

UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**DISTRIBUIÇÃO ESPACIAL DO ESTOQUE DA BIOMASSA ACIMA DO  
SOLO EM FLORESTA TROPICAL SAZONALMENTE SECA NO  
ESTADO DA BAHIA, BRASIL**

**HÉVELI KALINI VIANA SANTOS**

VITÓRIA DA CONQUISTA  
BAHIA - BRASIL  
JANEIRO - 2022

**HÉVELI KALINI VIANA SANTOS**

**DISTRIBUIÇÃO ESPACIAL DO ESTOQUE DA BIOMASSA ACIMA DO  
SOLO EM FLORESTA TROPICAL SAZONALMENTE SECA NO  
ESTADO DA BAHIA, BRASIL**

Dissertação apresentada à Universidade Estadual do Sudoeste da Bahia, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais para obtenção do título de Mestre.

**Orientador: Prof. Dr. Robson Borges de Lima (UEAP)**

VITÓRIA DA CONQUISTA  
BAHIA - BRASIL  
JANEIRO - 2022

S237d Santos, Héveli Kalini Viana.

Distribuição espacial do estoque da biomassa acima do solo em floresta tropical sazonalmente seca no estado da Bahia, Brasil. / Héveli Kalini Viana Santos, 2022.

54f.

Orientador (a): Dr. Robson Borges de Lima.

Dissertação (mestrado) – Universidade Estadual do Sudoeste da Bahia, Programa de Pós-graduação em Ciências Florestais, Vitória da Conquista, 2022.

Inclui referências. 43 - 54.

1. Biomassa florestal - Caatinga. 2. Krigagem com regressão. 3. Análise espacial. 4. Espacialização. I. Lima, Robson Borges de. II. Universidade Estadual do Sudoeste da Bahia, Programa de Pós-Graduação em Ciências Florestais. III. T.

CDD: 580

**Catálogo na fonte: Juliana Teixeira de Assunção – CRB 5/1890**

UESB – Campus Vitória da Conquista - BA

**HÉVELI KALINI VIANA SANTOS**

**DISTRIBUIÇÃO ESPACIAL DO ESTOQUE DA BIOMASSA ACIMA DO  
SOLO EM FLORESTA TROPICAL SAZONALMENTE SECA NO  
ESTADO DA BAHIA, BRASIL**

Dissertação apresentada à Universidade Estadual do Sudoeste da Bahia, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, para a obtenção do título de Mestre.

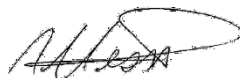
Aprovada em 19 de janeiro de 2022.

Comissão Examinadora:



---

Prof. Francisco Tarcísio Alves Junior (D.Sc., Ciências Florestais) – UEAP



---

Prof. Alessandro de Paula (D.Sc., Ecologia e Recursos Naturais) – UESB



---

Prof.<sup>a</sup> Cinthia Pereira de Oliveira (D.Sc., Ciências Florestais) – UEAP  
Coorientadora



---

Prof. Robson Borges de Lima (D.Sc., Ciências Florestais) – UESB  
Orientador

## **AGRADECIMENTOS**

Agradeço a Deus, pela força que não me deixou desanimar perante tantos desafios.

À Universidade Estadual do Sudoeste da Bahia (UESB) e ao Programa de Pós-Graduação em Ciências Florestais (PPGCiFlor), pela oportunidade.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela concessão da bolsa de estudos.

Ao professor Robson Borges de Lima pela orientação, confiança e ensinamentos, e também à minha coorientadora Cinthia. Obrigada pelo seu otimismo!

Agradeço imensamente ao Rafael Lucas, pelas contribuições que foram fundamentais para a concretização deste trabalho.

Ao INEMA, em especial ao Lucas, pela confiança e por disponibilizar os dados usados para o desenvolvimento da pesquisa. Também à Rede de Manejo Florestal da Caatinga e ao Laboratório de Ecologia e Proteção Florestal/UESB por disponibilizar dados.

Aos meus amados pais, Edmilson e Luciene, por acreditarem em mim e, também à minha irmã Eloiza, por embarcar comigo nessa jornada e dividir a saudade de casa.

Ao meu esposo Gabriel, pelo amor, paciência e por todo o apoio.

Aos colegas do PPGCiFlor, pelo convívio e troca de experiências, em especial a Lair. Agradeço por sua amizade!

**A vocês, meu muito obrigada!**

## SUMÁRIO

1. INTRODUÇÃO .....	7
2. REVISÃO DE LITERATURA.....	9
2.1. Caatinga.....	9
2.2. Biomassa florestal na Caatinga .....	11
2.3. Geoestatística .....	13
2.4. Interpolação de dados por krigagem .....	17
2.5. Interpolação pelo Inverso do Quadrado da Distância (IQD) .....	19
3. MATERIAL E MÉTODOS.....	21
3.1. Caracterização da área de estudo.....	21
3.2. Estimativa da biomassa .....	22
3.3. Mapeamento do estoque de biomassa .....	24
3.3.1. Interpolação por krigagem com regressão.....	24
3.3.1.1. Modelagem do estoque de biomassa .....	24
3.3.1.2. Espacialização do estoque de biomassa.....	25
3.3.2. Interpolação pelo Inverso do Quadrado da Distância (IQD).....	27
4. RESULTADOS E DISCUSSÃO .....	28
4.1. Análise exploratória .....	28
4.2. Interpolação por krigagem com regressão .....	29
4.2.1. Modelagem do estoque de biomassa .....	29
4.2.2. Espacialização do estoque de biomassa .....	32
4.3. Interpolação pelo Inverso do Quadrado da Distância (IQD) .....	40
5. CONCLUSÕES .....	42
6. REFERÊNCIAS.....	43

## RESUMO

SANTOS, Héveli Kalini Viana, M.Sc., Universidade Estadual do Sudoeste da Bahia, janeiro de 2022. **Distribuição espacial do estoque da biomassa acima do solo em floresta tropical sazonalmente seca no Estado da Bahia, Brasil.** Orientador: Robson Borges de Lima. Coorientadora: Cinthia Pereira de Oliveira.

As mudanças climáticas intensificadas pela emissão desenfreada de gases de efeito estufa têm dado destaque às florestas por sua capacidade de absorver dióxido de carbono e estocar a fração carbono em sua biomassa. Portanto, conhecer o estoque de formações de Caatinga é essencial para entender a sua contribuição para o ciclo global de carbono e, assim, traçar um planejamento estratégico de sua conservação. O presente estudo teve como objetivo modelar e mapear a distribuição espacial do potencial estoque de biomassa florestal da Caatinga, no estado da Bahia, por meio das técnicas de krigagem com regressão e do Inverso do Quadrado da Distância. A base de dados foi composta por 32 fragmentos florestais inventariados na área de estudo. Para aplicação da krigagem com regressão, um modelo para a estimativa de biomassa foi ajustado em função de variáveis ambientais e aplicado sobre os mapas das componentes selecionadas. A latitude, temperatura e precipitação explicaram 46% das variações da biomassa da Caatinga na Bahia. Os resíduos do modelo apresentaram forte dependência espacial e foram mapeados com base em critérios geoestatísticos, selecionando-se o modelo de semivariograma esférico para a interpolação por krigagem ordinária. Em nível de comparação, a biomassa também foi mapeada pelo Inverso do Quadrado da Distância. A qualidade do modelo de regressão sugere que existe um potencial em estimar a biomassa a partir de variáveis ambientais. A krigagem com regressão apresentou maior detalhamento na distribuição espacial e revelou uma tendência de aumento de biomassa na direção norte-sul. Sugere-se estudos adicionais com maior intensidade amostral e com o uso de outras variáveis explicativas para aprimorar o modelo, assim como maximizar a capacidade da técnica em captar, com detalhes, o comportamento real da biomassa na área de estudo.

**Palavras-chave:** geoestatística, krigagem com regressão, análise espacial, espacialização.

## ABSTRACT

SANTOS, Héveli Kalini Viana Santos, M.Sc., Universidade Estadual do Sudoeste da Bahia, January 2022. **Spatial distribution of aboveground biomass stock in seasonally dry tropical forest in Bahia State, Brazil.** Adviser: Robson Borges de Lima. Co-Adviser: Cinthia Pereira de Oliveira.

Climate change intensified by the unrestrained emission of greenhouse gases has been highlighted as forests, for their ability to absorb carbon dioxide and store the carbon fraction in their biomass. Therefore, knowing the biomass stock in the Caatinga biome is essential for the sense of its contribution to the global carbon cycle and, thus, drawing up a strategic planning for its conservation. The present study aimed to model and map the spatial distribution of the potential stock of forest biomass in the Caatinga, in the state of Bahia, through kriging techniques with regression and the inverse square of the distance. The database consisted of 32 forest fragments inventoried in the study area. For the application of kriging with regression, a model for estimating biomass was applied as a function of environmental variables and applied to the maps of selected components. The latitude, temperature and precipitation explained 46% of the biomass variations of the Caatinga, in Bahia. The residuals of model showed strong spatial dependence and were mapped based on geostatistical criteria, selecting itself the spherical semivariogram model for interpolation by ordinary kriging. In terms of comparison, biomass was also mapped by the inverse square of the distance. The quality of the regression model suggests that there is potential in estimating biomass from environmental variables. The regression kriging showed greater detail in the spatial distribution and revealed a trend of biomass increase in the north-south direction. Additional studies with greater sampling intensity and use of other explanatory variables are suggested to improve the model, as well as maximize the technique's ability in capture with detail the actual behavior of the biomass in the study area.

**Keywords:** geostatistics, regression kriging, spatial analysis, spatialization.



## 1. INTRODUÇÃO

As incessantes queimas das florestas e de combustíveis fósseis que liberam e acumulam dióxido de carbono (CO<sub>2</sub>) na atmosfera acarretam em considerável aumento na temperatura da superfície global e outras mudanças climáticas. Com isso, a necessidade em desenvolver técnicas que promovam a mitigação do efeito estufa se tornou prioritária, e sob esse aspecto as florestas atuam como importantes sumidouros de CO<sub>2</sub>, haja vista que promovem a fixação do carbono da atmosfera em sua biomassa vegetal (PEREIRA JÚNIOR et al., 2016).

Conhecer a biomassa retida nas plantas permite compreender a dinâmica do carbono, fornecendo melhor entendimento dos impactos do desmatamento no aquecimento global. Pode ainda subsidiar dados necessários à elaboração de planos de manejo e de políticas públicas para promover a conservação, definição do potencial de produção de madeira para fins energéticos e quantificação da ciclagem de nutrientes (AZEVEDO et al., 2018; FERREIRA et al., 2019; VIRGENS et al., 2016).

Do ponto de vista ecológico, conservacionista e econômico os valores dos estoques de biomassa acima do solo necessitam ser conhecidos, o que leva ao desenvolvimento de diferentes metodologias para a sua estimativa. Todavia, muitos destes estudos têm desconsiderado a distribuição da biomassa no espaço (VIRGENS et al., 2016; MACEDO et al., 2018).

A modelagem geoestatística fornece uma estrutura que permite prever a variável de interesse em locais não amostrados e gerar o mapeamento de sua distribuição espacial, empregando informações interpoladas de uma área amostrada (CAMARGO, 1998). As informações geradas têm sido fundamentais para apoiar as políticas públicas ambientais, uma vez que permitem indicar áreas potenciais para alocação de unidades de conservação, criar corredores ecológicos, subsidiar o fomento do uso dos créditos de carbono e contribuir para a redução da supressão e recuperação de fragmentos florestais (BARNI et al., 2016; SILVEIRA et al., 2019a).

Contudo, nesse viés, poucos são os trabalhos desenvolvidos que contemplem a fisionomia florestal das formações de Caatinga, vegetação predominante da região Nordeste que contribui significativamente com o ciclo do carbono (ALTHOFF et al., 2018). Compreender a espacialização da biomassa nessa formação é essencial para um planejamento estratégico de sua conservação e desenvolvimento. Isso porque, apesar de ser considerado o único bioma exclusivamente brasileiro, a Caatinga é um

dos biomas menos protegidos do País, com pouco mais de 2% do seu território pertencente a unidades de conservação de proteção integral, além de ser pouco conhecido cientificamente, principalmente em relação à prestação de serviços ambientais (MMA, 2021).

A formação florestal ocorre sob características edafoclimáticas extremas e é a região brasileira mais vulnerável às mudanças climáticas (GANEM, 2017). Além disso, a Caatinga é altamente ameaçada por práticas inadequadas de uso da terra. Devido à alta densidade populacional do semiárido nordestino, os seus recursos naturais são amplamente explorados, o que resulta na redução da produção e dos estoques de biomassa, além da fragmentação da paisagem em diferentes fisionomias, estágios de regeneração e usos da terra (MMA, 2016; ALTHOFF et al., 2018). Isso tem culminado em um intenso processo de degradação que tem avançado ao longo dos últimos anos (VIEIRA et al., 2020).

Dessa forma, verifica-se a necessidade de desenvolver técnicas para estimar a biomassa e, assim, produzir informações seguras sobre o potencial produtivo de suas formações florestais e dar suporte às estimativas da dinâmica do carbono. Nesse contexto, o objetivo deste trabalho foi modelar e mapear a distribuição espacial do potencial estoque de biomassa florestal da Caatinga, no estado da Bahia, por meio das técnicas de krigagem com regressão e do Inverso do Quadrado da Distância.

## 2. REVISÃO DE LITERATURA

### 2.1. Caatinga

A Caatinga, formação florestal caracterizada por uma vegetação xerófila e heterogênea em fisionomia e florística, é uma das mais distintas regiões fitogeográficas brasileiras, que ocupa uma área territorial de 862.818 km<sup>2</sup>, equivalente a 10,1% do território nacional compreendido entre a Linha do Equador e o Trópico de Capricórnio (IBGE, 2019). É limitado a leste pela Mata Atlântica e ao oeste pelo Cerrado, e engloba todos os estados do Nordeste, com exceção do Maranhão. Também está presente no norte de Minas Gerais (IBGE, 2019).

O clima semiárido é o ambiente de domínio na Caatinga, condicionado a baixa pluviosidade com média anual inferior a 800 mm, chuvas irregulares no tempo e no espaço, concentrando-se em três a quatro meses do ano (RODAL et al., 2013; IBGE, 2018). As temperaturas são altas e relativamente constantes com médias anuais entre 25°C e 30°C, associadas a baixas amplitudes térmicas e elevadas taxas de evapotranspiração e de insolação (SAMPAIO, 2010; ZANELLA, 2014).

A Caatinga é consagrada como a única formação florestal restrita ao Brasil e exibe riqueza em biodiversidade e paisagens, o que torna o seu patrimônio biológico único no mundo (KIILL et al., 2009). Apesar das limitações edafoclimáticas em que está submetida, apresenta alta diversidade florística, como encontrado nos estudos de Guedes et al. (2012), Leite et al. (2015), Brand (2017), Vasconcelos et al. (2017) e Fernandes et al. (2020). O desenvolvimento dessa vegetação só ocorre devido à presença de mecanismos morfológicos e/ou fisiológicos desenvolvidos para resistir aos longos períodos de estiagem. Assim, caracteriza-se por uma vegetação caducifólia, altamente resiliente, que possui abundante rebrota e rápida resposta às chuvas, razão da sazonalidade da camada herbácea (RIEGELHAUPT et al., 2010; PARENTE et al., 2012).

Devido à pluralidade no regime de chuvas, do tipo de solo e relevo, a formação exibe diversas fitofisionomias, desde aquelas compostas por arbustos esparsos de caules finos e tortuosos, entremeados por cactáceas, até as formações florestais (GANEM, 2017). O tipo de vegetação predominante na área é a Savana-Estépica (63,30%), mas também estão presentes as Florestas Estacionais Deciduais (8,32%)

e Semidecíduais (2,13%), Savanas (1,61%) e pequenas áreas ocupadas por Florestas Ombrófilas (0,4%) (IBGE, 2019).

A savana-estépica, genericamente chamada de caatinga, apresenta diversas formações: florestada, arborizada, parque e gramíneo-lenhosa (IBGE, 2012). Nessa ordem citada, as características fisionômicas se modificam, e a vegetação fica mais esparsa e de menor porte. Assim, vão desde a formação com maior predominância de árvores adensadas com troncos grossos e espinhosos até a formação caracterizada por um extenso campo graminoso entremeado de pequenas plantas lenhosas e espinhosas (IBGE, 2012).

As formações florestais, conhecidas como caatinga arbórea, são compostas predominantemente por árvores decíduas, sazonalmente secas, que chegam a 20 m de altura, onde sua ocorrência está restrita às manchas isoladas de solos profundos e ricos em nutrientes, e regiões mais altas (PRADO, 2003; LEAL et al., 2005). Segundo Sampaio (2010), esses solos possuem características que favorecem a retenção de água e a disponibilidade dos nutrientes. Todavia, com raras exceções, os solos tendem a ser pouco férteis, devido à baixa produção de fitomassa, e, ainda, pouco intemperizados, rasos, pedregosos e com baixa capacidade de retenção de água, o que os leva à saturação nos períodos de chuva e fácil ressecamento durante a estiagem (ALVES et al., 2009; MENEZES et al., 2013; RODAL et al., 2013; SILVEIRA et al., 2018).

Embora apresente características singulares em meio à fragilidade de um ambiente mais árido, apenas 9% de seu território pertence a unidades de conservação, sendo 2,4% inserido em unidades de proteção integral (MMA, 2021).

Por falta de conhecimento, as florestas da Caatinga foram sempre consideradas quase sem utilidade, o que se tornou fator limitante para o desenvolvimento da região em que ocorre (GARIGLIO et al., 2010). No entanto, Brasil (2014) destacou a importância da Caatinga para a manutenção da economia nordestina, uma vez que seus recursos naturais subsidiam diversas atividades econômicas. As florestas são utilizadas para geração de energia, tanto para o uso doméstico quanto para abastecer as indústrias. Delas ainda são extraídos produtos não madeireiros que servem como alternativa de geração de renda para muitas famílias, como a extração do mel, fibras, frutos e óleos (GIULIETTI et al., 2003; BRAND et al., 2015).

