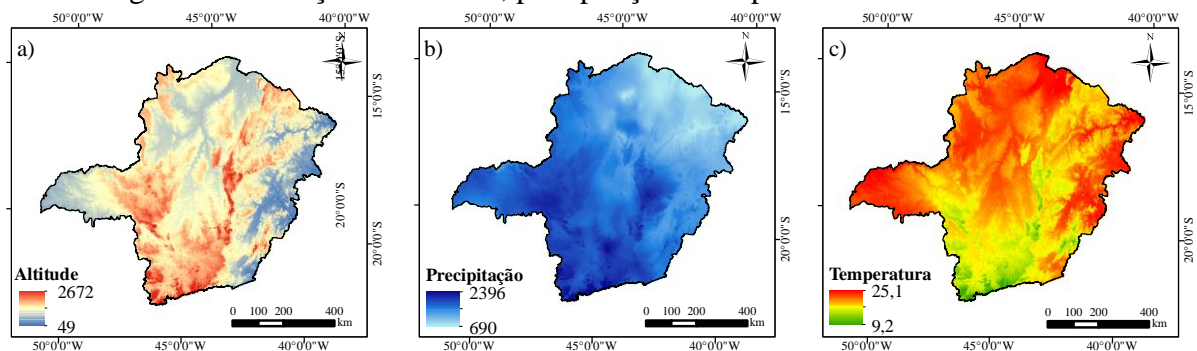
Legenda: a) Localização do estado de Minas Gerais no Sudeste do Brasil; b) Distribuição espacial dos biomas no estado.

Fonte: Do autor (2021).

O relevo da área de estudo é marcado por altitudes entre 900 e 1500 metros (Figura 2a), exceto nas regiões leste e sul, onde esta diferença é mais acentuada, com valores inferiores a 100 e ultrapassando dois mil metros em relação ao nível do mar (FILPI, 2019; SCOLFORO et

al., 2015). Os solos são representados principalmente pelas classes Latossolos (54%), Cambissolos (17,3%), Neossolos (12,5%) e Argissolos (11,3%) (UNIVERSIDADE FEDERAL DE VIÇOSA et al., 2010). A variabilidade climática é determinada por um gradiente positivo de precipitação e negativo de temperatura no sentido Norte-Sul (Figura 2b e 2c) (SCOLFORO et al., 2015; SILVEIRA et al., 2020). A precipitação média fica entre 690 e 2396 mm anuais (Figura 2b); enquanto a temperatura média anual vai de 9,2 a 25,1 °C (Figura 2c) (FICK; HIJMANS, 2017).

Figura 2 – Variação de altitude, precipitação e temperatura em Minas Gerais.



Legenda: a) Mapa de altitude (em metros) derivado do modelo digital de elevação disponibilizado pela NASA-SRTM (*Shuttle Radar Topography Mission*); b) Mapa de precipitação média anual (em milímetros) derivado da variável Bio12 do WorldClim 2.0; c) Mapa de temperatura média anual (em graus Celsius) derivado da variável Bio1 do WorldClim 2.0.

Fonte: Do autor (2021).

O Cerrado compõe 57% da vegetação nativa de Minas Gerais, ocorrendo predominantemente nas regiões oeste, noroeste, norte e central do estado (SCOLFORO et al., 2015; SILVEIRA et al., 2019d, 2020). Se desenvolve sob condições de clima tropical, com inverno seco (Aw, segundo a classificação de Köppen). A temperatura média anual está entre 22 e 23 °C. A precipitação média anual varia de 1200 a 1800 mm, com concentração das chuvas no verão, distribuídas de outubro a março (SCOLFORO et al., 2015; SILVEIRA et al., 2019e). A vegetação heterogênea compreende fitofisionomias que variam de pastagens secas a savanas densamente arborizadas (SCOLFORO et al., 2015). A cobertura arbórea-arbustiva é altamente variada, podendo ser ausente ou insignificante, como no Campo Limpo, ou presente, equivalente a 10% no Campo Sujo, em torno de 20-50% no típico Cerrado *Sensu Stricto*, e chegando até a 90% no Cerradão, com árvores de até 15 metros de altura (OLIVEIRA FILHO et al., 2006; RIBEIRO; WALTER, 2008; RIBEIRO et al., 2011).

A Mata Atlântica ocupa as regiões centro-sul e leste, onde prevalecem climas chuvosos com temperaturas mais amenas. O bioma representa 41% da vegetação estadual e é classificado

em duas fitofisionomias, cujas variações a nível de diversidade de espécies estão relacionadas às flutuações nas escalas de temperatura média anual e umidade do solo (COLOMBO; JOLY, 2010; SILVEIRA et al., 2019c; TERRA et al., 2018). Dessa forma, as florestas semidecíduas do bioma são mais representativas em termos de área e estão presentes sob condições climáticas com estiagem de dois a cinco meses. Enquanto as florestas ombrófilas ocorrem sob clima quente e úmido, com temperatura média anual em torno de 25 °C e chuvas bem distribuídas ao longo do ano (COLOMBO; JOLY, 2010; LEITMAN et al., 2015; SCOLFORO et al., 2015; SILVEIRA et al., 2019c, 2020).

A Caatinga, que se desenvolve no norte e nordeste de MG, constitui 2% da vegetação nativa estadual, é um bioma exclusivamente brasileiro e uma das maiores áreas semiáridas do mundo (ARAÚJO; SILVA, 2010; MILES et al., 2006; MORO et al., 2016). As condições de clima semiárido e subúmido, com estação seca bem definida, temperaturas elevadas e baixa precipitação anual, com 80% das chuvas distribuídas irregularmente na estação chuvosa (ARAÚJO; CASTRO; ALBUQUERQUE, 2007; COSTA et al., 2014; OLIVEIRA FILHO et al., 2006; SCOLFORO et al., 2015), impõem as características de resiliência da vegetação heterogênea, resistente aos períodos de seca prolongados, de porte arbóreo, arbustivo e herbáceo, geralmente caducifólia e espinhosa, rica em cactáceas e bromeliáceas (ALVES; ARAÚJO; NASCIMENTO, 2009; ARAÚJO; CASTRO; ALBUQUERQUE, 2007). As fitofisionomias são classificadas em floresta estacional decidual e floresta estacional semidecidual (SILVEIRA et al., 2019f, 2020).

## **2.2 Base de Dados**

### **2.2.1 Medições de Campo**

Foram utilizados dados da AGB e da TSD de 2755 parcelas de campo do Inventário Florestal de Minas Gerais (IFMG), conduzido pela Universidade Federal de Lavras (UFLA) em parceria com o Instituto Estadual de Florestas (IEF). Deste total, foram distribuídas 229 parcelas no Campo Cerrado (CCer), 52 no Cerradão (Cdao) e 565 no Cerrado *Sensu Stricto* (CSS), totalizando 846 parcelas no domínio do Cerrado; 1372 foram distribuídas na Floresta Estacional Semidecidual (FES) e 103 na Floresta Ombrófila (FOM), somando 1475 parcelas pertencentes às fitofisionomias da Mata Atlântica; por fim, 434 parcelas foram distribuídas nas Florestas Estacionais Deciduais (FED) da Caatinga.

As parcelas de campo (10 x 100 m) do IFMG foram lançadas entre 2006 e 2008, georreferenciadas e o procedimento de amostragem adotado foi o sistemático em dois estágios (SCOLFORO et al., 2015). Todas as árvores com no mínimo 5 cm de diâmetro a altura do peito (DAP), medido a 1,30 m do nível do solo, foram medidas e identificadas taxonomicamente de acordo com o Serviço de Resolução de Nomes Taxonômicos (TNRS do inglês *Taxonomic Name Resolution Service*) (<http://tnrs.iplantcollaborative.org>) (BOYLE et al., 2013).

A determinação da AGB foi realizada considerando indivíduos representativos de cada fitofisionomia em diferentes classes de diâmetro e altura. Os indivíduos selecionados foram georreferenciados, cortados e cubados pelo método de Huber. O peso seco foi determinado em laboratório a partir das amostras de madeira de cada árvore. A partir das equações ajustadas com os dados de campo, foram obtidas as estimativas de biomassa de cada parcela. Em seguida a quantidade de biomassa por parcela foi extrapolada para hectares (Mg/ha). Scolforo et al. (2008) descrevem detalhadamente a metodologia utilizada para quantificação da biomassa durante o IFMG.

O índice alfa de Fisher (FISHER; CORBET; WILLIAMS, 1943) foi utilizado para representar a TSD. O alfa de Fisher é determinado pela relação entre o número de indivíduos e o número de espécies presentes em uma área e foi calculado para cada parcela, conforme a equação 1, na qual  $\alpha$  é o alfa de Fisher,  $S$  é o número de espécies e  $n$  é o número de indivíduos computados na parcela.

$$S = \alpha * \ln \left( 1 + \frac{n}{\alpha} \right) \quad (1)$$

### 2.2.2 Variáveis de Sensoriamento Remoto

O conjunto de preditores usado na modelagem da biomassa e do alfa de Fisher é composto por quatro tipos de métricas texturais, extraídas do EVI e da LST, visando englobar os aspectos da produtividade vegetal e do clima da área de estudo (Quadro 1). As métricas texturais fornecem informações sobre a heterogeneidade do habitat dentro das classes que não são capturadas pelas classificações categóricas de cobertura do solo e contribuem com poder explicativo adicional na modelagem espacial (FARWELL et al., 2020). Na análise de textura de uma imagem, um valor de textura é calculado a partir dos valores espectrais de todos os pixels dentro de uma determinada unidade de análise (HALL-BEYER, 2017). O processamento das imagens necessário à obtenção das variáveis utilizadas foi desenvolvido no ambiente do

Google Earth Engine (GEE), uma plataforma de computação em nuvem, que abriga um amplo repositório de conjuntos de dados geospaciais publicamente disponíveis e permite a realização de análises geospaciais gratuitamente (GORELICK et al., 2017).

Quadro 1 – Descrição das métricas texturais extraídas das imagens das medianas do EVI e da LST no ano de estudo (2007) usadas como preditores na modelagem da biomassa arbórea acima do solo e diversidade de espécies arbóreas nas florestas de Minas Gerais.

Preditores		Descrição
Produtividade	Clima	
EVI_mean3x3	LST_mean3x3	Média: Textura de primeira ordem definida pela média dos valores dos níveis de cinza da imagem sob janela de 3x3 pixels;
EVI_std3x3	LST_std3x3	Desvio-padrão: Textura de primeira ordem definida pela dispersão dos valores dos níveis de cinza da imagem sob janela deslizante de 3x3 pixels;
EVI_contrast3x3	LST_contrast3x3	Contraste: Textura de segunda ordem derivada da GLCM, determinada pela diferença exponencial ponderada entre valores de pixels adjacentes em uma janela de 3x3. É o oposto de homogeneidade;
EVI_homogeneity3x3	LST_homogeneity3x3	Homogeneidade: Textura de segunda ordem derivada da GLCM, determinada pelo grau de similaridade entre valores entre pixels adjacentes.