Entretanto, Oliveira et al. (2009), Brand (2017) e Castanho et al. (2020) salientaram que o uso não planejado desses recursos somado ao desmatamento, queimadas, extração seletiva e à contínua substituição da vegetação natural pela agropecuária, tem gerado perdas irrecuperáveis nos estoques de biomassa e na diversidade florística. Esses danos já totalizam a perda de 46% da cobertura vegetal original da Caatinga, além de uma paisagem fragmentada em diferentes fisionomias, estágios de regeneração e usos da terra (MMA, 2016). Beuchle et al. (2015) comprovaram que, ao longo de duas décadas (1990-2010), a Caatinga apresentou perda líquida de 15.571 km<sup>2</sup> de cobertura arbórea. Esse cenário favorece a instalação do processo de degradação ambiental no nordeste brasileiro, principal preocupação atual sobre os problemas ambientais na região (MMA, 2007; SOUZA et al., 2015; GARCIA et al., 2019; TAVARES et al., 2019).

## **2.2. Biomassa florestal na Caatinga**

O termo biomassa se refere à massa de matéria de origem biológica, viva ou morta, animal ou vegetal, enquanto que a biomassa florestal se restringe à quantidade de material vegetal disponível na floresta, expresso por massa seca, podendo se referir a toda massa vegetal existente ou apenas aquela contida na fração arbórea (SANQUETTA, 2002).

É composta por carbono, hidrogênio, oxigênio e nutrientes minerais (NOGUEIRA e RENDEIRO, 2008; PROTÁSIO et al., 2011; ALVES et al., 2017), e as concentrações desses constituintes tendem a variar de acordo com a espécie, seu estado nutricional, fase de desenvolvimento, compartimento e com as condições climáticas. Contudo, o carbono é o elemento de maior concentração, e o seu teor pode variar em torno de 40% a 50% da biomassa (IPCC, 2006; VIEIRA et al., 2009; DALLAGNOL et al., 2011; TOLEDO et al., 2012).

A acumulação desse material é dada por fatores inerentes às características da própria planta, principalmente aqueles que afetam a fotossíntese e a respiração (SOARES et al., 2011; RATUCHNE et al., 2016), e por fatores ambientais, como a disponibilidade de água e de fertilidade do solo, recursos limitantes na produtividade da floresta (POORTER et al., 2016). Becknell et al. (2012) verificaram que uma única variável climática, a precipitação média anual, é capaz de explicar mais de 50% da variação da biomassa.

Os estudos de biomassa são realizados com diferentes objetivos, seja para fins econômicos, buscando conhecer o potencial energético de dada floresta (BRAND, 2017; FERREIRA et al., 2019) ou para fins ambientais, na finalidade de quantificar a ciclagem de nutrientes, avaliar impactos e fundamentar estudos de sequestro de carbono (SILVEIRA, 2010; AZEVEDO et al., 2018; SANQUETTA et al., 2019).

Diversos métodos vêm sendo desenvolvidos para quantificar a biomassa das florestas, como os realizados por Santos et al. (2016), Virgens et al. (2016), Barreto et al. (2018) e Macedo et al. (2018). Eles se dividem em métodos diretos e indiretos. A determinação direta, embora mais acurada e eficaz, é um processo demorado, oneroso e envolve técnicas destrutivas (CALDEIRA et al., 2015), o que a torna inviável se a finalidade for contribuir para a manutenção das florestas. No entanto, é um procedimento necessário para o estabelecimento de métodos indiretos, que são alternativos sustentáveis que estimam a biomassa por meio de relações matemáticas, a partir de dados de inventários, e geotecnologias (FERRAZ et al., 2014; HENTZ et al., 2014; RATUCHNE et al., 2016).

Os esforços na quantificação em áreas de Caatinga são empregados desde o início dos anos 1990, e embora o volume de trabalhos ainda seja incipiente (CASTANHO et al., 2020), o interesse em conhecer o estoque de biomassa dessa formação tem sido crescente. Das variáveis de uma floresta, os estudos da biomassa têm sido promissores por subsidiarem o desenvolvimento e aperfeiçoamento de técnicas de mensuração dos serviços ambientais (AMARAL et al., 2010). Presume-se que a Caatinga apresente menores estoques de biomassa por unidade de área quando comparado a outros biomas (SANTOS et al., 2016), porém esses estoques tendem a variar de acordo com o fragmento observado.

Lima Júnior et al. (2014) estimaram valores que variaram entre 5,93 e 60,74 t.ha<sup>-1</sup> para vinte parcelas em Petrolina (PE). Ao estudar os estoques de um fragmento de Caatinga arbustiva-arbórea, no município de Caicó (RN), Santos et al. (2016) quantificaram a biomassa em 12 t.ha<sup>-1</sup>. Já em um fragmento florestal pouco degradado em Poço Verde, Sergipe, foi estimado aporte de biomassa de 54,93 t.ha<sup>-1</sup> (OLIVEIRA, 2016) e em um fragmento com 30 anos de regeneração, no Ceará, o estoque foi de 43,25 t.ha<sup>-1</sup> (PEREIRA JÚNIOR et al., 2016). Comumente, estoques acima de 40 t.ha<sup>-1</sup> têm sido associados a áreas com menor grau de perturbação, conquanto em áreas em estágios iniciais de regeneração têm oscilado entre 22 a 30 t.ha<sup>-1</sup> (CABRAL et al., 2013; COSTA et al., 2014).

A produtividade anual de biomassa apresenta variabilidade espacial e temporal, associada principalmente à disponibilidade hídrica (SAMPAIO e COSTA, 2011). A grande variação verificada nas áreas de abrangência da formação depende não somente das condições climáticas, mas também do estágio sucessional da floresta e da riqueza de espécies. Souza et al. (2019) destacaram que as florestas mais antigas e em regiões de maior precipitação tendem a suportar maior número de espécies, que refletirão em maior estoque de biomassa, reforçando a necessidade de conservação desses fragmentos e de pousios longos em paisagens modificadas pelo homem.

Sampaio e Costa (2011) defenderam ainda a influência das formas de manejo da área sobre os estoques de biomassa. Esses mesmos autores analisaram os principais usos da terra no bioma: mata nativa, pastos nativos, pastos plantados e lavouras. Como esperado, verificaram que a cobertura com vegetação nativa confere maior estoque do que em áreas cobertas com pastagem, que superam os estoques das áreas de lavoura.

Todavia, a perturbação antrópica é cotidiana nessas áreas. A Caatinga é tida como um imenso mosaico de áreas que estão em distintos estágios de regeneração. Isso, pois, para a grande parte das áreas remanescentes nativas, a extração de lenha, a derrubada e a queima para formação de roçados e pastos são recorrentes (SAMPAIO, 2010; ALTHOFF et al., 2018), o que implica a redução do estoque e da produção de biomassa, gerando consideráveis emissões de CO<sub>2</sub> e redução da capacidade de fixar o CO<sub>2</sub> atmosférico (BRAND, 2017). Apesar desse cenário, Pereira Filho e Bakke (2010) acreditam que boa parte da vegetação seja passível de recuperação e exploração por vias sustentáveis, corroborando Barreto et al. (2018), que afirmaram que o manejo adequado da biomassa florestal na Caatinga favorece a sua condição como fonte de energia renovável e permite o aproveitamento dos resíduos de sua exploração.

### **2.3. Geoestatística**

A análise espacial tem se despontado como uma ferramenta fundamental em estudos que visem incorporar o espaço a um determinado fenômeno, permitindo que seja estudado e modelado considerando a sua distribuição espacial (CÂMARA et al., 2004). A necessidade em desenvolver ferramentas estatísticas capazes de caracterizar essa estrutura de variabilidade espacial, desconsiderada pela análise de

variância clássica, impulsionou o surgimento da Teoria das Variáveis Regionalizadas (MATHERON, 1965), conhecida como a geoestatística. Ribeiro Júnior (1995) a definiu como um grupo de procedimentos estatísticos aplicáveis sobre problemas nos quais os dados são espacialmente referenciados.

Devem ser tratadas como variáveis regionalizadas àquelas cujo seus valores estão diretamente relacionados com a posição espacial que ocupam, ou seja, apresentam condicionamento espacial (LANDIM, 2006). Guerra (1988) afirmou que essas variáveis apresentam dupla característica: são aleatórias, uma vez que os valores numéricos observados podem variar, consideravelmente, de um ponto a outro no espaço, e são espaciais, pois os valores observados não são inteiramente independentes, embora sejam muito variáveis no espaço.

A teoria pressupõe que a variação espacial de um atributo pode ser expressa pela soma de três componentes: um componente estrutural que representa o valor médio constante ou tendência do atributo; um componente aleatório, espacialmente correlacionado; e um erro aleatório (BURROUGH, 1987).

O estudo destas variáveis visa possibilitar a estimativa em locais que a amostragem não foi realizada (SANTOS et al., 2017a). Lundgren et al. (2017a) consideram que tais estimativas praticadas pela geoestatística oferecem, no mínimo, duas vantagens sobre as técnicas de regressão da estatística clássica: necessitam de menos amostras e fornece a localização geográfica da estimativa realizada.

Na aplicação da geoestatística, tem-se como ferramenta fundamental o semivariograma, que detecta e revela a medida do grau de dependência espacial de uma variável em análise (LANDIM, 2006; MELLO e OLIVEIRA, 2016). Caso haja dependência espacial, é esperado que observações próximas, no tempo e no espaço, possuam comportamentos mais semelhantes do que aquelas separadas por maiores distâncias (OLIVEIRA et al., 2015). Sendo assim, um semivariograma com características próximas do ideal, revela diferenças entre os dados que decrescem à medida que a distância que os separa também decresce (CAMARGO, 1998).

Há três tipos de semivariogramas: o real, aquele que representa a situação verdadeira, e logo, é de determinação inviável; o experimental ou observado, que é auferido a partir das amostras obtidas no campo e; o teórico, considerado de referência e usado para o ajuste do modelo (GUERRA, 1988). Grynshyna-Poliuga (2019) ressaltou que o ajuste de um modelo teórico é necessário, pois o uso de um semivariograma na interpolação por krigagem requer valores de semivariância

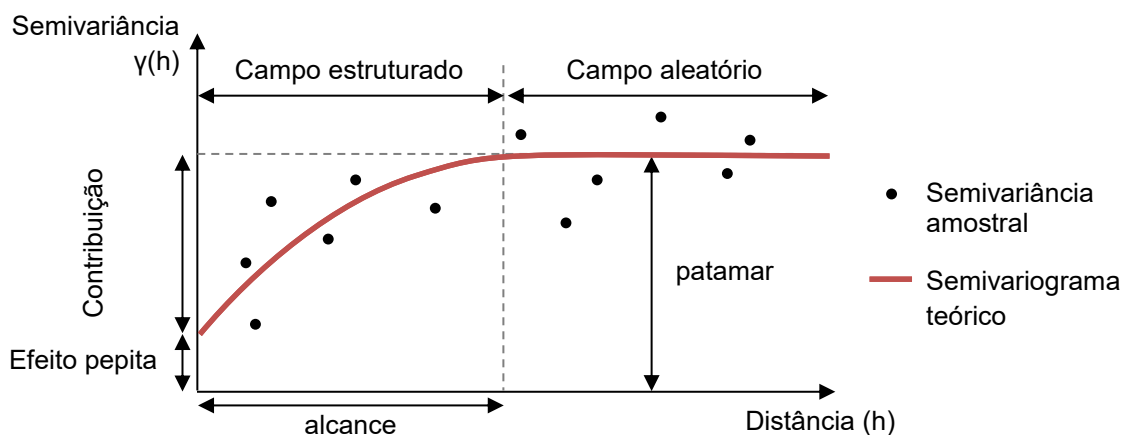


contínuos para todas as distâncias  $h$ . Isso não é fornecido pelo experimental, dado que apenas medições discretas podem ser realizadas no campo. No entanto, o comportamento do semivariograma experimental norteará a definição do modelo teórico que melhor representa os dados.

Segundo Oda-Souza et al. (2008), o melhor ajuste entre as amostras e o modelo teórico está diretamente associado à sensibilidade do semivariograma em detectar a variabilidade espacial da variável estudada. Entre os modelos teóricos disponíveis, os mais utilizados são o esférico, exponencial e gaussiano (LANDIM, 2006).

Os parâmetros que compõem o semivariograma são o efeito pepita, que corresponde a sua descontinuidade em distâncias inferiores a distância mínima de amostragem ou a erros cometidos; alcance, que compreende a distância em que as amostras estão correlacionadas espacialmente; patamar, que marca o início da região de aleatoriedade, isto é, a zona em que a dependência espacial entre as amostras deixa de existir; e contribuição que é a diferença entre o patamar e o efeito pepita, ou seja, a variância espacialmente estruturada (CAMARGO, 1998).

A Figura 1 ilustra um semivariograma com características próximas do ideal e evidencia esses parâmetros.



**Figura 1** – Esquemática de um semivariograma típico e seus componentes.  
 Fonte: Adaptado de Camargo (1998)

A razão entre o efeito pepita e o patamar, em termos percentuais, fornecem o grau de dependência espacial da variável, que pode ser classificado como forte (<25%), moderado (25% a 75%), fraco (>75%) ou revelar independência entre as amostras, conhecido como efeito pepita puro (=100%) (CAMBARDELLA et al., 1994).

Assim sendo, quanto maior for a descontinuidade na origem do semivariograma, dada pelo efeito pepita, mais aleatório é o fenômeno que originou a variável em análise, até atingir o extremo dessa situação, chamado de efeito pepita puro (SILVA et al., 2011). Nesse caso, que também é conhecido como o modelo aleatório de semivariograma, a variável em estudo apresenta independência espacial, e a semivariância é igual ao patamar para qualquer distância (LIMA et al., 2017).

Essa característica ocorre devido a erros associados à coleta e à medição das amostras ou a uma suposta regionalização inferior à menor distância da malha de amostragem (CAMARGO, 1998; DEBASTIANI et al., 2018). Assim, mesmo que o efeito pepita puro seja detectado, a hipótese de dependência espacial para o atributo estudado não deve ser eliminada, pois pode ser manifestada em distâncias menores do que a menor distância amostrada (GUIMARÃES, 2004). Cabe ressaltar que, quando ocorre comportamento totalmente aleatório, a análise espacial não se aplica, e as técnicas usuais da estatística clássica podem ser empregadas para analisar e interpolar os dados (ALMEIDA e GUIMARÃES, 2017; BERNARDI et al., 2018).

Na análise do semivariograma é importante observar se a estrutura de dependência espacial depende apenas da distância que separa as observações (GUEDES et al., 2013). Quando isso ocorre, o processo que descreve a variabilidade espacial de dado atributo é dito isotrópico. Caso a dependência espacial varie simultaneamente em razão da distância e da direção entre as observações, o processo é chamado anisotrópico (CÂMARA et al., 2004).

Observa-se que o campo geoestatístico fornece uma estrutura técnica capaz de caracterizar a variabilidade espacial de uma determinada variável de interesse, desde que a quantidade e a qualidade da amostra sejam adequadas (SCOLFORO et al., 2015). Embora a modelagem geoestatística tenha se erguido a partir de problemas relacionados à mineração, a adoção da ferramenta para a análise de dados se disseminou em diversas ciências que dispõem de fenômenos que apresentam dependência espacial (CORREIA et al., 2014; MELLO e OLIVEIRA, 2016; ROVEDA et al., 2018; SENA et al., 2019).

No meio florestal, promove maior clareza da variabilidade espacial das formações florestais, amparando tomadas de decisão no manejo das florestas, complementando os trabalhos de inventário florestal e levantamentos fitossociológicos (DEBASTIANI et al., 2018; SENA et al., 2019). Comumente, essas são atividades que se baseiam em conceitos da estatística clássica, os quais

assumem que a variabilidade espacial das variáveis dendrométricas são aleatórias, não as considerando espacialmente dependentes e acarretando em perda de informação (AMARAL et al., 2013; GUEDES et al., 2015).

Exemplos de aplicações geoestatísticas incluem estimar estoque de volume de madeira (SANTOS et al., 2017b), biomassa (BARNI et al., 2016), carbono florestal (RAJASHEKAR et al., 2018) e de serapilheira (MORAIS et al., 2017), definir zonas específicas de manejo (LIMA et al., 2017) e estratos em povoamentos florestais (REIS et al., 2016), prever estoques de carbono orgânico do solo (GOMES et al., 2019) e, mapear a precipitação (MELLO e OLIVEIRA, 2016) e insolação média (KOZMHINSKY et al., 2018).

#### **2.4. Interpolação de dados por krigagem**

Além de identificar se há estrutura espacial, o interesse maior nos estudos que empregam a geoestatística é conhecer o valor de dada característica em qualquer lugar no espaço, por meio de mapas espacialmente representativos. Isso é possível por meio da interpolação de dados. Entre os interpoladores, a krigagem tem se destacado e sido largamente utilizada, pois seus pesos são determinados a partir de uma análise espacial (CAMARGO, 1998; GRYNYSHYNA-POLIUGA, 2019).

Essa técnica é capaz de estimar uma variável espacial em locais não amostrados, a partir da interpolação por médias móveis conhecidas desta mesma variável, em pontos vizinhos (BARNI et al., 2016). O método se comporta como um interpolador ótimo, pois fornece estimativas sem tendências e com variância mínima, atribuindo pesos às diferentes amostras, que são determinados a partir da variabilidade espacial expressa pelo semivariograma experimental (MELLO e OLIVEIRA, 2016).

Logo, a modelagem do semivariograma é pré-requisito na interpolação dos dados por krigagem. Isso é o que o diferencia de outros métodos de interpolação. Além de definir os pesos, a análise espacial baseada no semivariograma define a zona de influência na interpolação, o tratamento da redundância dos dados e o erro associado à estimação (CAMARGO, 1998).

Segundo Lundgren et al. (2017b), a grande vantagem do uso da geoestatística na ciência florestal é que, além de estimar a variável no espaço, permite a construção de mapas para determinado atributo, o que, para o manejo, é uma informação de

grande valor. Isso pois, conhecer onde se localizam exatamente as maiores ou menores concentrações desse atributo na floresta, ajuda a subsidiar as atividades do manejo.

Nas ciências florestais, autores já utilizaram esse método para aprimorar modelos digitais de elevação, e, assim, otimizar o planejamento da colheita florestal em relevos acidentados (FERREIRA et al., 2017). Pelos métodos de krigagem, Barni et al. (2016) modelaram a espacialização dos estoques de biomassa em todo o estado de Roraima e geraram um mapa de referência, que fornece a base para estimativas das emissões de gases do efeito estufa por desmatamento no estado.

As técnicas de krigagem são diversas, como a krigagem simples, ordinária, co-krigagem e krigagem com regressão, todas com potencial para interpolação no meio florestal (BARNI et al., 2016; BATISTA et al., 2017; LUNDGREN et al., 2017b).

Em áreas altamente heterogêneas, busca-se o emprego de métodos híbridos de krigagem, como a krigagem com regressão, que realiza a autocorrelação espacial da variável alvo, correlacionando-a com preditores auxiliares (BATISTA et al., 2017; SILVEIRA et al., 2019a). Essa abordagem proporciona melhores previsões para os mapas em comparação com outros interpoladores, como observado por Mello et al. (2013), Scolforo et al. (2015) e Batista et al. (2017), pois considera informação auxiliar e combina dois interpoladores espaciais: um do tipo global e outro estocástico.

O primeiro se baseia em um modelo de regressão ajustado para prever a variável-alvo a partir de preditores auxiliares que são contínuos no espaço (SILVEIRA et al., 2019a). Esse interpolador produzirá um mapa global que revelará o comportamento espacial geral da variável, no entanto, sem detalhamento de áreas específicas (MELLO et al., 2013).

Para alcançar esse detalhamento, é necessária a correção desse mapa por meio da krigagem sobre os resíduos da regressão, que permite eliminar possíveis tendências das estimativas feitas pelo modelo e introduzir um aspecto estocástico ao mapeamento (MELLO et al., 2013; SCOLFORO et al., 2015). A krigagem é aplicada somente sobre os resíduos, apoiando-se na hipótese de que os resíduos retêm alguma estrutura espacial da variável principal (ODEH et al., 1995).

É importante destacar que o modelo de regressão envolvido nessa abordagem, estimará a variável principal em que os atributos secundários estiverem disponíveis, sendo assim, para um mapeamento eficaz, o método exige que esses atributos sejam exaustivos para a área de estudo (BATISTA et al., 2017).

Nas ciências florestais, as variáveis secundárias, comumente, compreendem características geográficas, topográficas e/ou climáticas, tal como, a longitude, latitude, altitude, declividade, tendências anuais e sazonais de temperatura e precipitação e, características de solo (SCOLFORO et al., 2015; GOMES et al., 2019; SILVEIRA et al., 2019a). Quando apresentam forte correlação com a variável principal, dados de sensoriamento remoto também têm sido utilizados (TSUI et al., 2013; SILVEIRA et al., 2019b; REIS et al., 2020).

## **2.5. Interpolação pelo Inverso do Quadrado da Distância (IQD)**

Em situações que a dependência espacial de uma variável de interesse for fraca ou não for detectada, a interpolação espacial pode ser realizada por interpoladores determinísticos, que se apoiam em critérios apenas geométricos (YAMAMOTO e LANDIM, 2013; SANTOS et al., 2017a).

O interpolador determinístico mais utilizado é o Inverso da Distância Ponderada (IDW), que realiza a predição de locais não amostrados considerando os dados conhecidos de pontos vizinhos (YAMAMOTO, 2001). O IDW assume que locais próximos apresentam maior semelhança e, portanto, valores medidos em pontos próximos ao local a ser estimado, terão maior influência na interpolação do que pontos mais distantes (ZECH et al., 2018).

Para isso, atribui pesos diferentes para cada amostra, considerando a distância entre cada ponto a ser estimado e observado. O peso é calculado pelo inverso dessa distância elevada a uma potência  $p$  (YAMAMOTO, 2001). Efetivamente, isso significa que, à medida que a distância aumenta, o peso que o ponto de dados observado terá na previsão diminui exponencialmente (PALMER et al., 2009).

Comumente, atribui-se o valor de  $p$  igual a 2, conforme Yamamoto (2001), método que é conhecido como ponderação pelo Inverso do Quadrado da Distância (IQD).

O método se difere da krigagem porque atribui pesos proporcionais a distância, sem considerar o limite em que as variações nas distâncias influenciam o comportamento dos dados (BERNARDI et al., 2017), além de não fornecer medidas de incerteza (YAMAMOTO e LANDIM, 2013).

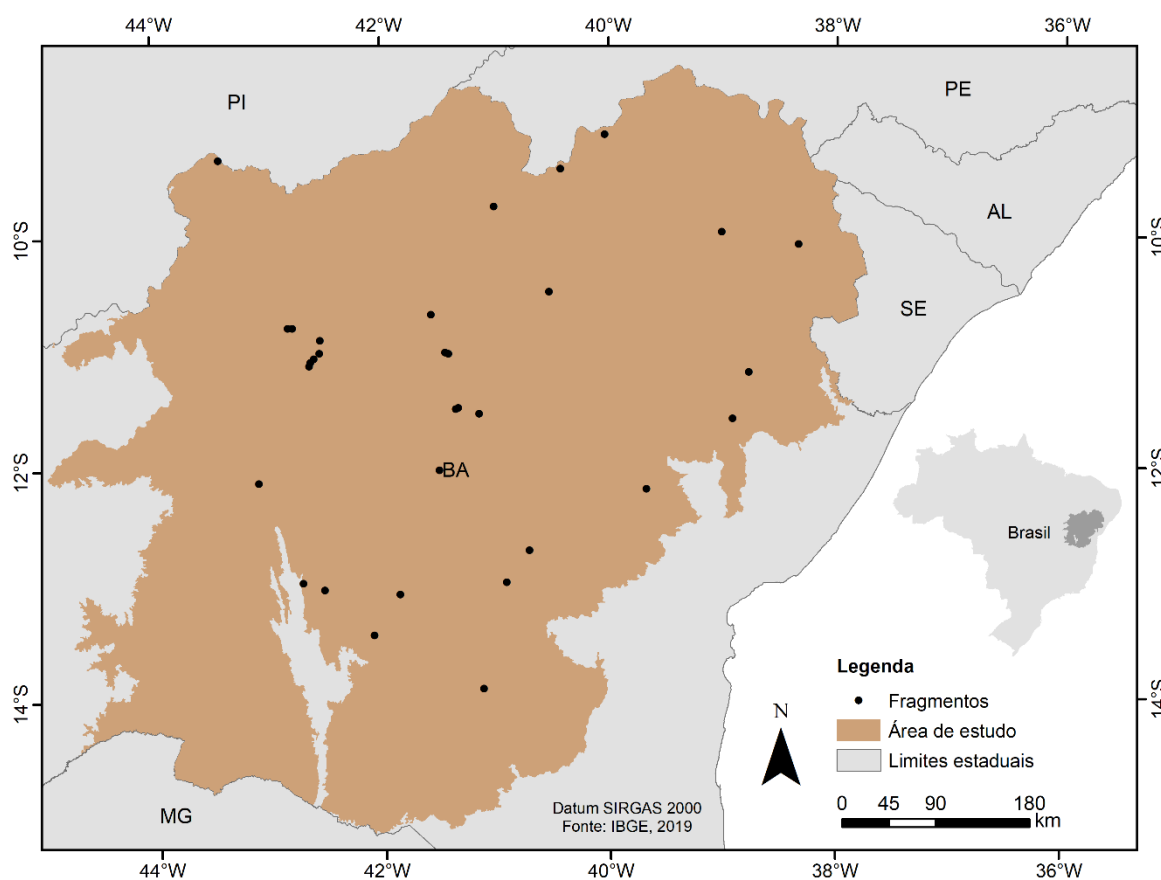
No entanto, Almeida e Guimarães (2017) e Zech et al. (2018) demonstraram que, em casos em que não há estrutura espacial, o uso do IDW é uma alternativa

pertinente, pois apresenta desempenho regular nas estimativas e pode fornecer o padrão espacial da variável de interesse. Além disso, trata-se de um método rápido e fácil de ser aplicado e que possui baixa complexidade computacional (GRYNYSHYNA-POLIUGA, 2019; SILVA JÚNIOR et al., 2019).

### 3. MATERIAL E MÉTODOS

#### 3.1. Caracterização da área de estudo

A área de abrangência deste estudo compreende o território da Caatinga inserido no estado da Bahia (Figura 2). A formação bioma ocupa uma área de 351.402 km<sup>2</sup> no estado, cobrindo cerca de 62% do território baiano (IBGE, 2019).



**Figura 2** – Localização dos fragmentos amostrados no bioma Caatinga, no estado da Bahia, Brasil.

De acordo com a classificação climática de Köppen (ALVARES et al., 2013), nessa área, é predominante o tipo climático BSh, caracterizado como clima semiárido seco e quente, que associa a escassez de chuvas à forte insolação e a temperaturas elevadas. Também estão presentes o clima tropical As, com estação de verão seco, e, na face oeste, o tipo Aw, com inverno seco. Em uma pequena região no centro-sul, onde as altitudes são superiores a 1000 m, há a ocorrência das zonas subtropicais úmidas de verão ameno Cwb – com inverno seco –, e Cfb, sem estação seca.

Há irregularidade na distribuição das chuvas no tempo e no espaço. Essa região recebe de 300 mm a 1180 mm anuais de chuva, todavia, uma parte expressiva da área recebe precipitação média inferior a 750 mm/ano; em uma pequena parte a precipitação é menor que 400 mm anuais. Geralmente, cerca de 50% desses totais anuais se concentram em apenas três meses (FICK e HIJMANS, 2017).

As temperaturas também variam no espaço, com médias anuais entre 16 e 29°C, entretanto, predominantemente são superiores aos 24°C (FICK e HIJMANS, 2017). No relevo estão presentes planaltos, serras e chapadas que podem superar os 1000 m de altitude. Entre essas geomorfologias estão as depressões que ocorrem de forma mais expressiva em toda a área. O relevo apresenta influência sobre os padrões espaciais das temperaturas (CASTANHO et al., 2020).

As ordens de solos que ocorrem são: Neossolos – típicos no ambiente semiárido do nordeste brasileiro, caracterizados por baixa fertilidade natural, baixa capacidade de retenção de água e baixos teores de matéria orgânica –, Latossolos, Planossolos, e ainda pequenos fragmentos de Cambissolos, Argissolos e Luvisolos (MARQUES et al., 2014; IBGE, 2021).

A vegetação com maior representatividade é a Savana Estépica, que apresenta fisionomia decidual, cinzenta e espinhosa na estação seca, entremeada por cactáceas e bromeliáceas. Essa paisagem é interrompida por fragmentos de Florestas Estacionais Semidecíduais – que ocupam regiões de solos com afloramentos rochosos e relevo cárstico –, e Decíduais associadas a solos mais argilosos e com presença de calcário nos vales e encostas. Essa última é mais expressiva na face oeste da área de estudo. Em regiões serranas, brejos e bolsões climáticos mais amenos, comuns no centro-sul do estado da Bahia, há a ocorrência de Savana, e de pequenos fragmentos de Floresta Ombrófila Densa (IBGE, 2019).

### **3.2. Estimativa da biomassa**

A base de dados para a estimativa da biomassa foi obtida de levantamentos florestais realizados dentro da área de estudo, que contemplam um total de 836 parcelas distribuídas em 32 fragmentos florestais (Figura 2).

Para compor esse banco de dados, foram cedidos pelo Instituto do Meio Ambiente e Recursos Hídricos do Estado da Bahia – INEMA, 21 inventários florestais realizados entre os anos de 2016 e 2020. O número e o tamanho das parcelas



variaram entre os inventários em 0,02 ha a 0,1 ha. Os indivíduos arbóreos foram mensurados quanto à Circunferência à Altura do Peito (CAP), medida a 1,30 metros acima do nível do solo, adotando como critério de inclusão o CAP maior ou igual a 10 cm.

A esse banco, foram acrescentados dados de 10 parcelas permanentes de 1 ha, registradas no ForestPlots.net (LOPEZ-GONZALEZ et al., 2009, 2011). Essas parcelas foram inventariadas entre os anos de 2017 e 2018. Para esses dados, assumiu-se cada parcela como um fragmento florestal e foram consideradas apenas as árvores com CAP  $\geq$  10 cm.

Ainda foi considerado como um único fragmento florestal, um levantamento realizado no ano de 2015, na Floresta Nacional Contendas do Sincorá, inventariado por uma parceria entre a Rede de Manejo Florestal da Caatinga e os Laboratórios de Solos Florestais e de Ecologia e Proteção Florestal da Universidade Estadual do Sudoeste da Bahia – UESB. Ali foi realizada a medição de indivíduos arbóreos com CAP  $\geq$  15 cm.

Para a predição da biomassa lenhosa seca, foi aplicada sobre os dados individuais das árvores das parcelas a Equação 1 desenvolvida por Sampaio e Silva (2005). A equação é específica da Caatinga e é a mais utilizada pela comunidade científica da formação.

$$AGB = 0,1730 * DAP^{2,295} \quad (R^2 = 92\%) \quad \text{Eq. 1}$$

Em que: AGB é a biomassa seca acima do solo para cada indivíduo arbóreo (kg), DAP é o diâmetro medido a 1,30 m acima do solo (cm) e  $R^2$  é o coeficiente de determinação.

Os estoques de biomassa das árvores por parcela foram somados e, de acordo com o tamanho das parcelas, foram extrapolados em tonelada por hectare ( $t \cdot ha^{-1}$ ).

Devido à heterogeneidade no estoque de biomassa das parcelas dentro de um mesmo fragmento, o conjunto de dados utilizado nas análises foi a média do estoque de biomassa das parcelas em cada um dos 32 fragmentos florestais (SCOLFORO et al., 2016). Os cálculos foram realizados utilizando o software Microsoft Office Excel 2019.

### 3.3. Mapeamento do estoque de biomassa

O mapeamento do estoque de biomassa foi realizado por meio das técnicas da krigagem com regressão (RK) e do Inverso do Quadrado da Distância (IQD).

#### 3.3.1. Interpolação por krigagem com regressão

A krigagem com regressão combina dois processos: a elaboração de um mapa global que ilustra o comportamento espacial da biomassa, gerado a partir de um modelo de regressão multivariado; e posterior aplicação da krigagem ordinária sobre os resíduos gerados pelo modelo de regressão.

##### 3.3.1.1. Modelagem do estoque de biomassa

A fim de introduzir características específicas de cada microrregião da área de estudo e fornecer uma base contínua de dados, a biomassa foi modelada em função de variáveis espaciais (Tabela 1). Em estudos anteriores, essas variáveis demonstraram relação com a distribuição espacial de atributos florestais (LIMA JÚNIOR et al., 2014; SCOLFORO et al., 2015; SILVEIRA et al., 2019a).

**Tabela 1** – Variáveis espaciais utilizadas para a modelagem de biomassa na Caatinga, Bahia

Variáveis	Descrição
Long	Longitude (m)
Lat	Latitude (m)
Elev	Elevação (m)
Temp	Temperatura média anual (°C)
Prec	Precipitação média anual (mm)

A extração das variáveis geográficas e topográfica partiu do modelo digital de elevação (DEM) derivado do mapa disponibilizado pela NASA-SRTM (*Shuttle Radar Topography Mission*), com resolução espacial de 100 metros. Os mapas de temperatura e precipitação foram adquiridos da base mundial de dados *WorldClim – Global Climate Data version 2.1* (FICK e HIJMANS, 2017), com resolução de 2,5 minutos (~5 km).

Todas as variáveis foram recortadas para a extensão da área de estudo utilizando os pacotes raster (HIJMANS, 2021) e rgdal (BIVAND et al., 2021) para o software R (R CORE TEAM, 2021).

Os valores de biomassa a serem usados na modelagem foram submetidos à análise exploratória para identificar a presença de valores discrepantes e sua influência sobre os pressupostos da regressão.

Para o ajuste do modelo utilizou-se a análise de regressão linear múltipla, e os parâmetros foram estimados pelo método dos mínimos quadrados. Foi empregada a técnica *stepwise* com base no Critério de informação de Akaike (AIC) com direção *both*, a fim de definir quais variáveis melhor explicam a biomassa, para a construção de um modelo multivariado.

Foram aplicados os testes de Shapiro-Wilk e Breusch-Pagan para verificar se os resíduos do modelo apresentavam normalidade e homocedasticidade, respectivamente. Além disso, o modelo foi submetido ao teste de Fator de Inflação de Variância (VIF), para analisar possíveis correlações entre as variáveis explicativas e garantir que o modelo seja livre de multicolinearidade.

Para testar a eficiência do modelo ajustado foram avaliados o coeficiente de determinação ( $R^2$ ), Erro Médio Absoluto (MAE) e análise gráfica dos resíduos. Também se utilizou do gráfico de dispersão dos valores preditos ao redor da reta 1:1 para observar o comportamento das predições realizadas pelo modelo.

Todas as análises foram realizadas utilizando o software R (R CORE TEAM, 2021).

### **3.3.1.2. Espacialização do estoque de biomassa**

Os mapas das variáveis selecionadas no modelo multivariado foram projetados para a área de estudo em formato raster, com resolução espacial de 1 hectare (100 x 100 m). Sobre essas células, o modelo de regressão foi aplicado, possibilitando estimar o estoque de biomassa em cada pixel e, conseqüentemente, gerar um mapa global da biomassa.

Todavia, no procedimento de krigagem com regressão, esse mapa necessita ser detalhado por meio da adição de um mapa de distribuição espacial dos resíduos do modelo de regressão.