Nota: GLCM: Gray Level Co-occurrence Matrix.

Fonte: Hall-Beyer (2017); Haralick, Shanmugam e Dinstein (1973).

Para calcular as texturas relacionadas a produtividade (derivadas do EVI) e ao clima (derivadas da LST), utilizou-se os dados de reflectância da superfície terrestre do sensor TM do Landsat 5, disponíveis no catálogo de imagens do GEE (LANDSAT/LT05/C01/T1\_SR), disponibilizadas com correções geométricas e atmosféricas. No pré-processamento, foram utilizados os recursos de filtragem temporal e espacial, considerando o intervalo de tempo de 01 de janeiro de 2007 a 31 de dezembro de 2007 e o polígono da área de estudo (o estado Minas Gerais), além de máscaras para remoção de nuvens e corpos d'água. Os valores de reflectância na banda termal (B6) em Kelvin foram transformados segundo o fator de escala (0,1) e em seguida convertidos em graus Celsius. Uma banda com os valores do EVI foi criada e adicionada à cada cena utilizada, conforme a equação 2, onde NIR, R e B são respectivamente

os valores de reflectância nas bandas do infravermelho próximo (B4), do vermelho (B3) e do azul (B1) (HUETE et al., 2002).

$$EVI = 2,5 \frac{(NIR - R)}{(NIR + 6 * R - 7,5 * B + 1)} \quad (2)$$

Posteriormente, um redutor estatístico foi utilizado para a obtenção das imagens individuais representadas pelas medianas do EVI e da LST, calculadas a partir das séries temporais do ano de 2007. As imagens das medianas foram convertidas para 8 bits e em seguida utilizadas para calcular as variáveis texturais de primeira ordem, média e desvio padrão. Já as variáveis de segunda ordem foram obtidas por meio da Matriz de Coocorrência de Nível de Cinza (GLCM, do inglês *Gray Level Co-occurrence Matrix*). A GLCM contém as frequências normalizadas com as quais os níveis de cinza de pixels adjacentes coocorrem dentro da unidade de análise e, portanto, refletem os padrões espaciais e as relações entre pixels vizinhos (FARWELL et al., 2021; HALL-BEYER, 2017). Diferentes tipos de texturas podem ser derivadas da GLCM, neste estudo foram utilizadas contraste e homogeneidade. Desse modo, foram calculadas as métricas texturais média, desvio padrão, contraste e homogeneidade para cada pixel em janelas deslizantes de 3 x 3 pixels sobre as medianas do EVI e da LST, formando o conjunto de oito variáveis preditoras. Por fim, os valores dos pixels de cada variável foram associados às coordenadas das parcelas de campo do IFMG.

### 2.3 Análises Exploratórias

Para investigar quais características de heterogeneidade da vegetação podem ser capturadas pelas texturas das imagens, avaliou-se primeiramente a relação entre o conjunto de métricas texturais do EVI e da LST e a distribuição espacial das variáveis dependentes (texturas x AGB/TSD), utilizando-se o coeficiente de correlação de Pearson. Em seguida, para determinar a quantidade da variação na AGB e na TSD que poderia ser explicada pelas medidas de textura da produtividade e do clima, foram utilizadas técnicas de regressão linear simples (RLS). Desse modo, as capacidades de explicação individuais das métricas texturais sobre as variáveis de interesse foram medidas pelo coeficiente de determinação ( $R^2$ ) e pelo nível de probabilidade de significância (p-valor) das equações ajustadas. Tanto as análises de correlação, quanto as análises de RLS foram conduzidas para a área de estudo como um todo, retornando

resultados globais, quanto de forma estratificada, para obtenção de resultados por fitofisionomia, usando pacotes do software R (R CORE TEAM, 2019).

## 2.4 Modelagem de Biomassa e Biodiversidade da Vegetação

Os modelos de predição da AGB e da TSD foram desenvolvidos tanto para as seis fitofisionomias arbóreas de MG agrupadas (modelo global), quanto de forma estratificada (modelos por fitofisionomia). Para isso, o algoritmo utilizado foi o *Random Forests* (RF) com seleção de variáveis por remoção recursiva em ordem crescente de importância no modelo (MILLARD; RICHARDSON, 2015; SILVEIRA et al., 2019b).

O RF foi implementado por meio da utilização do pacote *randomForest* (LIAW; WIENER, 2002), disponível no software R (R CORE TEAM, 2019). Do conjunto de dados, 70% foram selecionados aleatoriamente para compor a amostra de treinamento e ajustar os modelos, os outros 30% restantes foram reservados para os testes de desempenho. O número de árvores de decisão (ntree) cultivadas para regressão foi 1000. O procedimento de remoção recursiva ocorreu de maneira iterativa. A cada iteração, o algoritmo é treinado desconsiderando uma variável, e com base no incremento no erro médio quadrático, em termos percentuais (%IncMSE, do inglês *Mean-Squared Error*), associado à não utilização da variável, os preditores são ranqueados em ordem crescente de importância. Dessa forma, as métricas texturais de menor relevância foram eliminadas sucessivamente e ao final, a partir da iteração de menor erro, o subconjunto de preditores ótimos foi utilizado para treinar um novo RF e obtenção dos modelos de predição.

A performance preditiva da modelagem foi avaliada com base na análise gráfica dos resíduos; no coeficiente de determinação ajustado ( $R^2_{aj}$ ) que representa a percentagem da variabilidade dos dados explicada pelo modelo; no erro médio absoluto (MAE, do inglês *Mean Absolute Error*) que indica a tendência média de subestimação ou superestimação dos modelos, em percentagem (Equação 3); e na raiz do erro médio quadrático (RMSE, do inglês *Root-Mean-Squared Error*) calculada pelo desvio médio entre os valores estimados e os observados (Equação 4) (SILVEIRA et al., 2019b). Nas equações 3 e 4 a seguir,  $n$  corresponde ao número de parcelas; e  $O_i$  e  $E_i$  representam os valores observados e estimados respectivamente.



$$MAE(\%) = \frac{1}{n} \sum_i^n \frac{O_i - E_i}{O_i} 100 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_i^n (E_i - O_i)^2}{n}} \quad (4)$$

### 3 RESULTADOS

#### 3.1 Análises Exploratórias das Texturas das Imagens, Biomassa e Diversidade

Como esperado, as fitofisionomias do Cerrado, CCer, CSS e Cdao, exibiram menores médias de biomassa por hectare, em ordem crescente, seguidas da FED da Caatinga, e da FES e da FOm da Mata Atlântica. Em relação ao índice alfa de Fisher, a ordem entre as fitofisionomias da Caatinga e do Cerrado se inverteram, de forma que a menor TSD ocorreu na FED, seguida do CCer, CSS, Cdao, FES e FOm (Figura 3). Os valores das texturas derivadas do EVI (EVI\_mean3x3 e EVI\_std3x3) exibiram um padrão de distribuição similar ao da AGB e da TSD entre as fitofisionomias do Cerrado e da Mata Atlântica (Figura 3). As médias das texturas da LST (LST\_mean3x3 e LST\_std3x3) também seguem um padrão de distribuição esperado, indicando temperaturas médias mais elevadas e mais estáveis (menor desvio padrão) na Caatinga, seguida do Cerrado e Mata Atlântica (Figura 3).

Figura 3 – Amplitude de variação e distribuição da biomassa arbórea acima do solo, diversidade de espécies arbóreas e características das texturas das imagens medianas do EVI e da LST nas parcelas do Inventário Florestal de Minas Gerais (Continua).

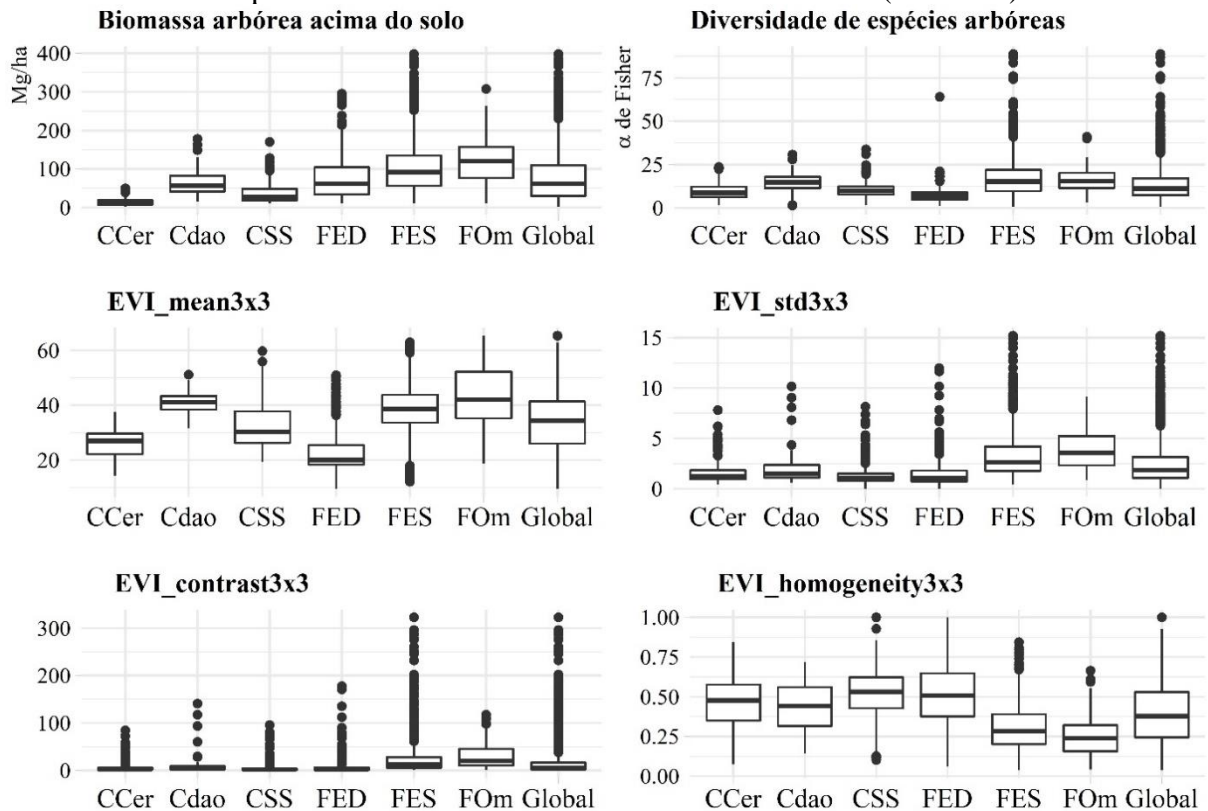
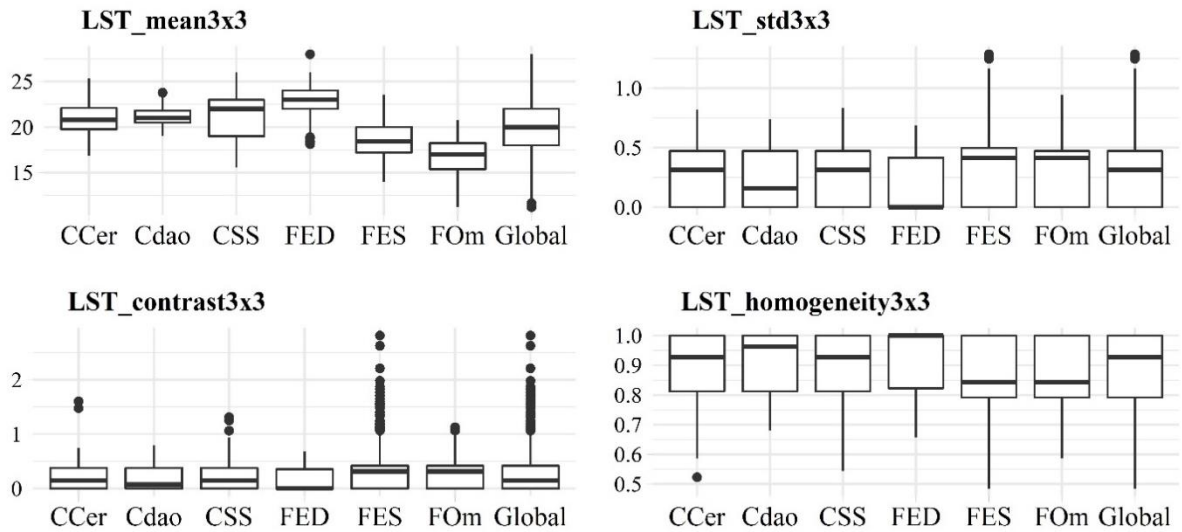


Figura 3 – Amplitude de variação e distribuição da biomassa arbórea acima do solo, diversidade de espécies arbóreas e características das texturas das imagens medianas do EVI e da LST nas parcelas do Inventário Florestal de Minas Gerais (Conclusão).



Nota: Global: Todas as fitofisionomias em conjunto; CCer: Campo Cerrado; Cdao: Cerradão; CSS: Cerrado *Sensu Stricto*; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOm: Floresta Ombrófila. As abreviações que definem os preditores indicam as métricas texturais derivadas do EVI e da LST, sob janela deslizante de 3x3 pixels: média (mean), desvio-padrão (std), contraste (contrast) e homogeneidade (homogeneity).

Fonte: Do autor (2021).

Na Mata Atlântica, as relações entre as variáveis dependentes e as métricas texturais de produtividade e temperatura variaram entre as fitofisionomias. Na FES, a medida de textura LST\_mean3x3 exibiu correlação linear moderada negativa ( $\rho = -0,33$ ) com a TSD. Enquanto na FOm, tanto a AGB, quanto a TSD apresentaram correlações lineares fracas com as métricas texturais ( $-0,27 \leq \rho \leq 0,12$ ). Os resultados das equações da RLS (Tabela S1, Apêndice A) corroboram com os obtidos nas correlações de Pearson. Na FES, a melhor equação aponta que a LST\_mean3x3 pode explicar até 10,67% da variação do alfa de Fisher; enquanto na FOm, apesar dos baixos valores do  $R^2$ , os melhores resultados foram obtidos em função de texturas derivadas do EVI (EVI\_std3x3, EVI\_contrast3x3 e EVI\_homogeneity3x3).

Considerando as fitofisionomias do Cerrado, no CSS, as texturas médias (LST\_mean3x3 e EVI\_mean3x3) apresentaram maiores valores de correlação tanto com a AGB ( $\rho = -0,35$  e  $\rho = 0,39$ , respectivamente), quanto com a TSD ( $\rho = 0,37$  e  $\rho = -0,36$ , respectivamente) em relação às demais métricas texturais. No CCer, as correlações lineares entre as texturas e a AGB são semelhantes ao observado no CSS, uma vez que a variável de interesse foi moderadamente correlacionada com as texturas médias (LST\_mean3x3 e EVI\_mean3x3); porém com a TSD apenas a métrica LST\_mean3x3 retornou coeficiente de Pearson moderado ( $\rho = 0,29$ ). Enquanto no Cdao, a maioria das correlações entre as variáveis

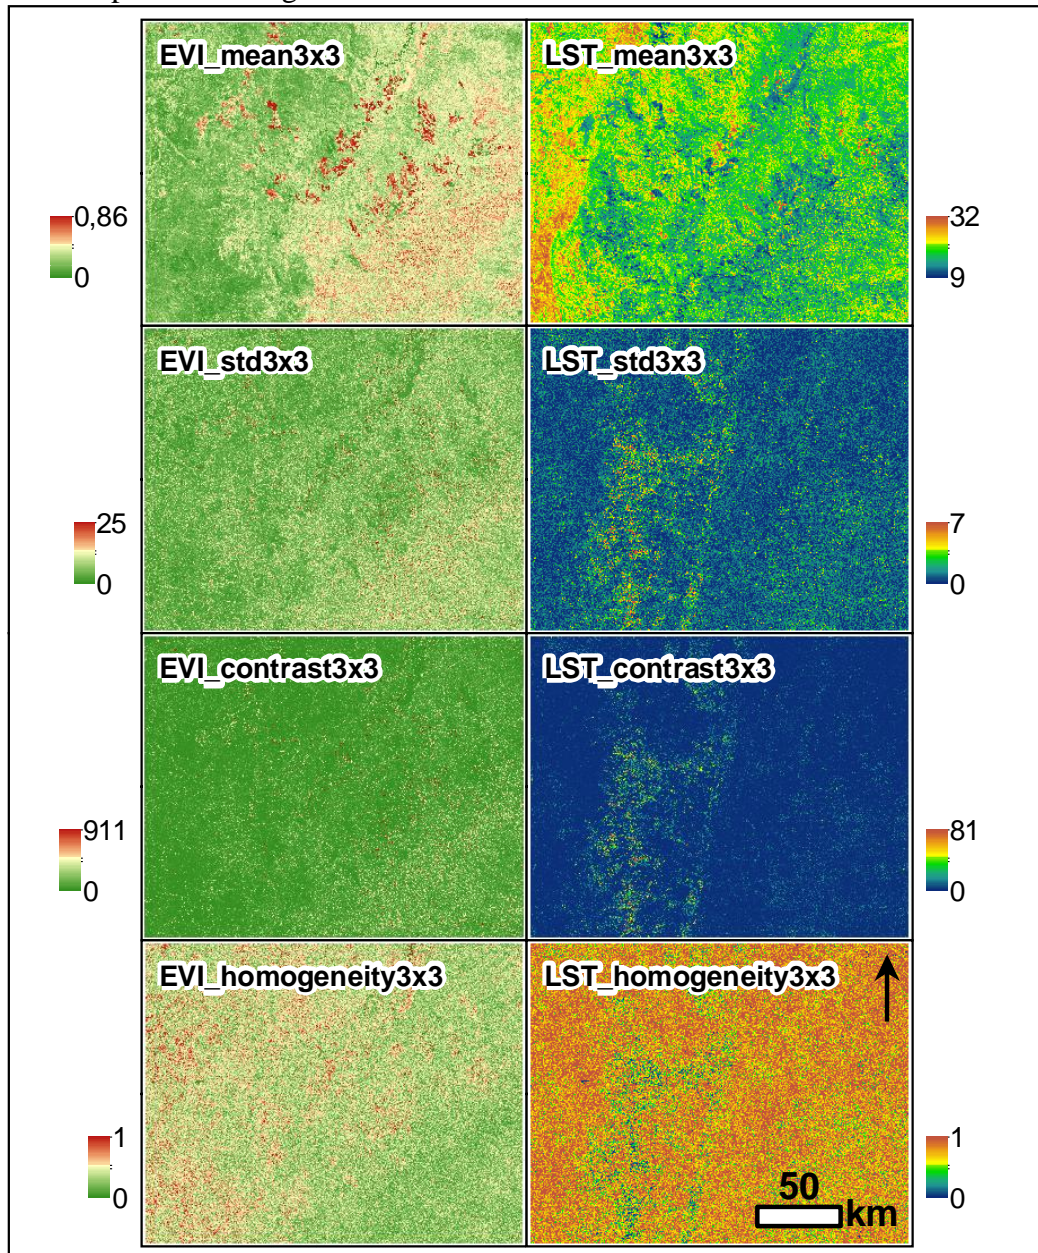
foram moderadas, porém, nesse caso, as métricas texturais foram mais associadas à AGB ( $-0,43 \leq \rho \leq 0,51$ ) do que a TSD ( $-0,38 \leq \rho \leq 0,30$ ). As equações resultantes da RLS para as fitofisionomias do Cerrado exibiram desempenho em concordância com as associações indicadas nas análises de correlação (Tabela S1, Apêndice A).

De modo geral, nas parcelas da FED na Caatinga, as métricas texturais exibiram correlações lineares fracas tanto com a AGB, quanto com a TSD ( $-0,13 \leq \rho \leq 0,14$ ). Por meio do desempenho das equações resultantes da análise de RLS, observamos a inexistência de relações lineares entre a maioria das métricas texturais e ambas as variáveis dependentes na FED (Tabela S1, Apêndice A). Considerando todas as fitofisionomias de MG, observamos que as medidas de textura do EVI e da LST possuem correlações lineares fracas tanto com a AGB, quanto com a TSD. A única exceção aconteceu entre a TSD e a LST\_mean3x3, que foram moderadamente correlacionadas entre si ( $\rho = -0,37$ ). Por outro lado, todas as equações univariadas globais foram significativas, a 90% de confiança (p-valor < 0,1), e apesar dos baixos valores de R<sup>2</sup>, os melhores resultados foram em função da LST\_mean3x3 tanto para AGB, quanto para a TSD (Tabela S1, Apêndice A).

### **3.2 Heterogeneidade da Vegetação Capturada pelas Métricas Texturais**

As métricas texturais foram eficientes em capturar a heterogeneidade das classes de cobertura do solo, bem como as diferenças dentro de uma mesma classe devido aos gradientes de precipitação e temperatura. Por exemplo, a métrica EVI\_mean3x3 foi eficiente em capturar as diferenças entre as classes de florestas nativas e plantadas que ocorrem ao longo da Serra do Espinhaço. Similarmente, a métrica LST\_mean3x3 capturou bem a diferença de temperatura entre as áreas mais quentes na base e as áreas mais frias no topo da Serra do Espinhaço. As métricas EVI\_mean3x3, EVI\_std3x3 e EVI\_contrast3x3 capturaram a alta variabilidade espacial entre as áreas vegetadas e áreas não vegetadas como estradas e aceiros. Já as métricas de desvio padrão, contraste e homogeneidade da temperatura (LST\_std3x3, LST\_contrast3x3 e LST\_homogeneity3x3) foram eficientes em capturar a alta variabilidade espacial da temperatura no topo da serra, onde prevalecem formações de campos rupestres, comparada a baixa variabilidade espacial da temperatura nas áreas de campo e de Floresta Estacional Semidecidual. A métrica EVI\_homogeneity3x3 foi responsável por capturar a variabilidade existente entre as fitofisionomias do Cerrado, uma vez que os remanescentes florestais do domínio apresentam diferentes densidades e graus de cobertura do solo, ocasionando uma maior heterogeneidade dentro da classe (Figura 4).