Para aplicação da geoestatística sobre os resíduos, inicialmente, foi empregada uma análise exploratória dos dados, de modo a conhecer a sua distribuição, tendências e identificar observações atípicas (*outliers*). Essa análise preliminar é fundamental para a tomada de decisões nos procedimentos geoestatísticos.

Para o cálculo do semivariograma experimental dos resíduos, utilizou-se o estimador clássico de Matheron (1963), e o alcance foi limitado à metade da distância máxima entre dois pontos, conforme Dall’Agnol et al. (2018). Para averiguar a existência de anisotropia nos resíduos, verificou-se o comportamento de semivariogramas construídos em quatro direções horizontais: 0°, 45°, 90° e 135° (GUEDES et al., 2013).

Foram ajustados os modelos teóricos esférico, exponencial e gaussiano diretamente aos dados, pelo método da Máxima Verossimilhança, considerando a pressuposição de estacionariedade da hipótese intrínseca (JOURNEL e HUIJBREGTS, 1978). Esse método de ajuste estima os parâmetros em função do conjunto original dos dados e não apresenta dependência dos pontos do semivariograma experimental, entretanto, requer a normalidade dos dados (MELLO et al., 2005; SANTOS et al., 2011).

Após os ajustes, os parâmetros dos semivariogramas foram determinados, e a razão entre efeito pepita e o patamar evidenciou o grau de dependência espacial, em conformidade com Cambardella et al. (1994).

O modelo teórico para a interpolação foi selecionado pela avaliação do Critério de Informação de Akaike (AIC), do grau de dependência espacial, do erro médio reduzido (EMR) e do desvio padrão do erro médio reduzido ( $S_{ER}$ ) fornecidos pela validação cruzada do tipo Jackknife (MELLO et al., 2005; MORAIS et al., 2017). Quanto mais próximo de zero for o EMR e quanto mais próximo de 1 for o  $S_{ER}$ , melhor o desempenho do modelo.

A partir dos parâmetros do modelo espacial selecionado, os resíduos da regressão foram interpolados por krigagem ordinária, obtendo-se o mapa residual que acrescentará um aspecto estocástico ao mapa global do estoque de biomassa. Essa abordagem visa melhorar a qualidade inicial das estimativas do mapa global, que pode apresentar tendências nas estimativas e não gerar uma distribuição espacial suficientemente detalhada da biomassa.

A qualidade preditiva da krigagem foi avaliada pelo erro médio (EM), erro médio padronizado (MSE), raiz quadrada do erro médio padronizado (RMSSE), raiz

quadrada do erro médio (RMSE) e erro padrão médio (ASE), que medem a precisão das estimativas e são fornecidos pela validação cruzada.

Logo, pela adição do mapa residual ao mapa global, usando ferramentas de álgebra de mapas, obteve-se o mapa final não enviesado da distribuição espacial da biomassa para toda a área de domínio da Caatinga no estado da Bahia.

O ajuste dos semivariogramas foi realizado utilizando o software R (R CORE TEAM, 2021), com o auxílio do pacote geoR (RIBEIRO JUNIOR et al., 2020) e os mapas e interpolação foram elaborados no software ArcGis (ESRI, 2019).

### **3.3.2. Interpolação pelo Inverso do Quadrado da Distância (IQD)**

A predição de biomassa utilizando o interpolador determinístico foi realizada por meio do Inverso da Distância Ponderada (IDW) com expoente 2, método conhecido como Inverso do Quadrado da Distância (IQD), conforme Yamamoto (2001). Os parâmetros de vizinhança foram definidos para um mínimo de 10 pontos e um máximo de 32 pontos, que corresponde ao número total de pontos amostrais na área de estudo.

O desempenho no mapeamento foi avaliado em critérios visuais e estatísticos. Usou-se para a avaliação estatística o erro médio (EM) e a raiz quadrada do erro médio (RMSE). O EM mediu o viés de predição e seus valores devem ser próximos a zero para previsões imparciais (PALMER et al., 2009). Valores negativos do EM sugerem que a técnica de predição está superestimando, enquanto que valores positivos apontam uma subestimação.

A interpolação por IQD foi realizada no software ArcGis (ESRI, 2019).

## 4. RESULTADOS E DISCUSSÃO

### 4.1. Análise exploratória

Os valores estimados de estoque de biomassa nos fragmentos estudados variaram entre 2,85 a 80,88 t.ha<sup>-1</sup>. Há uma proximidade entre o valor médio (25,17 t.ha<sup>-1</sup>) e mediano (20,33 t.ha<sup>-1</sup>), o que demonstra uma distribuição dos dados aproximadamente simétrica, mas a superioridade da média indica que os valores mais altos de biomassa estão mais distantes do centro, em comparação com os menores estoques.

A diferença acentuada entre o valor mínimo e máximo, acarretou em um alto coeficiente de variação (73,69%), indicando a heterogeneidade da área de estudo. Essa variação retrata como as condições dos fragmentos amostrados são distintas. Ocorrem nesses fragmentos diferentes estágios sucessionais e graus de antropização, variação no número de indivíduos por hectare, na riqueza e diversidade de espécies e, nos diâmetros e alturas das árvores.

A média de biomassa encontrada foi semelhante à estimada por Souza et al. (2019) em uma área protegida em Pernambuco (28,48 t.ha<sup>-1</sup>) e inferior a um fragmento em Sergipe, que exibiu um aporte de 54,93 t.ha<sup>-1</sup> (OLIVEIRA, 2016). Em Petrolina/PE, Lima Júnior et al. (2014) estimaram valores entre 5,93 e 60,74 t.ha<sup>-1</sup>, enquanto em Caicó/RN, Santos et al. (2016) observaram um intervalo menor, entre 10 e 17,8 t.ha<sup>-1</sup> de biomassa. A discrepância entre os estoques de biomassa observada nos trabalhos referidos evidencia a variação fisionômica que ocorre ao longo de fragmentos da Caatinga.

Essas diferenças nos estoques entre áreas de caatinga estão associadas à precipitação, à distribuição irregular das chuvas e ao estágio sucessional da floresta, que promovem variação no acúmulo e distribuição de biomassa das espécies (LIMA JÚNIOR et al., 2014). Souza et al. (2019) confirmaram que a biomassa da formação é altamente variável, porque é resultante de uma combinação entre a idade do fragmento florestal, das chuvas e da riqueza de espécies. Os autores verificaram que, florestas mais antigas e expostas à maior precipitação suportam maior número de espécies e apresentam o dobro de biomassa, quando comparadas a áreas sucessionais e pobres em espécies.

## 4.2. Interpolação por krigagem com regressão

### 4.2.1. Modelagem do estoque de biomassa

Foram identificados fragmentos com valores discrepantes para a biomassa, removidos da base de dados utilizada para análises subsequentes, pois influenciavam os pressupostos da regressão. Desse modo, utilizou-se 27 fragmentos para a modelagem e análise geoestatística.

Os parâmetros usados no modelo de regressão apresentaram coeficientes significativos (Tabela 2), o que implica a importância das variáveis selecionadas. O teste VIF confirma a inexistência de multicolinearidade entre elas. O modelo reteve três variáveis, o que é desejável no uso da regressão linear múltipla, pois reduz a complexidade e o tempo despendido para coleta de dados e uso do modelo.

**Tabela 2** – Coeficientes estimados pelo modelo de regressão e Fator de Inflação de Variância (VIF)

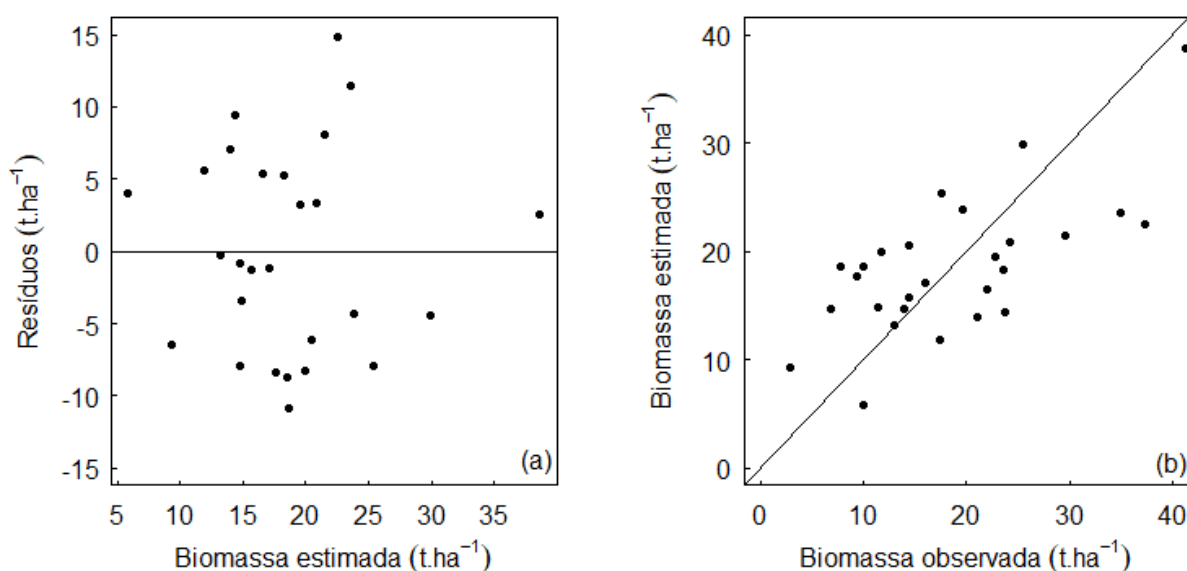
Parâmetro	Variável	Coeficiente	p-valor (<0,05)	VIF
b0	Intercepto	519,3	0,000346	-
b1	Lat	-0,0000594	0,000293	1,70
b2	Temp	1,831	0,045831	1,18
b3	Prec	-0,03326	0,016238	1,59

Lat = Latitude (m); Temp = Temperatura Média Anual (°C); Prec = Precipitação média anual (mm).

O modelo apresentou coeficiente de determinação ( $R^2$ ) igual a 46% e Erro Médio Absoluto (MAE) de 5,94%, que indicou que o modelo teve bom desempenho. O MAE demonstra a habilidade do modelo em fazer estimativas mais próximas das reais, quando seu valor tende a zero (REIS et al., 2020). O  $R^2$  demonstra o quanto o modelo é capaz de explicar os dados observados. O valor encontrado aqui é tido como aceitável, dada a magnitude da área de estudo e a ampla variação que ocorre entre os estoques de biomassa dos fragmentos estudados. Condições semelhantes também são relatadas por Scolforo et al. (2016), que encontraram  $R^2$  igual a 53% para um modelo geográfico que estima o estoque de carbono no estado de Minas Gerais.

Os resíduos da regressão seguem distribuição normal (Shapiro-Wilk, p-valor = 0,32) e são homocedásticos (Breusch-Pagan, p-valor = 0,36). Essas características são essenciais para definir a adequação do modelo e permitem adotar o método da Máxima Verossimilhança no ajuste do semivariograma, que requer o conhecimento a priori da distribuição dos dados (ALVARENGA et al., 2012).

A qualidade do modelo pode também ser verificada na Figura 3. O modelo apresentou resíduos distribuídos aleatoriamente e não manifestam desvios significativos da média ou heterogeneidade de variância, sugerindo que não há tendências de subestimação ou superestimação (Figura 3a). Essas características configuram modelo livre de viés de estimativas.

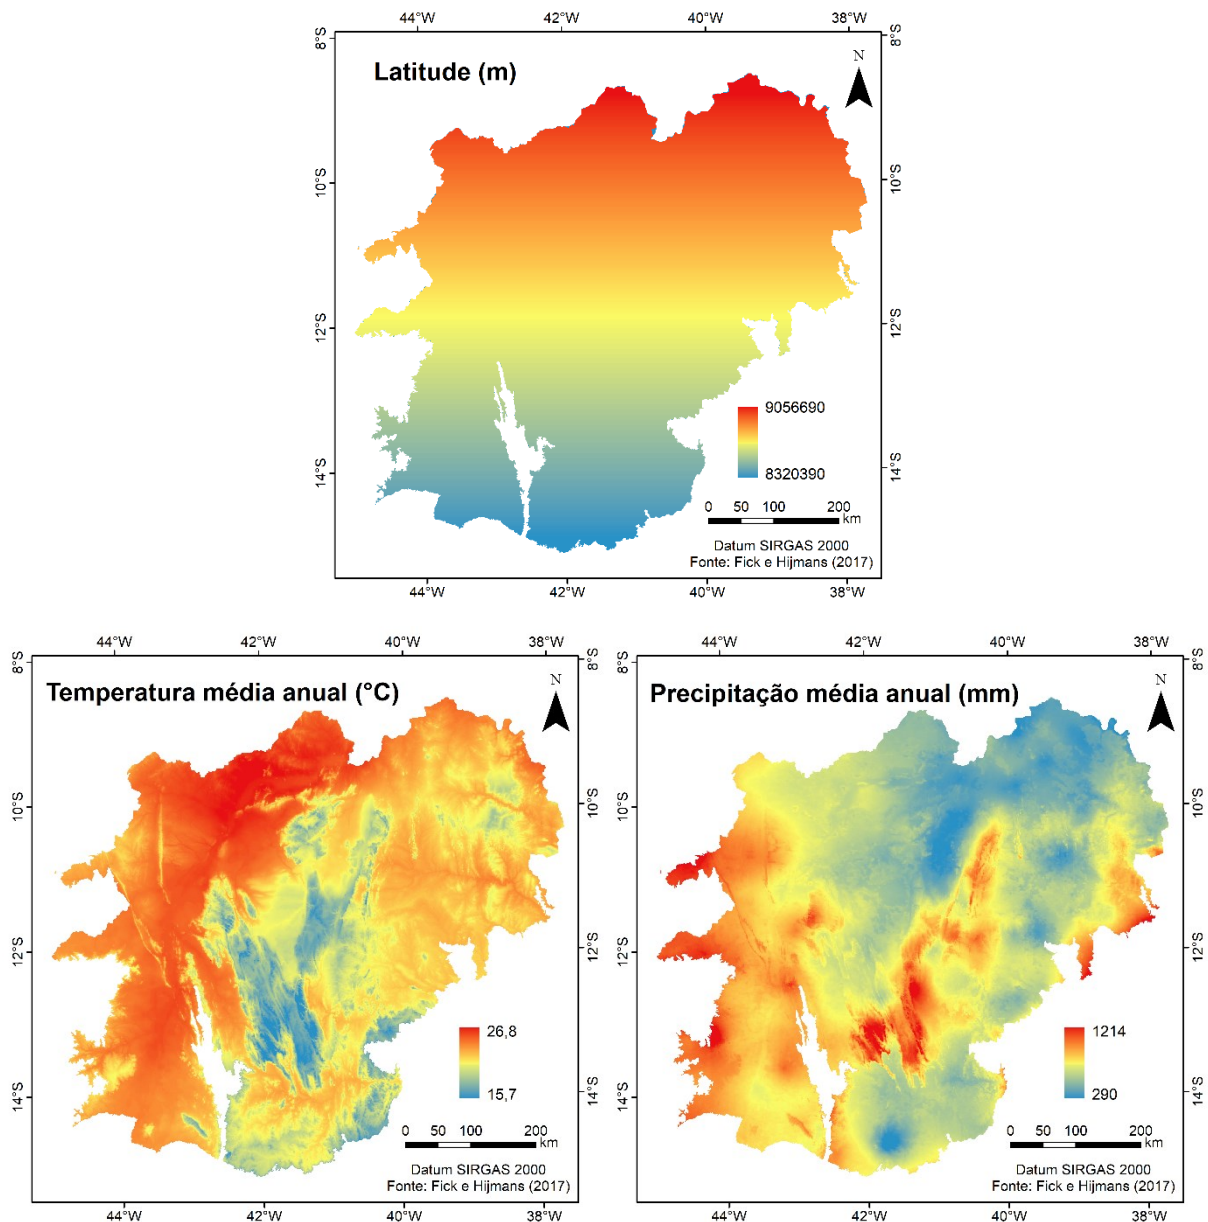


**Figura 3** – Distribuição gráfica dos resíduos da regressão (a); e biomassa observada versus estimada a partir do modelo ajustado para a Caatinga, Bahia (b).

A Figura 3b ilustra o comportamento da biomassa estimada em relação à observada. Quanto maior a proximidade dos valores preditos a linha 1:1, melhor o ajuste. Ou seja, há maior precisão, menor risco de haver viés de estimativa, e consequentemente, a soma dos resíduos tendem a zero.

A latitude, a temperatura média anual e a precipitação média anual são as principais variáveis responsáveis pela variação do estoque de biomassa da Caatinga, no estado da Bahia (Figura 4). A contribuição da precipitação já é consolidada na literatura (BECKNELL et al., 2012; BARNI et al., 2016; POORTER et al., 2016; SILVEIRA et al., 2019b; SOUZA et al., 2019). A disponibilidade de água no solo aumenta a atividade fotossintética das plantas, influenciando a sazonalidade e a intensidade da produção foliar, e consequente produção de biomassa (SOUZA et al., 2019).





**Figura 4** – Variáveis selecionadas pelo modelo de regressão multivariado para a estimativa de biomassa na Caatinga, Bahia.

O uso de equações alométricas em função de variáveis geográficas e climáticas para estimar a biomassa é vantajoso, pois, além de ser um método não destrutivo, é capaz de prever sobre áreas extensas com rapidez e baixo custo, com um erro médio absoluto de 5,94%.

O erro de predição associado ao modelo desenvolvido pode ser decorrente do grau de precisão da aplicação da equação alométrica utilizada neste estudo, que apresenta  $R^2$  igual a 92% (SAMPAIO e SILVA, 2005). O erro também pode ser atribuído ao processo de medição das árvores que foram feitas em diferentes ocasiões e por equipes distintas.

A alta variabilidade, que ocorre nos valores de biomassa que promoveram o alto coeficiente de variação, também representa uma dificuldade adicional para o ajuste de modelo multivariado. Isso também foi observado por Mello et al. (2013), que relataram prejuízos nas estatísticas de precisão ao modelar a erosividade da chuva para a região Nordeste, atribuída à alta variabilidade da precipitação nessa região.