Figura 4 – Métricas de texturas derivadas do EVI e da LST calculadas sob janela deslizante de 3x3 pixels de imagens do sensor TM do Landsat 5.



Nota: Para otimizar o processamento da Figura 4, as imagens correspondem à uma região amostral do estado de Minas Gerais, Brasil, que está localizada entre 16°49'23'' e 18°26'27'' de latitude Sul e 42°7'56'' e 44°10'32'' de longitude Oeste.

Fonte: Do autor (2021).

### 3.3 Random Forests

Os indicadores de qualidade dos modelos selecionados para obtenção de estimativas da AGB e da TSD nas fitofisionomias arbóreas de MG, que foram construídos a partir de métricas texturais de imagens da produtividade (EVI) e do clima (LST) estão apresentados na Tabela 1.

A raiz do erro médio quadrático (RMSE) variou, entre os modelos, em concordância com as médias de AGB (Mg/ha) e TSD (alfa de Fisher) obtidas a partir dos dados do IFMG (Figura 3); enquanto o erro médio absoluto em termos percentuais (MAE%) gerado em decorrência da utilização das estimativas, obtidas a partir dos modelos RF, variou entre 25,60% e 55,76% (Tabela 1).

Tabela 1 – Indicadores de qualidade dos modelos Random Forests obtidos para a biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais em função de medidas de texturas de imagens.

<b>Estatísticas</b>	<b>Global</b>	<b>FES</b>	<b>FED</b>	<b>FOM</b>	<b>CSS</b>	<b>Cdao</b>	<b>CCer</b>
<b>----- Biomassa -----</b>							
<b>RMSE</b>	54,45	57,84	49,01	61,83	18,47	32,61	9,37
<b>MAE%</b>	50,33	46,93	44,77	37,62	35,87	41,12	55,76
<b>R<sup>2</sup><sub>aj</sub></b>	22,03%	-	26,55%	-	33,81%	-	-
<b>----- <math>\alpha</math> de Fisher -----</b>							
<b>RMSE</b>	7,62	10,05	3,42	4,83	3,64	7,01	3,32
<b>MAE%</b>	39,46	45,30	38,06	25,60	27,56	50,05	31,15
<b>R<sup>2</sup><sub>aj</sub></b>	26,15%	13,29%	-	-	3,60%	-	20,78%

Nota: Global: Todas as fitofisionomias em conjunto; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOM: Floresta Ombrófila; Cdao: Cerradão; CCer: Campo Cerrado; CSS: Cerrado *Sensu Stricto* (CSS); RMSE: Raiz do Erro Médio Quadrático; MAE%: Erro Médio Absoluto em porcentagem; R<sup>2</sup><sub>aj</sub> = Coeficiente de determinação ajustado em porcentagem.

Fonte: Do autor (2021).

Os conjuntos de preditores ótimos para a modelagem, obtidos por meio da técnica de remoção recursiva, foram compostos pelas medidas de texturas que, quando não utilizadas, foram responsáveis por maiores %IncMSE (Tabela 2). Nos modelos RF Globais, a LST\_mean3x3 foi a variável explicativa de maior importância para a modelagem, responsável por %IncMSE de 39,26% e 43,24% nos modelos de TSD e AGB, respectivamente (Tabela 2). Analisando o desempenho da modelagem por fitofisionomia, nos modelos que contribuíram com a explicação da variação na TSD em cada tipo de vegetação (FES, CSS e CCer), a variável preditora responsável por maior %IncMSE foi a LST\_mean3x3 (44,08%, 35,17% e 28,82% respectivamente). Algumas medidas texturais do EVI também foram selecionadas pelos modelos de TSD. Por outro lado, a maioria dos preditores dos modelos capazes de explicar alguma parte da variação da AGB nas fitofisionomias (FED e CSS) são medidas de texturas derivadas do EVI (EVI\_mean3x3, EVI\_std3x3, EVI\_contrast3x3, EVI\_homogeneity3x3). Já na FOM, a variável preditora de maior importância para a modelagem da AGB foi a LST\_homogeneity3x3 (Tabela 2).

Tabela 2 – Valores de importância (%IncMSE) das medidas de textura utilizadas na modelagem da biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas florestas de Minas Gerais.

Preditores	Todas	FES	FED	FOM	CSS	Cdao	CCer
----- Biomassa -----							
<b>EVI_mean3x3</b>	27,78	8,78	34,27	-	29,94	5,89	18,09
<b>EVI_std3x3</b>	32,81	29,94	28,50	-	22,34	10,81	-
<b>EVI_contrast3x3</b>	30,08	28,20	26,07	-	22,15	12,28	6,69
<b>EVI_homogeneity3x3</b>	36,77	32,93	29,45	-	15,83	14,90	-
<b>LST_mean3x3</b>	43,24	-	25,08	-	27,41	17,27	23,51
<b>LST_std3x3</b>	-	16,66	-	26,48	15,92	-	6,78
<b>LST_contrast3x3</b>	22,87	16,01	-	25,14	11,38	-	-
<b>LST_homogeneity3x3</b>	21,61	15,24	-	27,29	-	3,55	-
----- $\alpha$ de Fisher -----							
<b>EVI_mean3x3</b>	28,74	25,47	-	2,66	30,87	9,26	13,39
<b>EVI_std3x3</b>	24,58	23,26	-	11,61	-	4,59	15,54
<b>EVI_contrast3x3</b>	21,85	-	-	12,56	-	-	12,71
<b>EVI_homogeneity3x3</b>	20,36	22,38	17,19	10,26	-	-	-
<b>LST_mean3x3</b>	39,26	44,08	16,56	5,25	35,17	-	28,82
<b>LST_std3x3</b>	-	-	-	-	-	-	-
<b>LST_contrast3x3</b>	-	-	-	-	-	8,14	-
<b>LST_homogeneity3x3</b>	-	-	-	-	-	10,18	-

Nota: Global: Todas as fitofisionomias em conjunto; FED: Floresta Estacional Decidual; FES: Floresta Estacional Semidecidual; FOM: Floresta Ombrófila; Cdao: Cerradão; CCer: Campo Cerrado; CSS: Cerrado *Sensu Stricto* (CSS); As abreviações que definem preditores indicam as métricas texturais derivadas de imagens EVI e da LST sob janela deslizante de 3x3 pixels: média (mean), desvio-padrão (std), contraste (contrast) e homogeneidade (homogeneity).

Fonte: Do autor (2021).

De acordo com os resultados obtidos, os modelos que apresentaram melhor distribuição gráfica dos resíduos foram para predição da AGB da FED, FES, CSS e CCer; e da TSD das fitofisionomias do Cerrado e da FES (Figura S1, Apêndice B). Visualmente, os modelos globais tendem a gerar maiores erros absolutos nas parcelas que apresentam valores mais altos de AGB por hectare e de TSD, fornecendo predições subestimadas ou superestimadas. No entanto, de modo geral, as melhores estimativas de AGB foram fornecidas pelo modelo RF desenvolvido para a fitofisionomia do CSS ( $R^2_{aj} = 33,81\%$ ; RMSE = 18,47 Mg/ha; MAE% = 35,87%); enquanto para a TSD, o modelo global ( $R^2_{aj} = 26,15\%$ ; RMSE = 7,62; MAE% = 39,46%) foi que apresentou melhor desempenho.

## 4 DISCUSSÃO

### 4.1 Métricas Texturais de Produtividade e Temperatura e a Biomassa e a Diversidade

Este estudo demonstrou que métricas texturais de imagens de sensoriamento, derivadas do EVI e da LST, possuem a habilidade de captar a variabilidade espacial da AGB, bem como da TSD no estado de Minas Gerais, Brasil. Similarmente, autores relatam que as texturas de imagens podem capturar importantes aspectos da heterogeneidade da vegetação em diferentes escalas em pesquisas sobre a biodiversidade e a biomassa (FARWELL et al., 2020; KELSEY; NEFF, 2014; WOOD et al., 2012). Se por um lado, estudos destacam que texturas de imagens podem capturar a heterogeneidade do dossel e são fortemente relacionadas à diversidade de plantas, como observado por George-Chacon et al. (2019), por exemplo, que utilizaram imagens do satélite RapidEye para prever e mapear a riqueza e a diversidade de espécies arbóreas em florestas tropicais secas. Por outro lado, Lu e Batistella (2005) notaram que as texturas derivadas do sensor TM, a bordo do Landsat, suavizam as diferenças espectrais entre os estágios da vegetação sucessional, resultando em relações precárias entre as texturas e a biomassa nestas condições.

Especificamente, quando conduzimos as análises globais, a medida de textura média da temperatura (LST\_mean3x3) foi a que apresentou relações lineares mais fortes com a AGB e a TSD. Este resultado pode ser justificado a partir de estudos de biodiversidade anteriores, pois em MG, a variação na TSD dentro das fitofisionomias FED e FES e entre as fitofisionomias da Mata Atlântica (FES e FOM), que juntas compõem quase 70% da base de dados, está relacionada ao gradiente de temperatura e de umidade do solo (TERRA et al., 2018). No entanto, na FOM, as texturas derivadas do EVI exibiram associações mais fortes, em relação às que foram derivadas da LST, tanto com a AGB, quanto com a TSD. O que pode estar associado à menor variação espacial da temperatura do ar dentro das florestas ombrófilas, quando comparada às fitofisionomias sazonais (Figura 2c). Em relação a este resultado, também é preciso destacar o contexto espectral dos dois grupos de variáveis, ao contrário da LST, o EVI pode sofrer saturação em regiões de florestas muito densas.

Nas florestas da Caatinga (FED), as relações extremamente fracas ou inexistentes entre a AGB e a TSD e as texturas do EVI e da LST, provavelmente, foram determinadas pela característica decidual da vegetação. Uma vez que a resolução espacial das imagens utilizadas fornecem informações espectrais mistas, baseadas nas propriedades de reflectância não apenas da vegetação, mas também do substrato abaixo do dossel (GALLARDO-CRUZ et al., 2012).



Cunha et al. (2020) não tiveram sucesso em detectar padrões espaciais de desmatamento na Caatinga brasileira, e evidenciaram as dificuldades em distinguir a vegetação caducifólia do solo encoberto durante o período seco por índices baseados do visível e infravermelho próximo.

Entre as relações lineares moderadas observadas nas análises de correlação e regressão, destacamos que medidas de texturas de primeira ordem (mean), tanto do EVI, como da LST foram mais associadas às variáveis de interesse nas fitofisionomias mais abertas (CSS e CCer), corroborando com descobertas anteriores. Por exemplo, Wood et al. (2012) observaram correlações de moderadas entre características estruturais da vegetação da savana e texturas de primeira ordem, como média, variância e entropia. Não obstante, no Cdao, as texturas derivadas da variação espacial na produtividade (EVI) foram mais eficientes, em relação às derivadas da LST, em explicar a variação na AGB e na TSD. O Cerradão apresenta dossel contínuo e árvores de até 20 m de altura (RIBEIRO; WALTER, 2008; RIBEIRO et al., 2011), e nesse caso, nossas descobertas podem ser fundamentadas no fato que a resposta das fitofisionomias do Cerrado à variabilidade climática ocorre em função da razão entre a biomassa arbórea e herbácea, onde a vegetação lenhosa promove mais estabilidade e resiliência as mudanças climáticas (ARANTES; FERREIRA; COE, 2016).

Por fim, não descartamos a aplicabilidade das métricas texturais de imagens para obtenção de informações sobre parâmetros da vegetação, pois são variáveis de sensoriamento remoto extraídas com facilidade, o que se torna uma vantagem para o estudo e monitoramento de grandes áreas. De modo geral, as associações evidenciadas neste artigo concordam com outras pesquisas relacionadas (FARWELL et al., 2020; LU; BATISTELLA, 2005; WOOD et al., 2012). Todavia, o princípio básico de que a textura da imagem reflete os aspectos da heterogeneidade espacial e temporal da estrutura da vegetação adequadamente (BASTIN et al., 2014; HERNÁNDEZ-STEFANONI et al., 2012; SARKER; NICHOL, 2011) depende de fatores críticos, como a resolução espacial, a identificação das medidas texturais apropriadas e do tamanho ideal da janela (GALLARDO-CRUZ et al., 2012; LU; BATISTELLA, 2005; MENG et al., 2016). Portanto, ressaltamos a importância do entendimento das relações complexas entre texturas de imagens e os padrões de distribuição espacial das características da vegetação.

#### **4.2 Avaliação dos Modelos Random Forests de Biomassa e Diversidade**

Conforme discutido anteriormente, as análises exploratórias baseadas em relações lineares entre as variáveis indicaram associações fracas entre a maioria das medidas de texturas

e a AGB e a TSD. No entanto, os modelos RF têm a capacidade de capturar relações complexas no conjunto de treinamento e selecionar subconjuntos com os preditores relevantes ao processo de modelagem. Em decorrência disso, as métricas texturais selecionadas para a modelagem não necessariamente apresentaram relações lineares fortes com as variáveis de interesse na fase de análises exploratórias. E em relação a quantidade de variáveis ótimas utilizadas em cada modelo, de modo geral, nos modelos globais, a regressão RF selecionou um maior número de preditores, quando comparados aos modelos estratificados (fitofisionomias). De acordo com Silveira et al. (2019d), nesse procedimento, o número de variáveis escolhidas geralmente é impulsionado pela distribuição espacial dos dados e pelas características sazonais de cada tipo de vegetação. De modo que quanto mais extensa a distribuição espacial da vegetação, maior a quantidade de variáveis explicativas requeridas pelos modelos.

Entre as duas imagens utilizadas para calcular as métricas texturais de produtividade e temperatura, a maior parte dos preditores selecionados pelos modelos RF foram texturas derivadas do EVI, e em menor número, as texturas derivadas da LST. Esse resultado é aceitável, pois o EVI tem sido considerado um bom indicador da produtividade da vegetação, que por sua vez, está relacionada à diversidade de árvores (WARING et al., 2006). Além disso, a LST é derivada da banda termal (B6) do sensor TM a bordo do Landsat 5, e conforme apontado por outros pesquisadores, métricas de textura de índices espectrais, como nesse caso, o EVI, têm melhor desempenho do que as métricas de texturas de bandas simples, em previsões da diversidade vegetal (CABEZAS; GALLEGUILLOS; PEREZ-QUEZADA, 2016; MOHAMMADI; SHATAEE, 2010). Adicionalmente, dentro de cada subconjunto de preditores, a métrica textural que demonstrou maior valor de importância (%IncMSE) foi a média de primeira ordem, tanto do EVI, quanto da LST. Portanto, nossos resultados sugerem a utilização de texturas baseadas em estatísticas simples, calculadas a partir dos valores da imagem original, que dispensam as relações entre pixels, para estudos de modelagem da AGB e da TSD, em ambientes tropicais.

No que se refere ao EVI e a biomassa florestal, por exemplo, as relações significativas descritas na literatura, geralmente, ocorreram em regiões não tropicais (ANAYA; CHUVIECO; PALACIOS-ORUETA, 2009). Nesse contexto, se a possibilidade de utilização do EVI em estudos sobre a biodiversidade é dependente de sua capacidade de representar a produtividade da vegetação (WARING et al., 2006), as fracas correlações entre as texturas derivadas do EVI e a AGB, que é uma medida de produtividade, justificam também o baixo desempenho preditivo dos modelos de TSD, cuja maioria dos preditores são texturas derivadas do EVI.

Quanto a LST, apesar de estudos indicarem que a temperatura e a precipitação governam a distribuição de biomassa e biodiversidade em ecossistemas florestais (LARJAVAARA; MULLER-LANDAU, 2012; MORANDI et al., 2020; TERRA et al., 2018), nossos resultados indicam que texturas da LST unicamente não são suficientes para englobar a variação climática espacial, quando o objetivo é contribuir com o percentual de variância explicada pelos modelos RF de AGB e TSD nas fitofisionomias de MG. Nesse caso, ressaltamos que além do fato das texturas da LST serem derivadas de dados de reflectância de bandas simples, a relação entre a temperatura e a AGB e a TSD também é influenciada por outros fatores climáticos, como a precipitação, e por características do terreno (ALI et al., 2020; HOMEIER et al., 2010; MOSER et al., 2011; TERRA et al., 2018).

Outro aspecto deve ser levado em consideração ao avaliar modelos de predição de parâmetros da vegetação baseados apenas em texturas de imagens de sensoriamento remoto. A maioria das pesquisas desenvolvidas até hoje utilizaram métricas texturais como variáveis auxiliares, em conjuntos contendo diferentes classes de preditores, como dados de sensoriamento remoto ativo e de sistemas de informações geográficas (GEORGE-CHACON et al., 2019; GHOSH; BEHERA, 2018; KELSEY; NEFF, 2014; LI et al., 2019). Geralmente, acrescentar medidas de textura ao processo de modelagem incrementa o desempenho preditivo dos modelos, principalmente por sua capacidade de englobar aspectos da heterogeneidade espacial da vegetação (GALLARDO-CRUZ et al., 2012; KELSEY; NEFF, 2014; OTA; MIZOUE; YOSHIDA, 2011). Desse modo, ressaltamos que entre os modelos RF que apresentaram alguma contribuição na explicação da variação da AGB e da TSD em MG, os que forneceram estimativas mais confiáveis foram ajustados para a AGB do CSS, e para a TSD do C Cer e de todas as fitofisionomias (Global). Cujos valores do MAE e da RMSE são semelhantes ou menores do que os gerados por outros modelos descritos na literatura (SILVEIRA et al., 2019d). Portanto, corroboramos com outros pesquisadores e acreditamos especificamente que a utilização de medidas de texturas de índices de vegetação e da temperatura deve ser incentivada em novos procedimentos de modelagem da biomassa e da biodiversidade em ambientes tropicais complexos, principalmente em diferentes resoluções espaciais e em conjunto com outras classes de variáveis explicativas.

## 5 CONCLUSÃO

Nossas descobertas mostraram que a variabilidade espacial do EVI e da LST, derivados de imagens de sensoriamento remoto do sensor TM a bordo do Landsat 5, apresentam associações de fracas a moderadas com a AGB e com a TSD nas seis fitofisionomias arbóreas predominantes no estado de Minas Gerais, Brasil. No entanto, as métricas texturais do EVI e da LST foram capazes de capturar aspectos da heterogeneidade espacial da produtividade e do clima entre as fitofisionomias estudadas. Entre os modelos obtidos, o modelo para a AGB no CSS e os modelos global e CCer para a TSD retornaram as melhores estimativas, demonstrando que o desempenho preditivo de modelos RF baseados exclusivamente em texturas de imagens do EVI e da LST variou entre os tipos de vegetação. Com estes resultados, esperamos estimular maiores discussões sobre a utilização de métricas texturais de imagens de resolução espacial média para a modelagem de biomassa e diversidade florestal, que são particularmente relevantes ao monitoramento dos estoques de carbono e da biodiversidade terrestre.

## REFERÊNCIAS

- ADAME-CAMPOS, R. L. et al. Variables selection for aboveground biomass estimations using satellite data: A comparison between relative importance approach and stepwise Akaike's information criterion. **International Journal of Geo-Information**, v. 8, n. 6, p. 1–23, 2019.
- AKBARI, H.; KALBI, S. Determining Pleiades satellite data capability for tree diversity modeling. **iForest**, v. 10, p. 348–352, 2017.
- ALI, A. et al. Impacts of climatic and edaphic factors on the diversity, structure and biomass of species-poor and structurally-complex forests. **Science of the Total Environment**, v. 706, n. 2020, p. 1–12, 2020.
- ALVES, J. J. A.; ARAÚJO, M. A. DE; NASCIMENTO, S. S. DO. Degradação da Caatinga: Uma Investigação Ecogeográfica. **Revista Caatinga**, v. 22, n. 3, p. 126–135, 2009.
- ANAYA, J. A.; CHUVIECO, E.; PALACIOS-ORUETA, A. Aboveground biomass assessment in Colombia: A remote sensing approach. **Forest Ecology and Management**, v. 257, n. 2009, p. 1237–1246, 2009.
- ARANTES, A. E.; FERREIRA, L. G.; COE, M. T. The seasonal carbon and water balances of the Cerrado environment of Brazil: Past, present, and future influences of land cover and land use. **Journal of Photogrammetry and Remote Sensing**, v. 117, p. 66–78, 2016.
- ARAÚJO, L. V. C. DE; SILVA, J. A. DA. Unidade Experimental Fazenda Belo Horizonte - Mossoró/RN. In: GARIGLIO, M. A. et al. (Eds.). **Uso Sustentável e Conservação dos Recursos Florestais da Caatinga**. 2. ed. Brasília: Serviço Florestal Brasileiro, 2010. p. 205–213.
- ARAÚJO, E. L.; CASTRO, C. C.; ALBUQUERQUE, U. P. Dynamics of Brazilian Caatinga - A Review Concerning the Plants, Environment and People. **Functional Ecosystems and Communities**, v. 1, n. 1, p. 15–28, 2007.
- ARAÚJO, M. B. et al. Standards for distribution models in biodiversity assessments. **Science Advances**, v. 5, n. 1, p. 1–11, 2019.
- BARNOSKY, A. D. et al. Has the Earth's sixth mass extinction already arrived? **Nature**, v. 471, n. 7336, p. 51–57, 2011.
- BASTIN, J. F. et al. Aboveground biomass mapping of African forest mosaics using canopy texture analysis: Toward a regional approach. **Ecological Applications**, v. 24, n. 8, p. 1984–2001, 2014.
- BELGIU, M.; DRAGUT, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BOYLE, B. et al. The taxonomic name resolution service: An online tool for automated standardization of plant names. **BMC Bioinformatics**, v. 14, n. 16, p. 1–14, 2013.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.