Ratuchne et al. (2016), Scolforo et al. (2016) e Silveira et al. (2019a) comprovaram que componentes ambientais podem ser variáveis altamente explicativas e capazes de estimar atributos florestais. O presente estudo corrobora os autores, ao identificar que há um potencial para o desenvolvimento de modelos capazes de estimar a biomassa da vegetação da Caatinga com o uso de variáveis ambientais. Contudo, faz-se necessário o aprimoramento desses modelos, visando ao aumento na precisão da estimativa, haja vista que equações de regressão estão sempre associadas a incertezas (RATUCHNE et al., 2016). Sugere-se estudos que utilizem maior população amostral, o que permitirá a construção de equações mais robustas e com menores erros associados à capacidade preditiva.

Cabe ressaltar que o acúmulo de biomassa em florestas não responde somente às variáveis consideradas, mas também a outras condições ambientais, como a fertilidade do solo, déficit hídrico, sazonalidade das chuvas e estágios sucessionais (AMARO et al., 2013; POORTER et al., 2016; SOUZA et al., 2019).

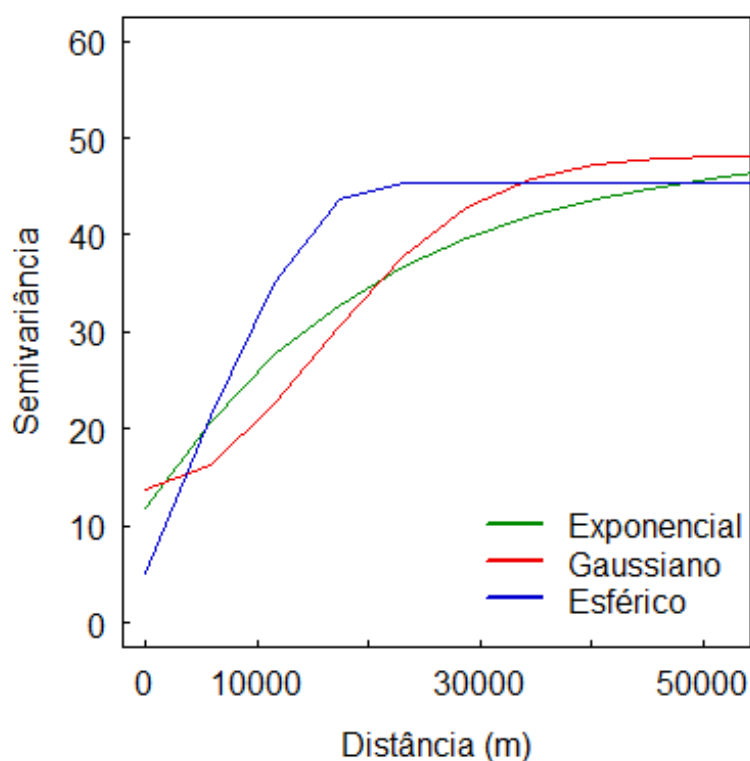
O uso de índices de vegetação e dados de sensoriamento remoto é certamente uma opção plausível para a caracterização da biomassa e desenvolvimento de modelos de regressão com menores graus de incerteza. Trabalhos nesse sentido já foram desenvolvidos por Lima Júnior et al. (2014), Silva et al. (2017), Xue et al. (2017) e Macedo et al. (2018) que encontraram boa performance nas funções ajustadas.

#### **4.2.2. Espacialização do estoque de biomassa**

A semivariância calculada nas quatro direções não mostrou diferenças significativas, e o semivariograma foi considerado isotrópico, indicando que a dependência espacial dos resíduos da regressão depende apenas da distância entre os pontos e é a mesma em todas as direções (CÂMARA et al., 2004; MELLO e OLIVEIRA, 2016).

Na Figura 5, estão representados os semivariogramas teóricos ajustados aos dados pelo método da Máxima Verossimilhança. Ressalta-se que os resíduos

apresentaram distribuição normal, o que legitima o uso desse método (SANTOS et al., 2011). É possível detectar que os resíduos do modelo de regressão se apresentam espacialmente estruturados independentemente do modelo teórico.



**Figura 5** – Ajuste dos modelos teóricos de semivariograma para os resíduos do modelo de regressão, pelo método da Máxima Verossimilhança.

Na Tabela 3 são mostrados os parâmetros dos modelos teóricos ajustados e os seus respectivos graus de dependência espacial dos resíduos, além dos critérios estatísticos utilizados para definição do melhor modelo. O modelo esférico apresentou o melhor ajuste aos resíduos do modelo de regressão, em função do menor grau de dependência espacial e efeito pepita, menor AIC e erro médio reduzido (EMR) mais próximo de zero.

**Tabela 3** – Parâmetros e critérios estatísticos dos modelos teóricos ajustados para os resíduos do modelo de regressão

Modelo	$C_0$	$C_1$	A (m)	GD (%)	EMR	$S_{ER}$	AIC
Exponencial	11,75	49,00	21000	23,90	0,018	1,001	187,3
Gaussiano	13,69	48,12	21000	28,45	0,020	1,002	186,3
Esférico	5,06	45,45	21000	11,14	0,016	0,992	185,4

$C_0$  = efeito pepita;  $C_1$  = patamar; A = alcance; GD = grau de dependência espacial, EMR = erro médio reduzido;  $S_{ER}$  = desvio padrão dos erros reduzidos; AIC = Critério de Informação de Akaike.

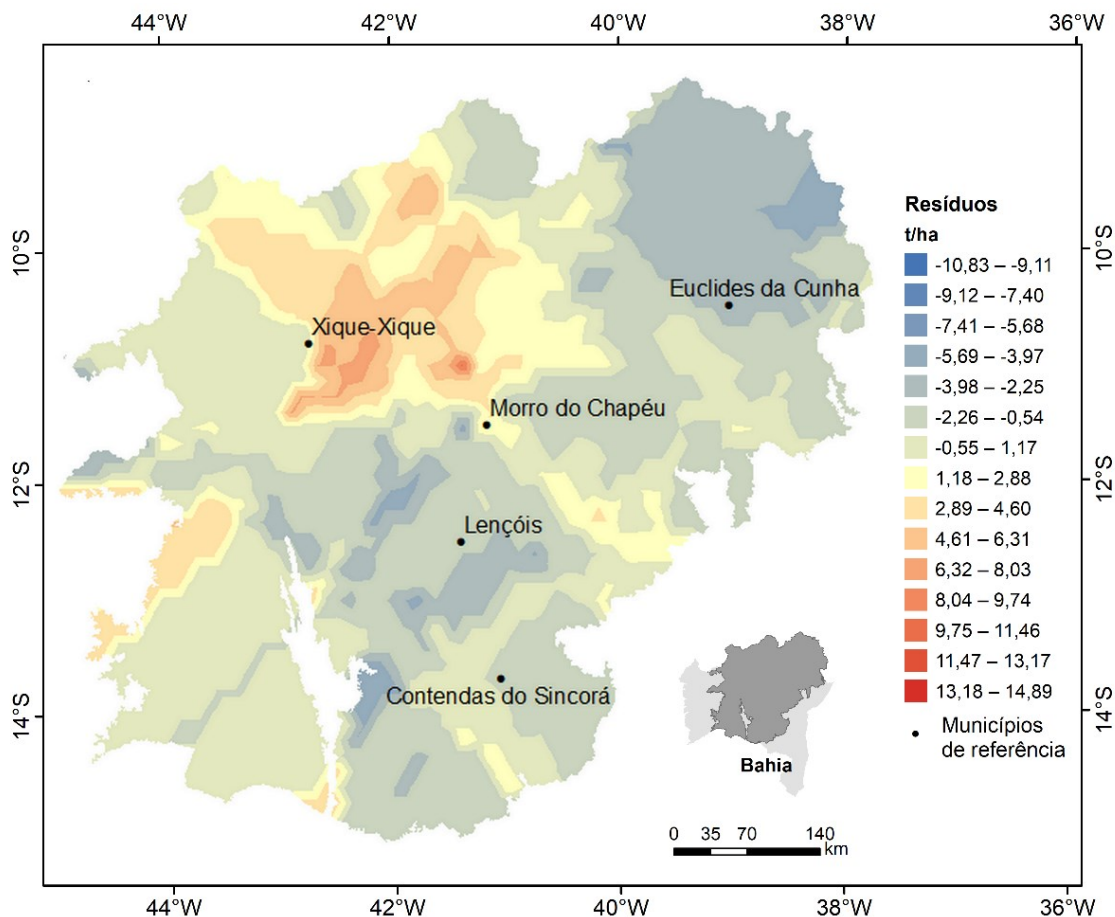
Na Figura 5, pode-se observar o menor efeito pepita associado ao modelo esférico, necessário para fornecer estimativas mais precisas na interpolação por krigagem (ALVARENGA et al., 2012). O efeito pepita diferente de zero indica que existe uma variação aleatória dos dados residuais que não pode ser explicada pela componente espacial, decorrente da falta de amostragem nas distâncias menores que a menor distância entre as parcelas (CAMARGO, 1998). A menor distância média registrada para os fragmentos amostrados foi de 2447 metros.

O alcance encontrado foi de 21.000 metros e sugere que os resíduos estão correlacionados espacialmente até essa distância. O alto valor do alcance é devido às distâncias entre os fragmentos amostrados e a magnitude da área de estudo.

A relação do efeito pepita e o patamar exprimem o grau de dependência espacial da variável, que se classifica como forte (<25%), moderada (25% a 75%) e fraca (>75%), de acordo com Cambardella et al. (1994). Todos os modelos evidenciaram uma estrutura de dependência espacial dos resíduos de forte a moderada, índices desejáveis na modelagem geoestatística (MELLO e OLIVEIRA, 2016).

O mapeamento da krigagem ordinária dos resíduos pelo modelo esférico é exibido na Figura 6. Observa-se que pontos mais próximos no espaço tendem a ter valores semelhantes entre si, principal característica revelada pela geoestatística (GRYNYSHYNA-POLIUGA, 2019).

Mello et al. (2013) destacaram que os valores positivos dos resíduos representam à subestimação do modelo, enquanto os valores negativos correspondem à superestimação. Assim, os autores asseguram que é desejável uma distribuição equilibrada dessas estimativas, pois sugere não haver tendências produzidas pelo modelo de regressão. É notável no mapa um equilíbrio entre as sub e superestimativas, evidenciando que o modelo é adequado para a área de estudo.



**Figura 6** – Mapeamento por krigagem ordinária dos resíduos do modelo de regressão.

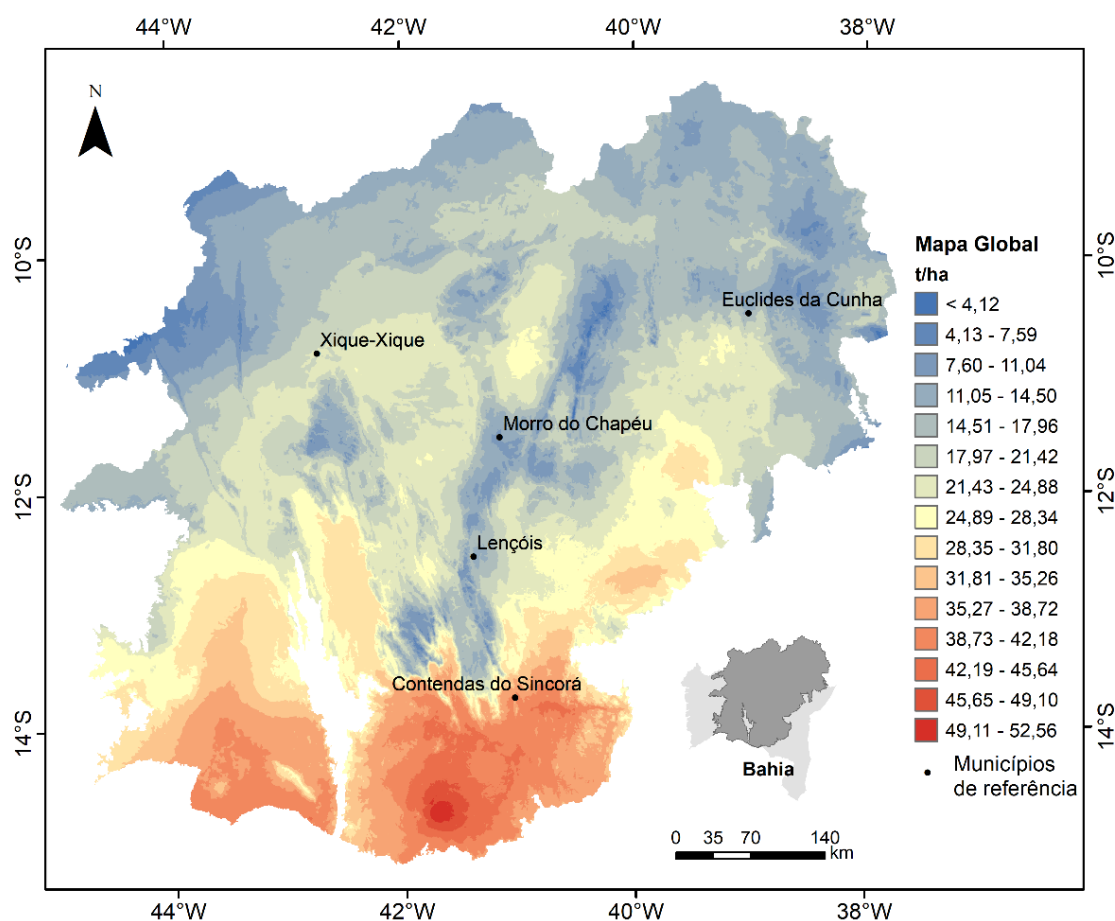
Para que o modelo de semivariograma seja apropriado para a interpolação, o erro médio (ME) e o erro médio padronizado (MSE) devem ser próximos a zero; a raiz quadrada do erro médio padronizado (RMSSE) deve ser próximo a 1 e; a raiz quadrada do erro médio (RMSE) e o erro padrão médio (ASE) devem ter os valores semelhantes e o menor possível (MELLO e OLIVEIRA, 2016). As métricas de erros associadas à superfície interpolada na krigagem ordinária dos resíduos são apresentadas na Tabela 4 e reforçam que o modelo teórico esférico foi adequado na interpolação dos resíduos. A diferença encontrada entre o RMSE e ASE indicam que a previsão foi subestimada em  $0,43 \text{ t}\cdot\text{ha}^{-1}$  (MELLO e OLIVEIRA, 2016).

**Tabela 4** – Estatísticas da interpolação por krigagem ordinária dos resíduos do modelo de regressão

ME	MSE	RMSSE	RMSE	ASE
-0,16	0,01	0,97	6,39	6,82

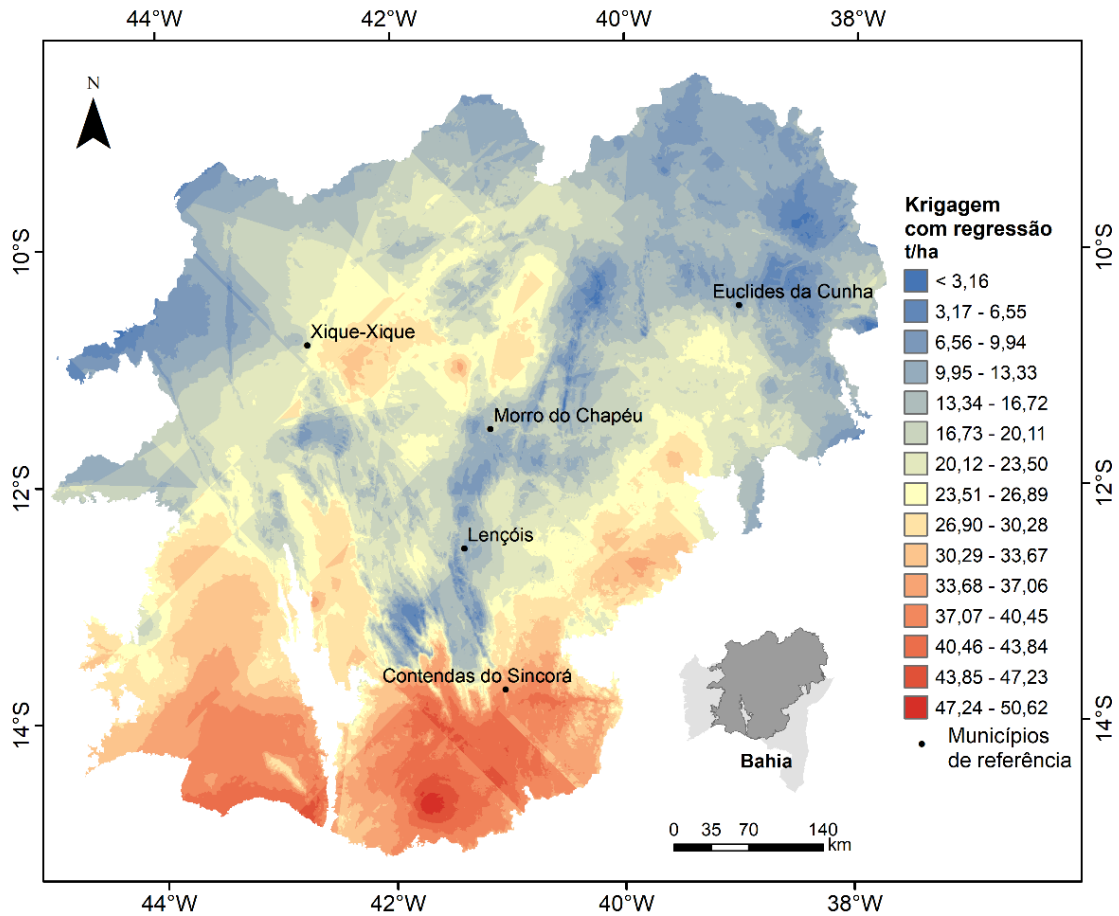
ME = Erro médio; MSE = Erro médio padronizado; RMSSE = Raiz quadrada do erro médio padronizado; RMSE = Raiz quadrada do erro médio; ASE = Erro padrão médio.