CABEZAS, J.; GALLEGUILLOS, M.; PEREZ-QUEZADA, J. F. Predicting Vascular Plant Richness in a Heterogeneous Wetland Using Spectral and Textural Features and a Random Forest Algorithm. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 5, p. 646–650, 2016.

COLOMBO, A. F.; JOLY, C. A. Brazilian Atlantic Forest lato sensu: The most ancient Brazilian forest, and a biodiversity hotspot, is highly threatened by climate change. **Brazilian Journal of Biology**, v. 70, n. 3 (supl.), p. 697–708, 2010.

COSTA, T. L. et al. Root and shoot biomasses in the tropical dry forest of semi-arid Northeast Brazil. **Plant and Soil**, v. 378, n. 1–2, p. 113–123, 2014.

CRISTÓBAL, J. et al. An Improved Single-Channel Method to Retrieve Land Surface Temperature from the Landsat-8 Thermal Band. **Remote Sensing**, v. 10, n. 3, p. 1–14, 10 mar. 2018.

CUNHA, J. et al. Surface albedo as a proxy for land-cover clearing in seasonally dry forests: Evidence from the Brazilian Caatinga. **Remote Sensing of Environment**, v. 238, n. May 2019, 2020.

DIVÍŠEK, J.; CHYTRÝ, M. High-resolution and large-extent mapping of plant species richness using vegetation-plot databases. 2017.

DUBE, T.; MUTANGA, O. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 208, n. 2015, p. 12–32, 2015.

DUFFY, J. E.; GODWIN, C. M.; CARDINALE, B. J. Biodiversity effects in the wild are common and as strong as key drivers of productivity. **Nature**, v. 549, n. 7671, p. 261–264, 2017.

FARWELL, L. S. et al. Habitat heterogeneity captured by 30-m resolution satellite image texture predicts bird richness across the United States. **Ecological Applications**, v. 0, n. 0, p. 1–17, 2020.

FARWELL, L. S. et al. Satellite image texture captures vegetation heterogeneity and explains patterns of bird richness. **Remote Sensing of Environment**, v. 253, p. 112175, 2021.

FICK, S. E.; HIJMANS, R. J. Worldclim 2: New 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, 2017.

FILPI, H. E. F. C. M. **ZONEAMENTO EDAFOCLIMÁTICO EM CENÁRIOS DE MUDANÇAS CLIMÁTICAS PARA A SELEÇÃO DE ESPÉCIES EM PROJETOS DE RECOMPOSIÇÃO FLORESTAL EM MINAS GERAIS, BRASIL**. [s.l.] Universidade Federal de Viçosa, 2019.

FISHER, R. A.; CORBET, A. S.; WILLIAMS, C. B. The Relation Between the Number of Species and the Number of Individuals in a Random Sample of an Animal Population. **Journal of Animal Ecology**, v. 12, n. 1, p. 42–58, 1943.

GALLARDO-CRUZ, J. A. et al. Predicting Tropical Dry Forest Successional Attributes from Space: Is the Key Hidden in Image Texture? **PLoS ONE**, v. 7, n. 2, p. 30506, 2012.

GE, S. et al. Texture analysis for mapping *Tamarix parviflora* using aerial photographs along the Cache Creek, California. **Environmental Monitoring and Assessment**, v. 114, n. 1–3, p. 65–83, 29 mar. 2006.

GEORGE-CHACON, S. P. et al. Combining high resolution satellite imagery and lidar data to model woody species diversity of tropical dry forests. 2019.

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

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 1 dez. 2017.

HALL-BEYER, M. **GLCM TEXTURE: A TUTORIAL v. 3.0**. 3. ed. Calgary: PRISM - University of Calgary's Digital Repository Arts, 2017.

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

HERNÁNDEZ-STEFANONI, J. L. et al. Modeling-and-diversity in a tropical forest from remotely sensed and spatial data. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, n. 2012, p. 359–368, 2012.

HOLZMAN, M. E.; RIVAS, R.; PICCOLO, M. C. Estimating soil moisture and the relationship with crop yield using surface temperature and vegetation index. **International Journal of Applied Earth Observation and Geoinformation**, v. 28, p. 181–192, 2014.

HOMEIER, J. et al. Tree Diversity, Forest Structure and Productivity along Altitudinal and Topographical Gradients in a Species-Rich Ecuadorian Montane Rain Forest. **Biotropica**, v. 42, n. 2, p. 140–148, 2010.

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, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Cidades e Estados: Minas Gerais**. Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais, Estimativas da população residente com data de referência 1° de julho de 2017. 2018. Disponível em: < <https://bit.ly/31LUDst>>. Acesso em 19 ago. 2019.

JUCKER, T. et al. Climate modulates the effects of tree diversity on forest productivity. **Journal of Ecology**, v. 104, n. 2, p. 388–398, 1 mar. 2016.

KELSEY, K.; NEFF, J. Estimates of Aboveground Biomass from Texture Analysis of Landsat Imagery. **Remote Sensing**, v. 6, n. 7, p. 6407–6422, 9 jul. 2014.

LARJAVAARA, M.; MULLER-LANDAU, H. C. Temperature explains global variation in biomass among humid old-growth forests. **Global Ecology and Biogeography**, v. 21, n. 10, p. 998–1006, 2012.

LECINA-DIAZ, J. et al. The positive carbon stocks-biodiversity relationship in forests: co-occurrence and drivers across five subclimates. **Ecological Applications**, v. 28, n. 6, p. 1481–1493, 1 set. 2018.

LEITMAN, P. et al. Floristic patterns of epiphytes in the Brazilian Atlantic Forest, a biodiversity hotspot. **Botanical Journal of the Linnean Society**, v. 179, n. 4, p. 587–601, 1 dez. 2015.

LI, B. et al. Estimation of aboveground vegetation biomass based on Landsat-8 OLI satellite images in the Guanzhong Basin, China. **International Journal of Remote Sensing**, v. 40, n. 10, p. 3927–3947, 2019.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, v. 2, n. 3, p. 18–22, 2002.

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. et al. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, v. 9, n. 1, p. 63–105, 2016.

LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, jun. 2005.

MADONSELA, S. et al. Remote sensing of species diversity using Landsat 8 spectral variables. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 133, p. 116–127, 2017.

MENG, J. et al. Estimation of forest structural diversity using the spectral and textural information derived from SPOT-5 satellite images. **Remote Sensing**, v. 8, n. 2, 2016.

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.

MILES, L. et al. A global overview of the conservation status of tropical dry forests. **Journal of Biogeography**, v. 33, n. 3, p. 491–505, 2006.

MILLARD, K.; RICHARDSON, M. On the Importance of Training Data Sample Selection in Random Forest Image Classification: A Case Study in Peatland Ecosystem Mapping. **Remote Sensing**, v. 7, p. 8489–8515, 2015.



- MOHAMMADI, J.; SHATAEE, S. Possibility investigation of tree diversity mapping using Landsat ETM+ data in the Hyrcanian forests of Iran. **Remote Sensing of Environment**, v. 114, n. 7, p. 1504–1512, 2010.
- MORANDI, P. S. et al. Tree diversity and above-ground biomass in the South America Cerrado biome and their conservation implications. **Biodiversity and Conservation**, v. 29, n. 5, p. 1519–1536, 2020.
- MORO, M. F. et al. A Phylogeographical Metaanalysis of the Semiarid Caatinga Domain in Brazil. **Botanical Review**, v. 82, n. 2, p. 91–148, 2016.
- MOSER, G. et al. Elevation effects on the carbon budget of tropical mountain forests (S Ecuador): the role of the belowground compartment. **Global Change Biology**, v. 2011, n. 17, p. 2211–2226, 2011.
- OLIVEIRA FILHO, A. T. et al. Definição e delimitação de domínios e subdomínios das paisagens naturais do estado de Minas Gerais. In: SCOLFORO, J. R.; CARVALHO, L. M. T. (Eds.). . **Mapeamento e Inventário da Flora e dos Reflorestamentos de Minas Gerais**. Lavras: UFLA, 2006. p. 21–35.
- OTA, T.; MIZOUE, N.; YOSHIDA, S. Influence of using texture information in remote sensed data on the accuracy of forest type classification at different levels of spatial resolution. **Journal of Forest Research**, v. 16, p. 432–437, 2011.
- OZKAN, U. Y. et al. Evaluating the Woody Species Diversity by Means of Remotely Sensed Spectral and Texture Measures in the Urban Forests. **Journal of the Indian Society of Remote Sensing**, v. 44, n. 5, p. 687–697, 1 out. 2016.
- PARKES, D.; NEWELL, G.; CHEAL, D. Assessing the quality of native vegetation: The “habitat hectares” approach. **Ecological Management and Restoration**, v. 4, p. S29–S38, fev. 2003.
- PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. **Ecosystems**, v. 9, n. 2, p. 181–199, 15 mar. 2006.
- RADELOFF, V. C. et al. The Dynamic Habitat Indices (DHIs) from MODIS and global biodiversity. **Remote Sensing of Environment**, v. 222, p. 204–214, 1 mar. 2019.
- R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna: R Foundation for Statistical Computing, 2019.
- RIBEIRO, J. F.; WALTER, B. M. T. As Principais Fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Eds.). . **Cerrado: ecologia e flora**. 1. ed. Brasília, DF: Embrapa Informação Tecnológica, 2008. p. 151–212.
- RIBEIRO, S. C. et al. Above- and belowground biomass in a Brazilian Cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491–499, 2011.
- ROCCHINI, D. et al. Measuring  $\beta$ -diversity by remote sensing: A challenge for biodiversity

- monitoring. **Methods in Ecology and Evolution**, v. 9, n. 8, p. 1787–1798, 2018.
- SAATCHI, S. et al. Modeling distribution of Amazonian tree species and diversity using remote sensing measurements. **Remote Sensing of Environment**, v. 112, n. 2008, p. 2000–2017, 2008.
- SARKER, L. R.; NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 2011, p. 968–977, 2011.
- SCHINDLER, S. et al. Performance of methods to select landscape metrics for modelling species richness. **Ecological Modelling**, v. 295, n. 2015, p. 107–112, 2015.
- SCOLFORO, H. F. et al. Spatial distribution of aboveground carbon stock of the arboreal vegetation in Brazilian Biomes of Savanna, Atlantic Forest and Semi-arid woodland. **PLoS ONE**, v. 10, n. 6, p. 1–20, 2015.
- SCOLFORO, J. R. et al. Amostragem e coleta de dados para equações de volume, peso de matéria seca, tanino, cortiça, óleo, sistema radicular, conversão de volumes e carbono. In: SCOLFORO, J. R.; OLIVEIRA, A. D.; ACERBI JÚNIOR, F. W. A. (Eds.). **Inventário florestal de Minas Gerais: equações de volume, peso de matéria seca e carbono para diferentes fisionomias da flora nativa**. Lavras: Ed. UFLA, 2008. cap. 1, p. 1-65.
- SILVEIRA, E. M. O. et al. Modelling aboveground biomass in forest remnants of the Brazilian Atlantic Forest using remote sensing, environmental and terrain-related data. **Geocarto International**, p. 1–18, 2019a.
- SILVEIRA, E. M. O. et al. Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. 2019, p. 175–188, 2019b.
- SILVEIRA, E. M. O. et al. Carbon-diversity hotspots and their owners in Brazilian southeastern Savanna, Atlantic Forest and Semi-Arid Woodland domains. **Forest Ecology and Management**, v. 452, n. May, p. 1–12, 2019c.
- SILVEIRA, E. M. O. et al. Pre-stratified modelling plus residuals kriging reduces the uncertainty of aboveground biomass estimation and spatial distribution in heterogeneous savannas and forest environments. **Forest Ecology and Management**, v. 445, p. 96–109, 2019d.
- SILVEIRA, E. M. O. et al. Anthropogenic disturbances affect the relationship between spectral indices and the biometric variables of Brazilian savannas. **Floresta e Ambiente**, v. 26, n. 3, p. 20180338, 2019e.
- SILVEIRA, E. M. O. et al. Reducing the effects of vegetation phenology on change detection in tropical seasonal biomes. **GIScience e Remote Sensing**, v. 56, n. 5, p. 699–717, 4 jul. 2019f.
- SILVEIRA, E. M. O. et al. Estimating Aboveground Biomass Loss from Deforestation in the Savanna and Semi-arid Biomes of Brazil between 2007 and 2017. In: SURATMAN, M. N. et al. (Eds.). **Forest Degradation Around the World**. [s.l.] IntechOpen, 2020. p. 1–17.

SIMS, D. A. et al. A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. **Remote Sensing of Environment**, v. 112, p. 1633–1646, 2008.

TERRA, M. DE C. N. S. et al. Water availability drives gradients of tree diversity, structure and functional traits in the Atlantic-Cerrado-Caatinga transition, Brazil. **Journal of Plant Ecology**, v. 11, n. 6, p. 803–814, 2018.

TRAVIS, J. M. J. Climate change and habitat destruction: A deadly anthropogenic cocktail. **Proceedings of the Royal Society**, v. 270, n. 1514, p. 467–473, 2003.

UNIVERSIDADE FEDERAL DE VIÇOSA; FUNDAÇÃO CENTRO TECNOLÓGICO DE MINAS GERAIS; UNIVERSIDADE FEDERAL DE LAVRAS; FUNDAÇÃO ESTADUAL DO MEIO AMBIENTE. Mapa de solos do estado de Minas Gerais. Belo Horizonte: Fundação Estadual do Meio Ambiente, 2010. Disponível em: <<https://bit.ly/31XCGaA>>. Acesso em 23 ago. 2019.

VEČEŘA, M. et al. Alpha diversity of vascular plants in European forests. **Journal of Biogeography**, v. 46, p. 1919–1935, 7 set. 2019.

WAN, R. et al. Mapping Aboveground Biomass of Four Typical Vegetation Types in the Poyang Lake Wetlands Based on Random Forest Modelling and Landsat Images. **Frontiers in Plant Science**, v. 10, p. 1281, 16 out. 2019.

WANG, L. et al. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**, v. 4, n. 3, p. 212–219, 1 jun. 2016.

WANG, M. et al. An enhanced single-channel algorithm for retrieving land surface temperature from Landsat series data. **Journal of Geophysical Research: Atmospheres**, v. 121, n. 11, p. 712–722, 16 out. 2016.

WARING, U. S. A. R. H. et al. MODIS enhanced vegetation index predicts tree species richness across forested ecoregions in the contiguous. 2006.

WOOD, E. M. et al. Image texture as a remotely sensed measure of vegetation structure. **Remote Sensing of Environment**, v. 121, n. 2012, p. 516–526, 2012.

WU, J.; LIANG, S. Developing an integrated remote sensing based biodiversity index for predicting animal species richness. **Remote Sensing**, v. 10, n. 5, 2018.

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, 2015.

## APÊNDICE A – Material Suplementar

Tabela S1 – Indicadores de qualidade dos ajustes de regressão linear simples para biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais (Continua).

Parcelas	Variáveis	AGB		Fisher	
		R <sup>2</sup>	p-value	R <sup>2</sup>	p-value
<b>Global</b>	EVI_mean3x3	2,80%	0,00	6,06%	0,00
	EVI_std3x3	6,23%	0,00	5,87%	0,00
	EVI_contrast3x3	3,90%	0,00	2,87%	0,00
	EVI_homogeneity3x3	7,75%	0,00	7,88%	0,00
	LST_mean3x3	8,40%	0,00	13,35%	0,00
	LST_std3x3	2,03%	0,00	1,41%	0,00
	LST_contrast3x3	1,59%	0,00	1,09%	0,00
	LST_homogeneity3x3	1,80%	0,00	1,23%	0,00
<b>F0m</b>	EVI_mean3x3				
	EVI_std3x3			6,08%	0,01
	EVI_contrast3x3	2,71%	0,10	7,51%	0,01
	EVI_homogeneity3x3			4,22%	0,04
	LST_mean3x3			1,17%	
	LST_std3x3			0,37%	
	LST_contrast3x3			0,71%	
	LST_homogeneity3x3			0,40%	
<b>FES</b>	EVI_mean3x3	1,60%	0,00	0,23%	0,08
	EVI_std3x3	0,39%	0,02	0,83%	0,00
	EVI_contrast3x3	0,55%	0,01	0,37%	0,02
	EVI_homogeneity3x3			0,91%	0,00
	LST_mean3x3	0,92%	0,00	10,67%	0,00
	LST_std3x3	0,36%	0,03		
	LST_contrast3x3	0,22%	0,08		
	LST_homogeneity3x3	0,41%	0,02		
<b>FED</b>	EVI_mean3x3				
	EVI_std3x3			0,63%	0,10
	EVI_contrast3x3				
	EVI_homogeneity3x3	0,86%	0,05	1,90%	0,00
	LST_mean3x3	2,11%	0,00		
	LST_std3x3			0,74%	0,07
	LST_contrast3x3				
	LST_homogeneity3x3				
<b>CSS</b>	EVI_mean3x3	15,05%	0,00	12,81%	0,00
	EVI_std3x3				
	EVI_contrast3x3				
	EVI_homogeneity3x3	0,60%	0,07		
	LST_mean3x3	12,09%	0,00	13,96%	0,00
	LST_std3x3	1,45%	0,00	0,90%	0,02

Tabela S1 – Indicadores de qualidade dos ajustes de regressão linear simples para biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais (Conclusão).

Parcelas	Variáveis	AGB		Fisher	
		R <sup>2</sup>	p-value	R <sup>2</sup>	p-value
CSS	LST_contrast3x3	1,04%	0,02	1,11%	0,01
	LST_homogeneity3x3	1,68%	0,00	1,35%	0,01
Cdao	EVI_mean3x3	6,61%	0,07	14,38%	0,01
	EVI_std3x3	26,68%	0,00	7,17%	0,05
	EVI_contrast3x3	23,53%	0,00		
	EVI_homogeneity3x3	18,38%	0,00	10,06%	0,02
	LST_mean3x3	5,69%	0,09		
	LST_std3x3	7,81%	0,04	9,05%	0,03
	LST_contrast3x3	5,66%	0,09	7,02%	0,06
	LST_homogeneity3x3	6,01%	0,08	7,88%	0,04
CCer	EVI_mean3x3	11,83%	0,00	2,24%	0,02
	EVI_std3x3			3,31%	0,01
	EVI_contrast3x3			2,71%	0,01
	EVI_homogeneity3x3	2,14%	0,03		
	LST_mean3x3	10,72%	0,00	8,44%	0,00
	LST_std3x3			1,73%	0,05
	LST_contrast3x3				
	LST_homogeneity3x3			1,19%	0,10

Nota: Globais: Todas as fitofisionomias em conjunto; FOM: Floresta Ombrófila; FES: Floresta Estacional Semidecidual; FED: Floresta Estacional Decidual; CSS: Cerrado *Sensu Stricto* (CSS); Cdao: Cerradão; CCer: Campo Cerrado; R<sup>2</sup> = Coeficiente de determinação em porcentagem; p-valor: nível de probabilidade de significância dos ajustes; Variáveis: Medidas texturais de imagens medianas do EVI e da LST de primeira ordem, média (mean) e desvio-padrão (std), e de segunda ordem, contraste (contrast) e homogeneidade (homogeneity); Linhas em branco indicam equações lineares não significativas a 90% de confiança.

Fonte: Do autor (2021).

**APÊNDICE B – Material Suplementar**

Figura S1 – Gráficos de distribuição de resíduos dos modelos Random Forests obtidos para a biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais em função de métricas texturais de imagens de Sensoriamento Remoto (Continua).