O mapeamento do estoque de biomassa obtido a partir do modelo de regressão demonstra o comportamento global desse estoque na área de estudo (Figura 7).



**Figura 7** – Mapa global do estoque de biomassa obtido pelo modelo de regressão.

A junção das estimativas do modelo de regressão (Figura 7) e dos resíduos krigados (Figura 6) resultaram no mapa final de previsão do estoque de biomassa por krigagem com regressão (RK), representado na Figura 8. O mapa global e o mapa corrigido pela krigagem dos resíduos revelam comportamentos semelhantes dos estoques de biomassa, no entanto, é notável o maior detalhamento dado pelo mapa final.



**Figura 8** – Mapa do estoque de biomassa do bioma Caatinga na Bahia, interpolado por krigagem com regressão (RK).

Em geral, ocorre um aumento do estoque de biomassa na direção norte-sul. No norte da área de estudo ocorrem estoques de biomassa inferiores a  $20 \text{ t}\cdot\text{ha}^{-1}$ , decorrente dos menores índices de precipitação e das temperaturas mais elevadas. A região que circunda o município de Euclides da Cunha é classificada por Ganem (2017) como área prioritária para a criação de unidade de conservação de proteção integral, devido à urgência por perda de habitat e susceptibilidade à degradação ambiental.

Uma pequena área próxima ao município de Xique-Xique se destacou por exibir maiores valores de biomassa. A junção do mapa residual evidencia a subestimativa dada pelo mapa global nessa região, reforçando que a combinação entre um interpolador global e um geoestatístico representam melhor a distribuição espacial de uma variável. O evidente detalhamento dado nessa área específica é decorrente da maior concentração de fragmentos amostrados ali, o que aproximou o mapa de RK ao real estoque dessa região.

No sul do mapa estão os maiores estoques de biomassa. No município de Contendas do Sincorá, a biomassa foi estimada em 37 t.ha<sup>-1</sup>, enquanto Virgens et al. (2016) estimaram um valor médio de 29,2 t.ha<sup>-1</sup>. Os autores classificam a vegetação predominante nessa área como caatinga arbórea e em estágio sucessional tardio. Considerando que esses autores utilizaram o método direto de quantificação e, por consequência, mais preciso, afirma-se que a biomassa no presente estudo foi superestimada nessa região.

Os maiores estoques de biomassa indicados no sul da Bahia sugerem que essas são áreas potenciais na Caatinga em armazenar carbono. Tendo em vista que os teores de carbono na biomassa, em geral, estão em torno de 50% (IPCC, 2006; AZEVEDO et al., 2018), o gradiente de estoque de carbono florestal na área tende a ser semelhante ao apresentado na Figura 8.

Para a região da Chapada Diamantina, onde estão os municípios de Morro do Chapéu e Lençóis, foram encontrados baixos valores de biomassa. A Chapada Diamantina é caracterizada por um conjunto de serras que atingem mais de 1000 metros de altura, altos índices de precipitação e temperaturas mais amenas (Figura 4), condições favoráveis à produtividade das florestas (SOUZA et al., 2019). Desse modo, essa área tende a comportar árvores com maiores dimensões, sustentar florestas mais densas e, conseqüentemente, armazenar altos estoques de biomassa vegetal, comprovado pelo mapeamento da biomassa em toda a Caatinga, realizado por Castanho et al. (2020), que se utilizaram de imagens de satélite. Os autores estimaram valores superiores a 60 t.ha<sup>-1</sup> nessa região e a classificaram como uma das áreas com maior biomassa vegetal em toda a Caatinga.

No entanto, essa região não sustenta uma homogeneidade de vegetação densa. A Chapada Diamantina é um conjunto de comunidades que formam um mosaico rico em fisionomias, em função da topografia, natureza e profundidade do solo (CONCEIÇÃO e GIULIETTI, 2002). As elevadas altitudes e relevo movimentado, decorrem em alto índice de erosão e ocupação das áreas por afloramentos rochosos, o que é limitante ao desenvolvimento da vegetação, ocorrendo nesses solos, formações com fisionomias diferentes do contexto geral dominante dessa região (BENITES et al., 2003).

Logo, é provável que os baixos valores de biomassa nessa área no mapa (Figura 8) foram decorrentes de fragmentos amostrados sob essas condições. Uma maior intensidade amostral sobre as áreas de florestas mais densas permitiria que a



RK estimasse mais adequadamente o comportamento espacial do estoque de biomassa na Chapada Diamantina, respeitando as suas distintas fisionomias. Assim, as conclusões acerca da distribuição espacial do estoque de biomassa na área de estudo são moderadas, reconhecendo que o banco de dados é limitado no número e distribuição de fragmentos.

Devido à riqueza de fisionomias da Caatinga na Bahia, era esperado menor precisão do mapeamento, pois caracterizar a biomassa em ambientes heterogêneos, como são as florestas tropicais, é um desafio (SILVEIRA et al., 2019b). Mas considerando o banco de dados e a riqueza de detalhamento alcançada no mapa final de RK, o resultado foi satisfatório.

No estado da Bahia, não se tem disponível um banco de dados consolidado que contemple todo o seu território, o que valida o compilado de dados utilizado neste estudo. Embora não seja tão consistente, os dados fornecem o potencial de biomassa em cada fragmento. Uma base de inventários capaz de captar todo o espectro de variação da vegetação na Bahia e que amostrasse a sua pluralidade de biomas, estágios sucessionais, graus de antropização e fitofisionomias, faz-se necessária. A existência de uma base consistente viabilizaria o desenvolvimento de técnicas e estudos, capazes de subsidiar a conservação e exploração sustentável dos recursos florestais do estado com maior precisão.

No presente estudo, essas informações providenciariam maior detalhamento no mapa final e promoveriam substancial melhora no mapeamento. Scolforo et al. (2015) e Silveira et al. (2019a), ao mapearem a distribuição espacial do estoque de carbono e de volume, respectivamente, por RK para o estado de Minas Gerais, alcançaram resultados satisfatórios e próximos do que foi observado em campo. Todavia, ambos os autores se utilizaram de uma base de dados robusta, com maior intensidade amostral e fragmentos florestais bem distribuídos na área de estudo.

Devido à heterogeneidade da vegetação da Caatinga na Bahia, sugere-se considerar em trabalhos futuros, as diferentes fitofisionomias, ecorregiões ou zonas climáticas do bioma como variáveis independentes na modelagem da biomassa. Essa distinção tem sido utilizada para reduzir a variação espacial comum em dados de vegetação em grandes áreas (BARNI et al., 2016; SCOLFORO et al., 2016; SILVEIRA et al., 2019b). Ao modelar a biomassa para o estado de Roraima, Barni et al. (2016) consideraram as distintas fitofisionomias que ocorrem no estado, classificando-as em quatro grupos florestais que foram utilizados como variáveis de entrada no modelo de

regressão. Com isso, os autores conseguiram melhorar o desempenho na interpolação, pois o modelo foi capaz de captar melhor as variações da vegetação, e, assim, gerar melhor representação dos estoques de biomassa no estado.

De modo semelhante, Scolforo et al. (2016) consideraram os diferentes biomas que ocorrem ao longo do estado de Minas Gerais e os incluiu como variável categórica no modelo de regressão utilizado para espacializar o estoque de carbono no estado. Os autores obtiveram um modelo consistente, mais flexível e que estimou adequadamente o comportamento espacial do carbono, com redução de possíveis tendências em áreas específicas.

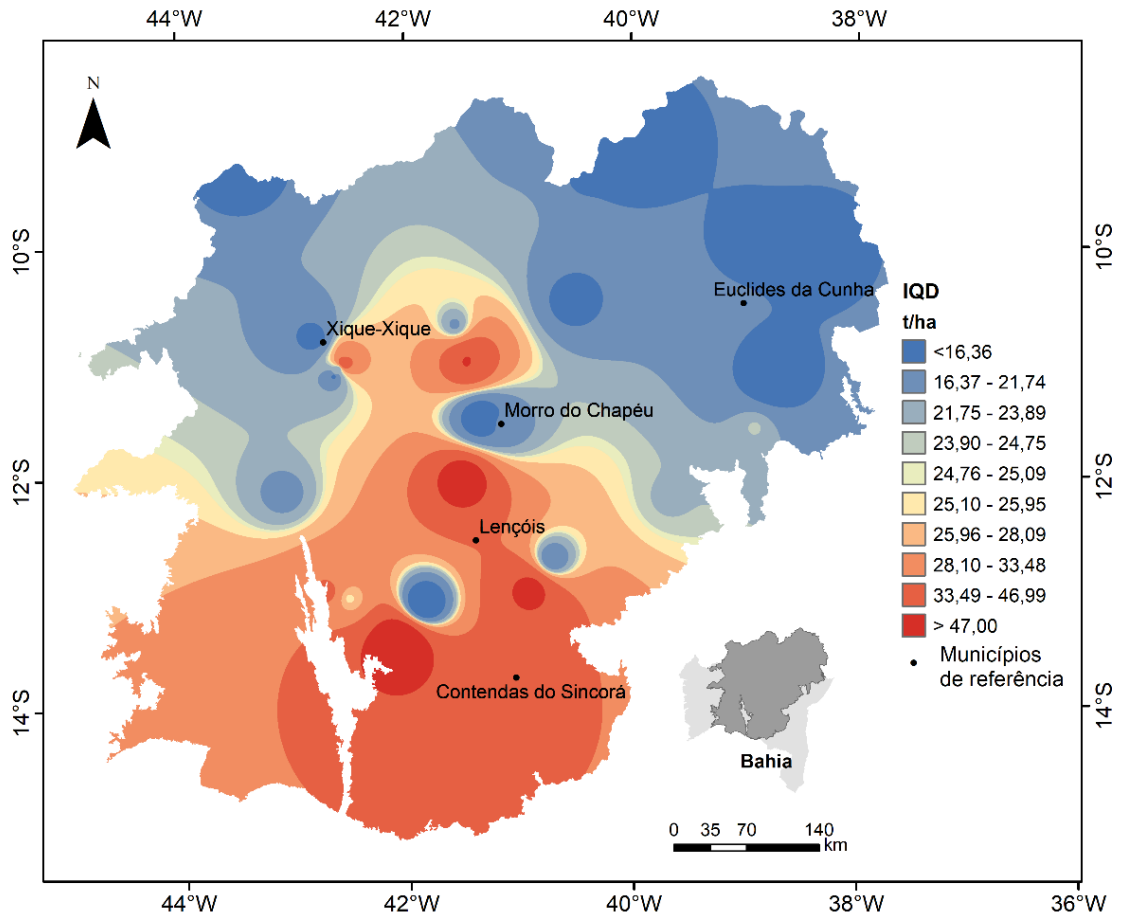
### **4.3. Interpolação pelo Inverso do Quadrado da Distância (IQD)**

O mapa do estoque de biomassa interpolado a partir da técnica de IQD é representado na Figura 9. É característica dessa técnica preservar a amplitude dos dados originais, logo, os valores mínimos e máximos encontrados no mapa são aqueles apontados na estatística descritiva dos dados.

Assim como o mapeamento gerado da RK, observa-se um gradiente de biomassa que aumenta na direção norte-sul. No entanto, por ser uma técnica dependente dos pontos da vizinhança mais próxima, o mapa não detalhou a biomassa para as regiões subamostradas e promoveu a formação de ilhas ao redor dos fragmentos amostrais.

A superfície interpolada apresentou valores do erro médio (EM) de -0,38, o que sugere uma superestimação da previsão do estoque de biomassa pelo IQD. O EM mede a tendência do modelo em sub ou superestimar uma variável de interesse e deve ser próximo de zero para predições imparciais (PALMER et al., 2009; REIS et al., 2020). A raiz quadrada do erro médio (RMSE) foi de 19,83 t.ha<sup>-1</sup>.

Embora esse tipo de interpolação seja útil na ausência de estrutura espacial da variável de interesse, ou mesmo na presença de fraca estrutura de dependência, o uso do IQD foi pertinente, pois evidenciou que a incoerência no mapeamento por RK foi influenciada pela subamostragem na área de estudo.



**Figura 9** – Mapa do estoque de biomassa do bioma Caatinga na Bahia, interpolado pela técnica do Inverso do Quadrado da Distância (IQD).

Na porção centro-sul do mapa, em que os estoques de biomassa são superiores a  $25 \text{ t.ha}^{-1}$ , observa-se pequenas áreas isoladas com menores estoques, efeito da baixa biomassa estimada nos fragmentos amostrados ali. Isso evidencia que esses fragmentos não captam a real variação de estoque de biomassa que ocorre na área de estudo e reforça que a subestimativa da Chapada Diamantina representada no mapa de RK, ocorre por efeito desses fragmentos.

Apesar disso, na comparação visual dos mapas, é notável que a RK consegue capturar detalhes mais específicos quanto à distribuição de biomassa na área estudada do que o IQD, o que a torna mais eficiente no mapeamento.

## 5. CONCLUSÕES

A qualidade do modelo de regressão sugere que existe um potencial em estimar a biomassa a partir de variáveis ambientais. Estudos adicionais com maior população amostral e uso de outras variáveis podem aprimorar o modelo.

Quando comparada ao IQD, a krigagem com regressão mostrou ser capaz de revelar a variabilidade espacial da biomassa com maior detalhamento. A adoção de maior intensidade amostral tem potencial para maximizar esse detalhamento dado pela técnica.

Uma base de inventários florestais robusta se faz necessária para a Bahia, visando viabilizar estudos que permitam conhecer os potenciais dos recursos florestais do estado com maior precisão.

## 6. REFERÊNCIAS

- ALMEIDA, L.S.; GUIMARÃES, E.C. Geoestatística para determinação e modelagem da variabilidade espacial de micronutrientes no solo cultivado com café no município de Araguari-MG. **Cultura Agronômica**, v. 26, n. 2, p. 158-173, 2017.
- ALTHOFF, T.F.; MENEZES, R.S.C.; PINTO, A.S.; PAREYN, F.G.C.; CARVALHO, A.L.; MARTINS, J.C.R.; CARVALHO, E.X.; SILVA, A.S.A.; DUTRA, E.D.; SAMPAIO, E.V.S.B. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. **Agriculture, Ecosystems and Environment**, v. 254, p. 26-34, 2018.
- ALVARENGA, L.H.V.; MELLO, J.M.; GUEDES, I.C.L.; SCOLFORO, J.R.S. Desempenho da estratificação em um fragmento de cerrado *stricto sensu* utilizando interpolador geoestatístico. **Cerne**, v. 18, n. 4, p. 675-681, 2012.
- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ALVES, A.R.; FERREIRA, R.L.C. SILVA, J.A.A.; DUBEUX JÚNIOR, J.C.B.; SALAMI, G. Nutrientes na biomassa aérea e na serapilheira em áreas de caatinga em Floresta, PE. **Pesquisa florestal brasileira**, v. 37, n. 92, p. 413-420, 2017.
- ALVES, J.J.A.; ARAÚJO, M.A.; NASCIMENTO, S.S. Degradação da Caatinga: uma investigação ecogeográfica. **Revista Caatinga**, v. 22, n. 3, p. 126–135, 2009.
- AMARAL, L.P.; FERREIRA, R.A.; WATZLAWICK, L.F.; GENÚ, A.M. Análise da distribuição espacial de biomassa e carbono arbóreo acima do solo em Floresta Ombrófila Mista. **Ambiência**, v. 6, Ed. Especial, p. 103-144, 2010.
- AMARAL, L.P.; FERREIRA, R.A.; WATZLAWICK, L.F.; LONGHI, S.J.; SEBEM, E. Influência da floresta alterada na distribuição espacial de três espécies da Floresta Ombrófila Mista avaliada pela Geoestatística. **Revista Árvore**, v. 37, n. 3, p. 491-501, 2013.
- AMARO, M.A.; SOARES, C.P.B.; SOUZA, A.L.; LEITE, H.G.; SILVA, G.F. Estoque volumétrico, de biomassa e de carbono em uma floresta estacional semidecidual em Viçosa, Minas Gerais. **Revista Árvore**, v. 37, n. 5, p. 849-857, 2013.
- AZEVEDO, A.D.; FRANCELINO, M.R.; CAMARA, R.; PEREIRA, M.G.; LELES, P.S.S. Estoque de carbono em áreas de restauração florestal da Mata Atlântica. **Floresta**, v. 48, n. 2, p. 183-194, 2018.
- BARNI, P.E.; MANZI, A.O.; CONDÉ, T.M.; BARBOSA, R.I.; FEARNSSIDE, P.M. Spatial distribution of forest biomass in Brazil's state of Roraima, northern Amazonia. **Forest Ecology and Management**, v. 377, p. 170-181, 2016.
- BARRETO, T.N.A.; SILVA, J.A.A.; FERREIRA, R.L.C.; ALMEIDA, C.C.S. Ajuste de modelos matemáticos à biomassa seca dos compartimentos de plantas lenhosas em área de caatinga. **Scientia Forestalis**, v. 46, n. 118, p. 285-295, 2018.

BATISTA, P.V.G.; SILVA, M.L.N.; AVALOS, F.A.P.; OLIVEIRA, M.S.; MENEZES, M.D.; CURI, N. Hybrid kriging methods for interpolating sparse river bathymetry point data. **Ciência e Agrotecnologia**, v. 41, n. 4, p. 402-412, 2017.

BECKNELL, J.M.; KUCEK, L.K.; POWERS, J.S. Aboveground biomass in mature and secondary seasonally dry tropical forests: a literature review and global synthesis. **Forest Ecology and Management**, v. 276, p. 88-95, 2012.

BENITES, V.M.; CAIAFA, A.N.; MENDONÇA, E.S.; SCHAEFER, C.E.; KER, J.C. Solos e vegetação nos complexos rupestres de altitude da Mantiqueira e do Espinhaço. **Floresta e Ambiente**, v. 10, n. 1, p. 76-85, 2003.

BERNARDI, A.C.C.; BETTIOL, G.M.; MAZZUCO, G.G.; ESTEVES, S.N.; OLIVEIRA, P.P.A.; PEZZOPANE, J.R.M. Spatial variability of soil fertility in na integrated crop livestock forest system. **Advances in Animal Biosciences**, v. 8, n. 2, p. 590-593, 2017.

BERNARDI, A.C.C.; BUENO, J.O.A.; LAURENTI, N.; SANTOS, K.E.L.; ALVES, T.C. Efeito da calagem e fertilizantes aplicados à taxa variável nos atributos químicos do solo e custos de produção de pastagem de capim Tanzânia manejadas intensivamente. **Brazilian Journal of Biosystems Engineering**, v. 12, n. 4, p. 368-382, 2018.

BEUCHLE, R.; GRECCHI, R.C.; SHIMABUKURO, Y.E.; SELIGER, R.; EVA, H.D.; SANO, E.; ACHARD, F. Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2020 based on a systematic remote sensing sampling approach. **Applied Geography**, v. 58, p. 116-127, 2015.

BIVAND, R.; KEITT, T.; ROWLINGSON, B. **rgdal**: Bindings for the 'Geospatial' Data Abstraction Library. R package version 1.5-25, 2021.

BRAND, M.A. Potencial de uso da biomassa florestal da Caatinga, sob manejo sustentável, para geração de energia. **Ciência Florestal**, v. 27, n. 1, p. 117-127, 2017.

BRAND, M.A.; OLIVEIRA, L.C.; LACERDA, S.R.; TONIOLO, E.R.; LEAL JÚNIOR, G.; CAMPELHO, R.B. Caracterização da vegetação da caatinga do sul do Piauí para geração de energia. **Floresta**, v. 45, n. 3, p. 477-486, 2015.

BRASIL. Ministério do Meio Ambiente. **Biomass**: Caatinga. Brasília: 2014. Disponível em: <<https://www.mma.gov.br/biomass/caatinga>>. Acesso em: 20 mar. 2020.

BURROUGH, P.A. Spatial aspects of ecological data. In: JONGMAN, R.H.; BRAAK, C.J.F.; TONGEREN, O.F.R. eds. **Data analysis in community and landscape ecology**. Pudoc Wageningen, 1987, p. 213-251.

CABRAL, G.A.L.; SAMPAIO, E.V.S.B.; ALMEIDA-CORTEZ, J.S. Estrutura espacial e biomassa da parte aérea em diferentes estádios sucessionais de Caatinga, em Santa Terezinha, Paraíba. **Revista Brasileira de Geografia Física**, v. 6, n. 3, p. 566-574, 2013.

CALDEIRA, M.V.W.; WATZLAWICK, L.F.; VIERA, M.; BALBINOT, R.; CASTRO, K. C. Biomassa e carbono orgânico em povoamentos de *Araucaria angustifolia* (Bertol.) Kuntze. **Ciência Florestal**, v. 25, n. 4, p. 1027-1034, 2015.

CÂMARA, G.; MONTEIRO, A.M.; FUCKS, S.D.; CARVALHO, M.S. Análise espacial e geoprocessamento. In: Druck, S.; CARVALHO, M.S.; CÂMARA, G.; MONTEIRO, A.M.V. (Eds). **Análise espacial de dados geográficos**. Brasília: EMBRAPA, 2004, p. 21-54.

CAMARGO, E.C.G. Geoestatística: fundamentos e aplicações. In: CÂMARA, G.; MEDEIROS, J.S. Orgs. **Geoprocessamento para projetos ambientais**. 2. ed. São José dos Campos: INPE, 1998.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F.; KONOPKA, A.E. Field-scale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, v. 58, n. 5, p. 1501-1511, 1994.

CASTANHO, A.D.A.; COE, M.; ANDRADE, E.M.; WALKER, W.; BACCINI, A.; CAMPOS, D.A.; FARINA, M. A close look at above ground biomass of a large and heterogeneous Seasonally Dry Tropical Forest – Caatinga in North East of Brazil. **Anais da Academia Brasileira de Ciências**, v. 92, n. 1, p. 1-18, 2020.

CONCEIÇÃO, A.A.; GIULIETTI, A.M. Composição florística e aspectos estruturais de campo rupestre em dois platôs do Morro do Pai Inácio, Chapada Diamantina, Bahia, Brasil. **Hoehnea**, v. 29, n. 1, p. 37-48, 2002.

CORREIA, M.D.; MENEZES, R.S.C.; OLINDA, R.A. Modelagem geoestatística da distribuição de carbono do solo e biomassa de herbáceas em sistema silvopastoril na região Nordeste do Brasil. **Revista Brasileira de Biomassa**, v. 31, n. 2, p. 116-129, 2014.

COSTA, T.L.; SAMPAIO, E.V.S.B.; SALES, M.F.; ACCIOLY, L.J.O.; ALTHOFF, T.D.; PAREYN, F.G.C.; ALBUQUERQUE, E.R.G.M.; MENEZES, R.S.C. Root and shoot biomasses in the tropical dry forest of semi-arid Northeast Brazil. **Plant Soil**, v. 378, p. 113-123, 2014.

DALL'AGNOL, R.W.; BETZEK, N.M.; BAZZI, C.L. Aplicação do software R para análise geoestatística, interpolação de dados por krigagem ordinária e geração de mapas temáticos de produtividade agrícola. **Revista de Computação Aplicada ao Agronegócio**, v. 1, n. 1, p. 24-37, 2018.

DALLAGNOL, F.S.; FRANCELO, M.; SANQUETTA, C.R.; CORTE, A.P.D. Teores de carbono de cinco espécies florestais e seus compartimentos. **Floresta e Ambiente**, v. 18, n. 4, p. 410-416, 2011.

DEBASTIANI, A.B.; VASCONCELLOS, B.N.; MARTINS, A.P.M.; CORTE, A.P.D.; SANQUETTA, C.R. Predições geoestatísticas e zonas de incerteza no inventário de povoamentos florestais. **Advances in Forestry Science**, v. 5, n. 1, p. 283-287, 2018.

ESRI – ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. 2019. **Arcgis Desktop**: Version 10.8. Redlands, CA: Esri. 2019

FERNANDES, M.F.; CARDOSO, D.; QUEIROZ, L.P. Na updated plant checklist of the Brazilian Caatinga seasonally dry forests and woodlands reveals high species richness and endemismo. **Journal of Arid Environments**, v. 174, n. 104079, p. 1-8, 2020.

FERRAZ, A.S.; SOARES, V.P.; SOARES, C.P.B.; RIBEIRO, C.A.A.S.; BINOTI, D.H.B.; LEITE, H.G. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**, v. 21, n. 3, p. 286-296, 2014.

FERREIRA, F.A.C.; LEITE, E.S.; FREITAS, L.C.; VIRGENS, A.P. Potencial de krigagem em modelos digitais de elevação para o planejamento da colheita florestal. **Pesquisa Florestal Brasileira**, v. 37, n. 92, p. 579-586, 2017.

FERREIRA, J.C.; STÄHELIN, T.S.F.; JESUS, M.S.; MUÑIZ, G.I.B.; BRAND, M.A.; FREITAS, T.P. Estimativa da oferta de biomassa florestal em povoamentos de *Pinus taeda* L. após intervenções culturais. **Ciência Florestal**, v. 29, n. 3, p. 1459-1468, 2019.

FICK, S.E.; HIJMANS, R.J. WorldClim 2: new 1km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, v.37, n.12, p.4302-4315, 2017.

GANEM, R.S. **Caatinga: estratégias de conservação**. Estudo Técnico, Consultoria legislativa, 2017, 105p.

GARCIA, A.C.S.M.; ARAÚJO FILHO, J.C.; SILVA, H.P.S.P.; CARVALHO, R.M.C.M.O. Estudo espaço temporal de áreas susceptíveis à desertificação do Semiárido brasileiro. **Revista Gestão & Sustentabilidade Ambiental**, v. 8, n. 3, p. 352-370, 2019.

GARIGLIO, M.A.; SAMPAIO, E.V.S.B.; CESTARO, L.A.; KAGEYAMA, P.Y. **Uso sustentável e conservação dos recursos florestais da Caatinga**. 1. ed. Brasília: Serviço Florestal Brasileiro, 2010.

GIULIETTI, A.M.; BOCAGE NETA, A.L.; CASTRO, A.A.J.F.; GAMARRA-ROJAS, C.F.L.; SAMPAIO, E.V.S.B.; VIRGÍNIO, J.F.; QUEIROZ, L.P.; FIGUEIREDO, M.A.; RODAL, M.J.N.; BARBOSA, M.R.V.; HARLEY, R.M. Diagnóstico da vegetação nativa do bioma Caatinga. In: SILVA, J.M.C.; TABARELLI, M.; FONSECA, M.T.; LINS, L.V. (Orgs.). **Biodiversidade da Caatinga: áreas e ações prioritárias para a conservação**. Brasília: Ministério do Meio Ambiente, 2003, p. 47-131.

GOMES, L.C.; FARIA, R.M.; SOUZA, E.; VELOSO, G.V.; SCHAEFER, C.E.G.R.; FERNANDES FILHO, E.I. Modelling and mapping soil organic carbon stocks in Brazil. **Geoderma**, v. 340, p. 337-350, 2019.

GRYNYSHYNA-POLIUGA, O. Characteristic of modelling spatial processes using geostatistical analysis. **Advances in space research**, v. 64, n. 2, p. 415-426, 2019.

GUEDES, I.C.L.; MELLO, J.M.; SILVEIRA, E.M.O.; MELLO, C.R.; REIS, A.A.; GOMIDE, L.R. Continuidade espacial de características dendrométricas em povoamentos clonais de *Eucalyptus* sp. avaliada ao longo do tempo. **Cerne**, v. 21, n.4, p. 527-534, 2015.

GUEDES, L.P.C.; URIBE-OPAZO, M.A.; RIBEIRO JUNIOR, P.J. Influence of incorporating geometric anisotropy on the construction of thematic maps of simulated data and chemical attributes of soil. **Chilean Journal of Agricultural Research**, v. 73, n. 4, p. 414-423, 2013.



GUEDES, R.S.; ZANELLA, F.C.V.; COSTA JÚNIOR, J.E.V.; SANTANA, G.M.; SILVA, J.A. Caracterização florístico-fitosociológica do componente lenhoso de um trecho de caatinga no semiárido paraibano. **Revista Caatinga**, v. 25, n. 2, p. 99-108, 2012.

GUERRA, P.A.G. **Geoestatística Operacional**. Brasília: Departamento Nacional da Produção Mineral, 1988. 145p.

GUIMARÃES, E.C. **Geoestatística básica e aplicada**. Uberlândia-MG: Universidade Federal de Uberlândia, 2004. 76p.

HENTZ, A.M.K.; RUZA, M.S.; CORTE, A.P.D.; SANQUETTA, C.R. Técnicas de sensoriamento remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia Biosfera**, v. 10, n. 18, p. 2810-2823, 2014.

HIJMANS, R.J. **raster**: Geographic Data Analysis and Modeling. R package version 3.4-13, 2021.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro: IBGE, Coordenação de Recursos Naturais e Estudos ambientais, 2012, 271p.

\_\_\_\_\_. **Mapa Semiárido brasileiro 1:27.000.000**. IBGE. 2018. Disponível em: <[ftp://geoftp.ibge.gov.br/organizacao\\_do\\_territorio/estrutura\\_territorial/semiario\\_brasileiro/Situacao\\_23nov2017/mapa\\_Brasil\\_Semiario\\_2017\\_11\\_23.pdf](ftp://geoftp.ibge.gov.br/organizacao_do_territorio/estrutura_territorial/semiario_brasileiro/Situacao_23nov2017/mapa_Brasil_Semiario_2017_11_23.pdf)>. Acesso em: 31 mar. 2020.

\_\_\_\_\_. **Biomass e sistema costeiro-marinho do Brasil**: compatível com a escala 1:250.000. Rio de Janeiro: IBGE, Coordenação de Recursos Naturais e Estudos ambientais, 2019, 168 p.

\_\_\_\_\_. **Mapeamento de recursos naturais do Brasil Escala 1:250.000**. Pedologia Versão 2021. Rio de Janeiro: IBGE, Coordenação de Recursos Naturais e Estudos ambientais, 2021. Disponível em: <<https://www.ibge.gov.br/geociencias/downloads-geociencias.html>>. Acesso em: 15 ago. 2021.

IPCC – Intergovernmental Panel on Climate Change. Guidelines for national greenhouse gas inventories: agriculture, forestry and other land use. [S.l.]: Institute for Global Environmental Strategies, 2006. v. 2. p. 2-59. Disponível em: <<https://www.ipcc-nggip.iges.or.jp/public/2006gl/vol2.html>>. Acesso em: 15 set. 2020.

JOURNAL, A.G.; HUIJBREGTS, C.J. **Mining Geostatistics**. London: Academic Press. 1978. 600 p.

KIILL, L.H.P.; RIBEIRO, M.F.; DIAS, C.T.V.; SILVA, P.P.; SILVA, J.F.M. **Caatinga: flora e fauna ameaçadas de extinção**. São Paulo: EMBRAPA Semiárido, 2009. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/161895>>. Acesso em: 31 mar. 2020.

KOZMHINSKY, M.; MEDEIROS, R.M.; HOLANDA, R.M.; SILVA, V.P. Average insolation interpolated by the krigagem method for the state of Pernambuco – Brazil. **Journal of Hyperspectral Remote Sensing**, v. 8, n. 2, p. 78-84, 2018.

LANDIM, P.M.B. Sobre geoestatística e mapas. **Terrae Didactica**, v. 2, n. 1, p. 19-33, 2006.

LEAL, I.R.; SILVA, J.M.C.; TABARELLI, M.; LACHER JÚNIOR, T.E. Mudando o curso da conservação da biodiversidade na Caatinga do Nordeste do Brasil. **Megadiversidade**, v. 1, n. 1, p. 139-146, 2005.

LEITE, J.A.N.; ARAÚJO, L.V.C.; ARRIEL, E.F.; CHAVES, L.F.C.; NÓBREGA, A.M.F. Análise quantitativa da vegetação lenhosa da Caatinga em Teixeira, PB. **Pesquisa Florestal Brasileira**, v. 35, n. 82, p. 89-100, 2015.

LIMA, E.S.; MONTANARI, R.; LOVERA, L.H.; TEIXEIRA FILHO, M.C.M.; GONZÁLEZ, A.P. Variabilidade espacial das propriedades dendrométricas do eucalipto e atributos químicos de um Neossolo Quartzarênico. **Revista de Agricultura Neotropical**, v. 4, n. 1, p. 1-11, 2017.

LIMA JÚNIOR, C.; ACCIOLY, L.J.O.; GIONGO, V.; LIMA, R.L.F.A.; SAMPAIO, E.V.S.B.; MENEZES, R.S.C. Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índices de vegetação. **Scientia Forestalis**, v. 42, n. 102, p. 289-298, 2014.

LOPEZ-GONZALEZ, G.; LEWIS, S.L.; BURKITT, M.; BAKER T.R.; PHILLIPS, O.L. **ForestPlots.net Database**. 2009. Disponível em: <[www.forestplots.net](http://www.forestplots.net)>. Acesso em: 17 Ago. 2021.

LOPEZ-GONZALEZ, G.; LEWIS, S.L.; BURKITT, M.; PHILLIPS, O.L. ForestPlots.net: a web application and research tool to manage and analyse tropical forest plot data. **Journal of Vegetation Science**, v. 22, n. 4, p. 610-613, 2011.

LUNDGREN, W.J.C.; SILVA, J.A.A.; FERREIRA, R.L.C. A precisão da estimativa do erro da krigagem pela validação cruzada. **Floresta e Ambiente**, v. 24, e00124114, 2017a.

LUNDGREN, W.J.C.; SILVA, J.A.A.; FERREIRA, R.L.C. Estimativa do volume de eucaliptos por krigagem e cokrigagem no semiárido pernambucano. **Floresta e Ambiente**, v. 24, e00140415, 2017b.

MACEDO, F.L.; SOUSA, A.M.O.; GONÇALVES, A.C.; SILVA, H.R.; RODRIGUES, R.A.F. Função alométrica de biomassa com imagens de satélite de alta resolução espacial. **Ciência Florestal**, v. 28, n. 3, p. 960-969, 2018.

MARQUES, F.A.; NASCIMENTO, A.F.; ARAÚJO FILHO, J.C.; SILVA, A.B. **Solos do Nordeste**. Recife: Embrapa Solos, 2014. 8 p.

MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, p. 1246-1266, 1963.

MATHERON, G. **Les variables régionalisées et leur estimation**. Masson, Paris, 1965, 306 p.

MELLO, C.R.; VIOLA, M.R.; BESKOW, S.; NORTON, L.D. Multivariate models for annual rainfall erosivity in Brazil. **Geoderma**, v. 202-203, p. 88-102, 2013.

MELLO, J.M.; BATISTA, J.L.F.; RIBEIRO JÚNIOR, P.J.; OLIVEIRA, M.S. Ajuste e seleção de modelos espaciais de semivariograma visando à estimativa volumétrica de *Eucalyptus grandis*. **Scientia Forestalis**, n. 69, p. 25-37, 2005.

MELLO, Y.R.; OLIVEIRA, T.M.N. Análise estatística e geoestatística da precipitação média para o município de Joinville (SC). **Revista Brasileira de Meteorologia**, v. 31, n. 2, p. 229-239, 2016.

MENEZES, J.A.L.; SANTOS, T.E.M.; MONTENEGRO, A.A.A.; SILVA, J.R.L. Comportamento temporal da umidade do solo sob Caatinga e solo descoberto na Bacia Experimental do Jatobá, Pernambuco. **Water Resources and Irrigation Management**, v. 2, n. 1, p. 45-51, 2013.

MMA – MINISTÉRIO DO MEIO AMBIENTE. **Atlas das áreas susceptíveis à desertificação do Brasil**. Brasília: MMA, Secretaria de Recursos Hídricos, Universidade Federal da Paraíba, 2007.