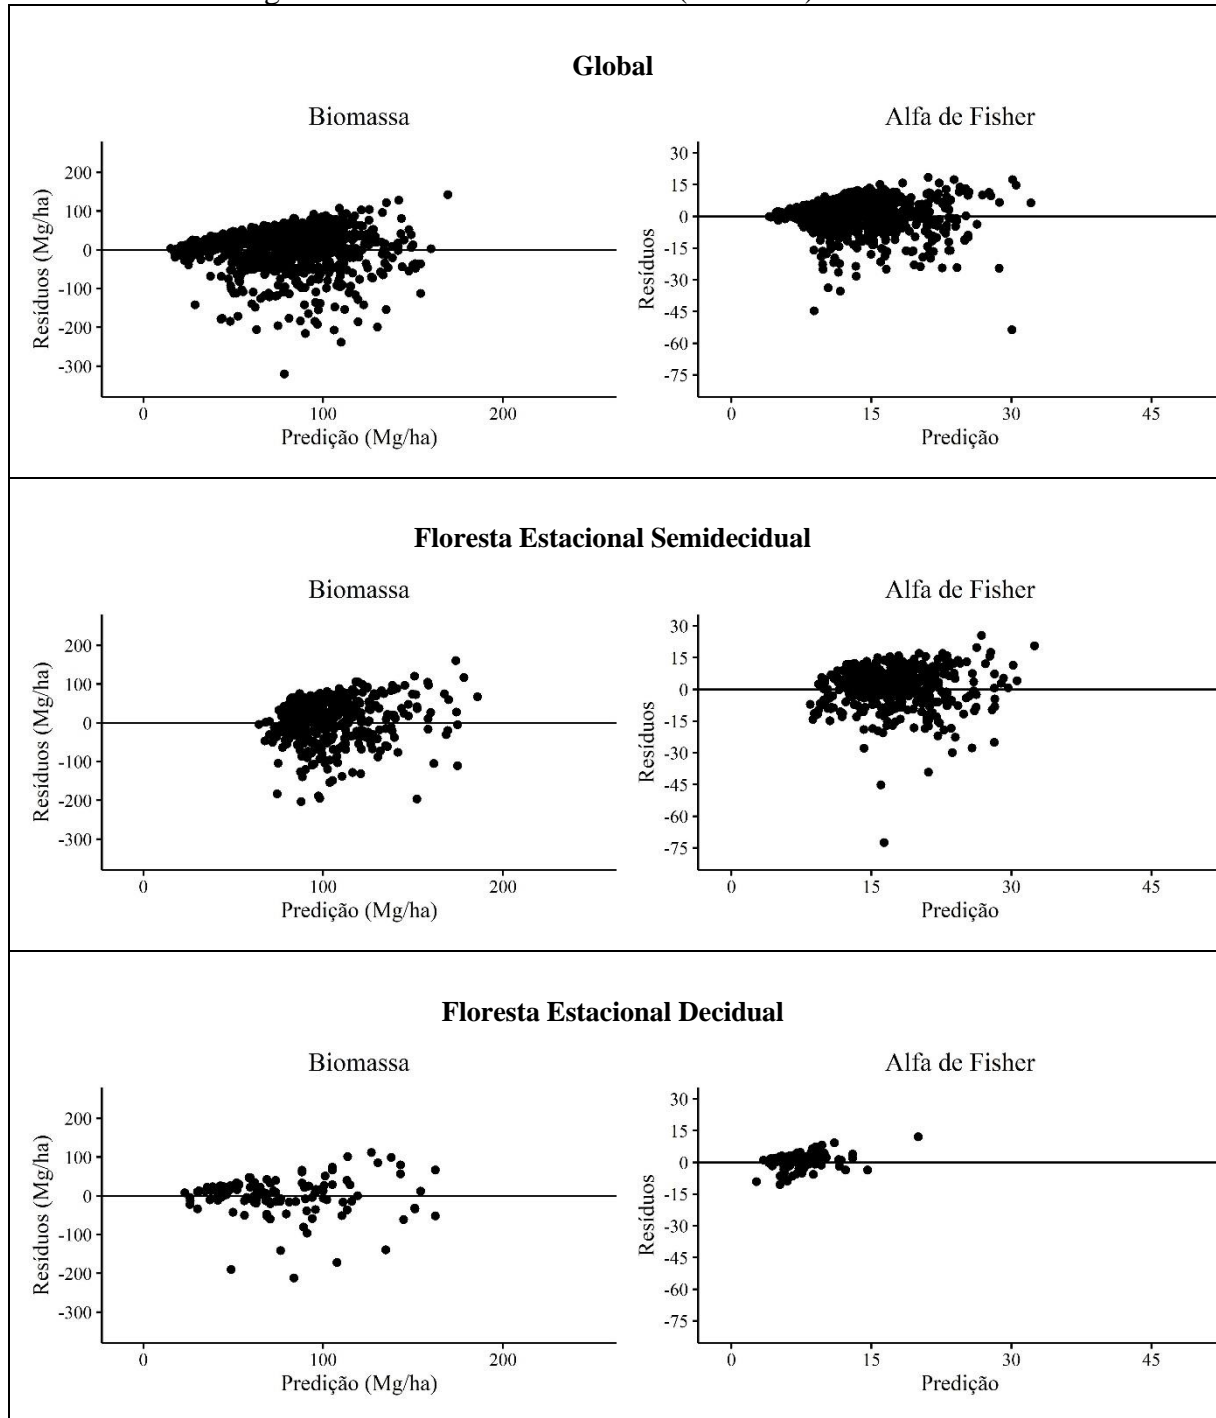


Figura S1 – Gráficos de distribuição de resíduos dos modelos Random Forests obtidos para a biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais em função de métricas texturais de imagens de Sensoriamento Remoto (Continua).

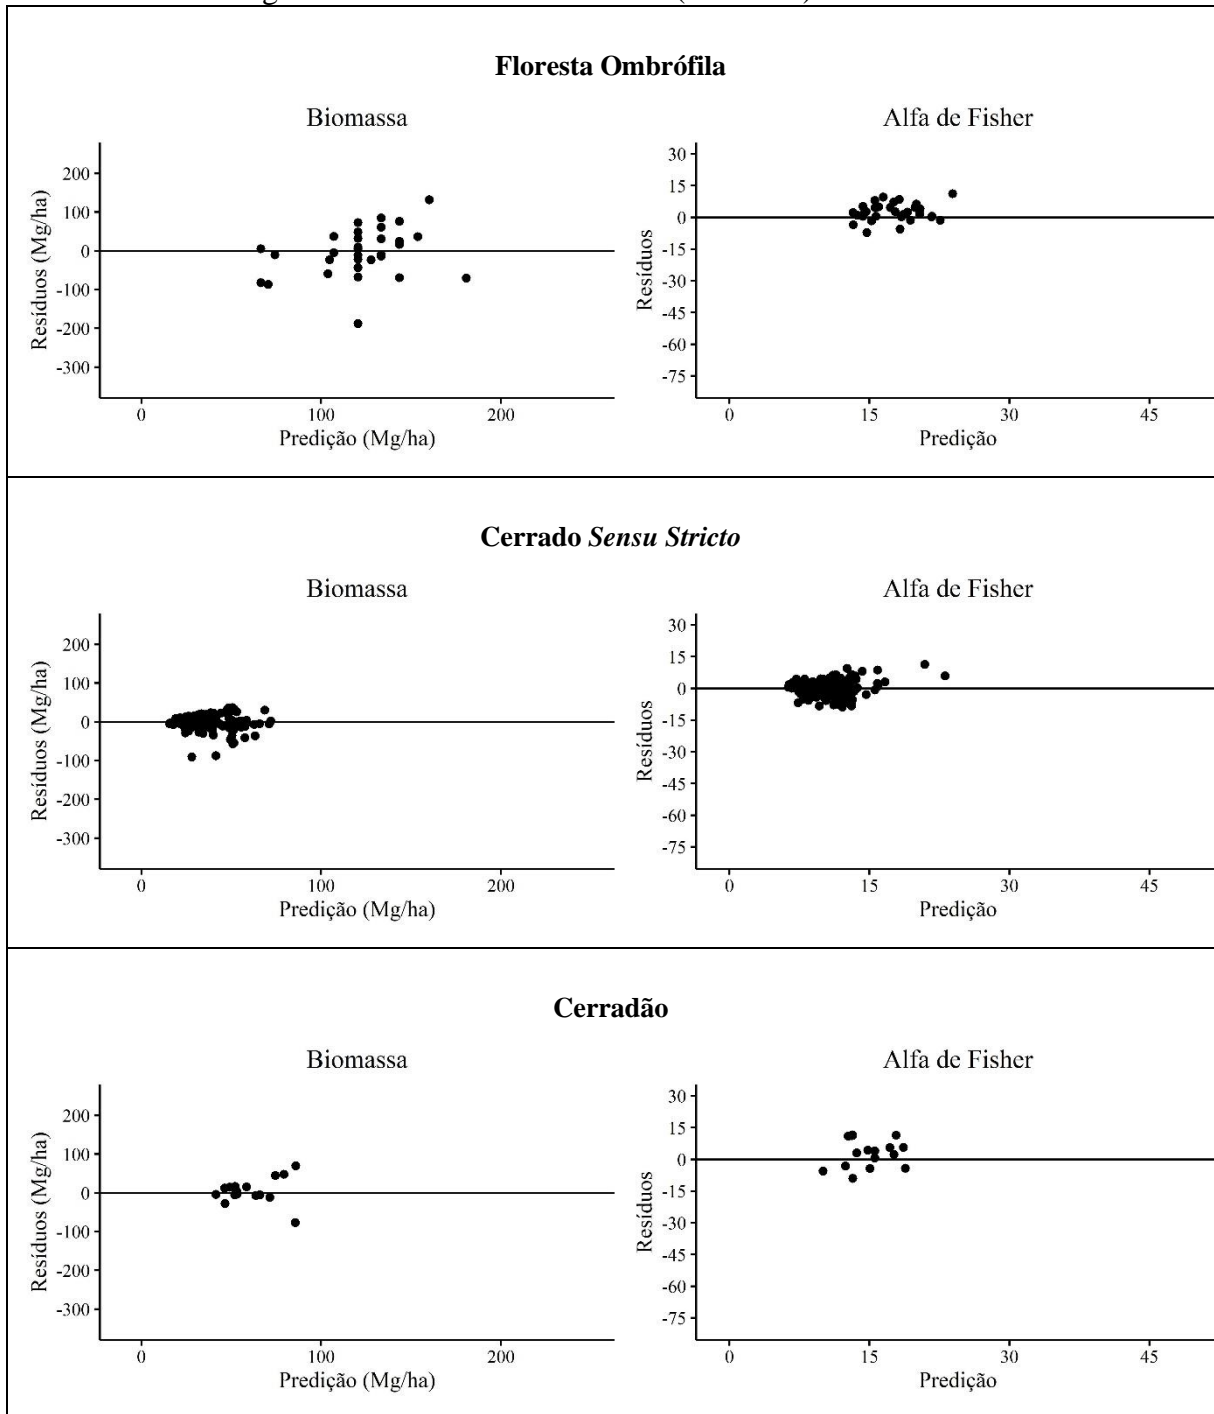
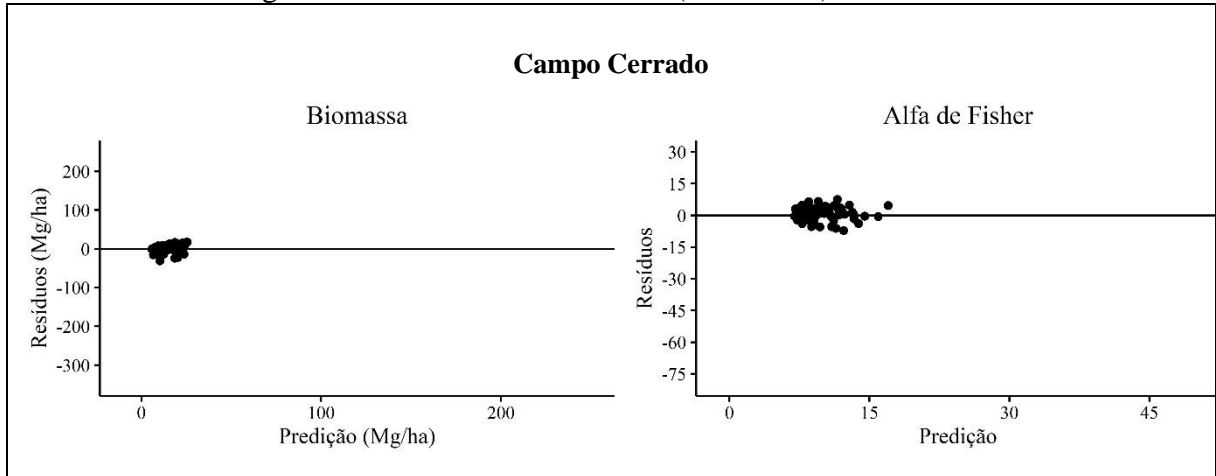


Figura S1 – Gráficos de distribuição de resíduos dos modelos Random Forests obtidos para a biomassa arbórea acima do solo e índice de diversidade de espécies arbóreas nas parcelas do Inventário Florestal de Minas Gerais em função de métricas texturais de imagens de Sensoriamento Remoto (Conclusão).



Fonte: Do autor (2021).