\_\_\_\_\_. **Caatinga – Monitoramento do desmatamento dos biomas brasileiros por satélite**. Relatório Técnico 2010-2011. 32p. 2016.

\_\_\_\_\_. **Unidades de Conservação por Bioma**. Brasília: MMA, 2021. Disponível em: <<https://antigo.mma.gov.br/areas-protegidas/cadastro-nacional-de-ucs.html>>. Acesso em: 29 nov. 2021.

MORAIS, V.A.; MELLO, J.M.; MELLO, C.R.; SILVA, C.A.; SCOLFORO, J.R.S. Spatial distribution of the litter carbono stock in the Cerrado biome in Minas Gerais state, Brazil. **Ciência e Agrotecnologia**, v. 41, n. 5, p. 580-589, 2017.

NOGUEIRA, M.F.M.; RENDEIRO, G. Caracterização energética da biomassa vegetal. In: RENDEIRO, G.; NOGUEIRA, M. **Combustão e gasificação de biomassa sólida: soluções energéticas para a Amazônia** (1.ed.). Brasília: Ministério de Minas e Energia, 2008, p. 52-63.

ODA-SOUZA, M.; BARBIN, D.; RIBEIRO JÚNIOR, P.J.; STAPE, J.L. Aplicação de métodos geoestatísticos para identificação de dependência espacial na análise de dados de um ensaio de espaçamento florestal em delineamento sistemático tipo leque. **Revista Árvore**, v. 32, n. 3, p. 499-509, 2008.

ODEH, I.O.A.; MCBRATNEY, A.B.; CHITTLEBOROUGH, D.J. Further results on a prediction of soil properties from terrain attributes: heterotopic cokriging and regression-kriging. **Geoderma**, v. 67, p. 215-226, 1995.

OLIVEIRA, P.T.B.; TROVÃO, D.M.B.M.; CARVALHO, E.C.D.; SOUZA, B.C.; FERREIRA, L.M.R. Florística e fitossociologia de quatro remanescentes vegetacionais em áreas de serra no Cariri Paraibano. **Revista Caatinga**, v. 22, n. 4, p. 169-178, 2009.

OLIVEIRA, E.V.S. **Dinâmica temporal e aspectos da vegetação em uma comunidade de Caatinga**. São Cristóvão-SE: UFS, 2016, 98p. Dissertação (Mestrado em Ecologia e Conservação) – Universidade Federal de Sergipe.

OLIVEIRA, R.P.; GREGO, C.R.; BRANDÃO, Z.N. Geoestatística aplicada na Agricultura de Precisão utilizando o Vesper. 23. ed. Brasília, DF: Embrapa, 2015.

PALMER, D.J.; HÖCK, B.K.; KIMBERLEY, M.O.; WATT, M.S.; LOWE, D.J.; PAYN, T.W. Comparison of spatial prediction techniques for developing *Pinus radiata* productivity surfaces across New Zealand. **Forest Ecology and Management**, v. 258, p. 2046-2055, 2009.

PARENTE, H.N.; ANDRADE, A.P.; SILVA, D.S.; SANTOS, E.M.; ARAÚJO, K.D.; PARENTE, M.O.M. Influência do pastejo e da precipitação sobre a fenologia de quatro espécies em área de caatinga. **Revista Árvore**, v. 36, n. 3, p. 411-421, 2012.

PEREIRA FILHO, J.M.; BAKKE, O.A. Produção de forragem de espécies herbáceas da Caatinga. In: GARIGIGLIO, M.A.; SAMPAIO, E.V.S.B.; CESTARO, L.A.; KAGEYAMA, P.Y. (Orgs.). **Uso Sustentável e conservação dos recursos florestais da Caatinga**. Brasília: Serviço Florestal Brasileiro, 2010, p. 145-159.

PEREIRA JÚNIOR, L.R.; ANDRADE, E.M.; PALÁCIO, H.A.Q.; RAYMER, P.C.L.; RIBEIRO FILHO, J.C.; PEREIRA, F.J.S. Carbon stocks in a tropical dry forest in Brazil. **Revista Ciência Agrônômica**, v. 45, n. 1, p. 32-40, 2016.

POORTER, L.; BONGERS, F.; AIDE, T.M.; ZAMBRANO, A.M.A.; BALVANERA, P.; BECKNELL, J.M.; BOUKILI, V.; BRANCALION, P.H.S.; BROADBENT, E.N.; CHAZDON, R.L.; CRAVEN, D.; ALMEIDA-CORTEZ, J.S.; CABRAL, G.A.L.; JONG, B.H.J.; DENSLOW, J.S.; DENT, D.H.; DEWALT, S.J.; DUPUY, J.M.; DURAN, S.M.; ESPÍRITO-SANTO, M.M.; FRANDINO, M.C.; CÉSAR, R.G.; HALL, J.S.; HERNANDEZ-STEFANONI, J.L.; JAKOVAC, C.C.; JUNQUEIRA, A.B.; KENNARD, D.; LETCHER, S.G.; LICONA, J.; LOHBECK, M.; MARIN-SPIOTTA, E.; MARTINEZ-RAMOS, M.; MASSOCA, P.; MEAVE, J.A.; MESQUITA, R.; MORA, F.; MUÑOZ, R.; MUSCARELLA, R. NUNES, Y.R.F.; OCHOA-GANOVA, S.; OLIVEIRA, A.A.; ORIHUELA-BELMONTE, E.; PEÑA-CARLOS, M.; PÉREZ-GARCIA, E.A.; PIOTTO, D.; POWERS, J.S.; RODRIGUEZ-VELÁZQUEZ, J.; ROMERO-PÉREZ, E.; RUIZ, J.; SALDARRIAGA, J.G.; SANCHEZ-AZOFEIFA, A.; SCHWARTZ, N.B.; STEININGER, M.K.; SWENSON, N.G.; TOLEDO, M.; URIARTE, M.; BREUGEL, M.; WAL, H.; VELOSO, M.D.M.; VESTER, H.F.M.; VICENTINI, A.; VIEIRA, I.C.G.; BENTOS, T.V.; WILLIAMSON, G.B.; ROZENDAAL, D.M.A. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, p. 211-214, 2016.

PRADO, D.E. As caatingas da América do Sul. In: LEAL, I.R.; TABARELLI, M.; SILVA, J.M.C. (Eds.). **Ecologia e conservação da Caatinga**. Recife: Ed. Universitária da UFPE, 2003, p. 3-74.

PROTÁSIO, T.P.; BUFALINO, L.; TONOLO, G.H.D.; COUTO, A.M.; TRUGILHO, P.F.; GUIMARÃES JÚNIOR, M. Relação entre o poder calorífico superior e os componentes elementares e minerais da biomassa vegetal. **Pesquisa Florestal Brasileira**, v. 31, n. 66, p. 113-122, 2011.

R CORE TEAM. **R**: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. 2021. Disponível em: <<https://www.R-project.org/>>.

RAJASHEKAR, G.; FARARODA, R.; REDDY, R.S.; JHA, C.S.; GANESHIAH, K.N.; SINGH, J.S.; DADHWAL, V.K. Spatial distribution of forest biomass carbon (Above and below ground) in Indian forests. **Ecological indicators**, v. 85, p. 742-752, 2018.

RATUCHNE, L.C.; KOEHLER, H.S.; WATZLAWICK, L.F.; SANQUETTA, C.R.; SCHAMNE, P.A. Estado da arte na quantificação de biomassa em raízes de formações florestais. **Floresta e Ambiente**, v. 23, n. 3, p. 450-462, 2016.

REIS, A.A.; MELLO, J.M.; RAIMUNDO, M.R.; ACERBI JÚNIOR, F.W.; OLIVEIRA, M.S.; DINIZ, J.M.F.S. Estratificação de um povoamento de eucalipto por interpoladores geoestatísticos e sensoriamento remoto. **Pesquisa Agropecuária brasileira**, v. 51, n. 10, p. 1751-1761, 2016.

REIS, A.A.; DINIZ, J.M.F.S.; ARCEBI JÚNIOR, F.W.; MELLO, J.M.; BATISTA, A.P.B.; FERRAZ FILHO, A.C. Modeling the spatial distribution of wood volume a Cerrado *Stricto Sensu* remnant in Minas Gerais state, Brazil. **Scientia Forestalis**, v. 48, n., 125, p. 1-13, 2020.

RIBEIRO JÚNIOR, P.J. **Métodos geoestatísticos no estudo da variabilidade espacial de parâmetros do solo**. Piracicaba-SP: ESALQ, 1995, 99 p. Dissertação (Mestrado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”.

RIBEIRO JUNIOR, P.J.; DIGGLE, P.J.; SCHLATHER, M.; BIVAND, R.; RIPLEY, B. **geoR**: Analysis of Geostatistical Data. R package version 1.8-1, 2020.

RIEGELHAUPT, E.; PAREYN, F.G.C.; BACALINI, P. O manejo florestal na caatinga: resultados da experimentação. In: GARIGIGLIO, M.A.; SAMPAIO, E.V.S.B.; CESTARO, L.A.; KAGEYAMA, P.Y. (Orgs.). **Uso sustentável e conservação dos recursos florestais da caatinga**. Brasília: Serviço Florestal Brasileiro, 2010, p. 256-275.

RODAL, M.J.N.; SAMPAIO, E.V.S.B.; FIGUEIREDO, M.A. (Orgs.). **Manual sobre métodos de estudo florístico e fitossociológico**: Ecosistema Caatinga. (1.ed.). Brasília: Sociedade Botânica do Brasil, 2013.

ROVEDA, M.; PELISSARI, A.L.; GENÚ, A.M.; FIGUEIREDO FILHO, A.; ROIK, M. Modelagem geoestatística da estrutura espacial arbórea e dos atributos do solo em Floresta Ombrófila Mista. **FLORESTA**, v. 48, n. 1, p. 67-76, 2018.

SAMPAIO, E.V.S.B. Características e potencialidades. In: GARIGIGLIO, M.A.; SAMPAIO, E.V.S.B.; CESTARO, L.A.; KAGEYAMA, P.Y. (Orgs.). **Uso Sustentável e conservação dos recursos florestais da Caatinga**. Brasília: Serviço Florestal Brasileiro, 2010, p. 29-48.

SAMPAIO, E.V.S.B.; COSTA, T.L. Estoques e fluxos de carbono no semi-árido nordestino: estimativas preliminares. **Revista Brasileira de Geografia Física**, v. 6, p. 1275-1291, 2011.

SAMPAIO, E.V.S.B.; SILVA, G.C. Biomass equations for Brazilian semiarid caatinga plants. **Acta Botanica Brasilica**, v. 19, n. 4, p. 935-943, 2005.

SANQUETTA, C.R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C.R.; WATZLAWICK, L.F.; BALBINOT, R.; ZILLOTTO, M.A.B.; GOMES, F.S. (Eds.). **As florestas e o carbono**. Curitiba: Universidade Federal do Paraná, 2002, p. 119-140.

SANQUETTA, C.R.; SANQUETTA, M.N.I.; MAAS, G.C.B.; PELISSARI, A.L.; CORTE, A.P.D.; PIVA, L.R.O. Métodos de quantificação do estoque de carbono na biomassa

de *Nectandra grandiflora* Nees em remanescente de Floresta Ombrófila Mista. **Acta Iguazu**, v. 8, n. 1, p. 41-49, 2019.

SANTOS, K.E.L.; BERNARDI, A.C.C.; BETTIOL, G.M.; CRESTANA, S. Geoestatística e geoprocessamento na tomada de decisão do uso de insumos em uma pastagem. **Brazilian Journal of Biosystems Engineering**, v. 11, n. 3, p. 294-307, 2017a.

SANTOS, M.C.; ROVEDA, M.; ZANON, M.L.B.; FIGUEIREDO FILHO, A.; ROIK, M.; PACHECO, J.M.; SCAVINSKI, V. Inventário florestal utilizando técnicas de silvicultura de precisão em povoamentos de *Eucalyptus grandis* Hill ex Maiden. **Floresta e Ambiente**, v. 24, p. 1-9, 2017b.

SANTOS, P.C.; SANTANA, A.C.; BARROS, P.L.C.; QUEIROZ, J.C.B.; VIEIRA, T.O. O emprego da geoestatística na determinação do tamanho “ótimo” de amostras aleatórias com vistas à obtenção de estimativas dos volumes dos fustes de espécies florestais em Paragominas, estado do Pará. **Acta Amazonica**, v. 41, n. 2, p. 213-22, 2011.

SANTOS, R.C.; CASTRO, R.V.O.; CARNEIRO, A.C.O.; CASTRO, A.F.N.M.; PIMENTA, A.S.; PINTO, E.M.; MARINHO, I.V. Estoques de volume, biomassa e carbono na madeira de espécies da Caatinga em Caicó, RN. **Pesquisa Florestal Brasileira**, v. 36, n. 85, p. 1-7, 2016.

SCOLFORO, H.F.; SCOLFORO, J.R.S.; MELLO, C.R.; MELLO, J.M.; FERRAZ FILHO, A.C. 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, H.F.; SCOLFORO, J.R.S.; MELLO, J.M.; MELLO, C.R.; MORAIS, V.A. Spatial interpolators for improving the mapping of carbon stock of the arboreal vegetation in Brazilian biomes of Atlantic forest and Savanna. **Forest Ecology and Management**, v. 376, p. 24-35, 2016.

SENA, K.K.K.; CAMPOS, P.S.S.; RODRIGUES, H.C.T.; CHASE, O.A.; MARQUES, G.T.; MORAES, R.I.R.; MORAIS, E.C.; SANTOS JÚNIOR, P.C.; SOARES, J.A.C.; GALATE, R.S. Análise geoestatística em povoamento de floresta nativa no município de Paragominas - Pará. **Brazilian Journal of Development**, v. 5, n. 10, p. 18695-18713, 2019.

SILVA, A.G.; FARIAS, P.R.S.; BOIÇA JUNIOR, A.L.; CORREIA, R.G.; SILVA, J.B.; RODRIGUES, N.E.L. Análise espacial da mosca-negra-dos-citros em pomar de Citros utilizando a geoestatística. **Revista de Agricultura**, v.86, n.2, p.102-114, 2011.

SILVA, C.A.; HUDAK, A.T.; VIERLING, L.A.; KLAUBERG, C.; GARCIA, M.; FERRAZ, A.; KELLER, M.; EITEL, J.; SAATCHI, S. Impacts of airborne Lidar pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 1068, p. 1-19, 2017.

SILVA JÚNIOR, J.C.; MEDEIROS, V.; GARROZI, C.; MONTENEGRO, A.; GONÇALVES, G.E. Random forest techniques for spatial interpolation of evapotranspiration data from Brazilian's Northeast. **Computers and Electronics in Agriculture**, v. 166, n. 105017, 2019.

SILVEIRA, E.M.O.; REIS, A.A.; TERRA, M.C.N.S.; WITHEY, K.D.; MELLO, J.M.; ACERBI-JÚNIOR, F.W.; FERRAZ FILHO, A.C.; MELLO, C.R. Spatial distribution of wood volume in Brazilian savannas. **Anais da Academia Brasileira de Ciências**, v. 91, n. 4, p. 1-12, 2019a.

SILVEIRA, E.M.O.; SANTO, F.D.E.; WULDER, M.A.; ARCEBI JÚNIOR, F.W.; CARVALHO, M.C.; MELLO, C.R.; MELLO, J.M.; SHIMABUKURO, Y.E.; TERRA, M.C.N.S.; CARVALHO, L.M.T.; SCOLFORO, J.R.S. 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, 2019b.

SILVEIRA, H.L.F.; GALVÃO, L.S.; SANCHES, I.D.A.; SÁ, I.B.; TAURA, T.A. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian semi-arid region. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 179-190, 2018.

SILVEIRA, P. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. **Floresta**, v. 40, n. 4, p. 789–800, 2010.

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

SOUZA, B.I.; ARTIGAS, R.C.; LIMA, E.R.V. Caatinga e desertificação. **Mercator**, v. 14, n. 1, p. 131-150, 2015.

SOUZA, D.G.; SFAIR, J.C.; PAULA, A.S.; BARROS, M.F.; RITO, K.F.; TABARELLI, M. Multiple drivers of aboveground biomass in a human-modified landscape of the Caatinga dry forest. **Forest Ecology and Management**, v. 435, p. 57-65, 2019.

TAVARES, V.C.; ARRUDA, I.R.P.; SILVA, D.G. Desertificação, mudanças climáticas e secas no semiárido brasileiro: uma revisão bibliográfica. **Geosul**, v. 34, n. 70, p. 385-405, 2019.

TOLEDO, D.P.; JACOVINE, L.A.G.; TORRES, C.M.M.E.; SOARES, C.P.B. Equação de biomassa e estoque de carbono do pinhão manso, no município de Viçosa, MG. **Ciência Rural**, v. 42, n. 11, p. 1998-2004, 2012.

TSUI, O.W.; COOPS, N.C.; WULDER, M.A.; MARSHALL, P.L. Integrating airborne LiDAR and space-borne radar via multivariate kriging to estimate above-ground biomass. **Remote Sensing of Environment**, v. 139, p. 340-352, 2013.

VASCONCELOS, A.D.M.; HENRIQUES, I.G.N.; SOUZA, M.P.; SANTOS, W.S.; SANTOS, W.S.; RAMOS, G.G. Caracterização florística e fitossociológica em área de Caatinga para fins de manejo florestal no município de São Francisco-PI. **Agropecuária Científica no Semiárido**, v. 13, n. 4, p. 329-337, 2017.

VIEIRA, G.; SANQUETTA, C.R.; KLÜPPEL, M.L.W.; BARBEIRO, L.S.S. Teores de carbono em espécies vegetais da Caatinga e do Cerrado. **Revista Acadêmica**, v. 7, n. 2, p. 145-155, 2009.

VIEIRA, R.M.S.P.; TOMASELLA, J.; BARBOSA, A.A.; MARTINS, M.A., RODRIGUEZ, D.A.; REZENDE, F.S.D.; CARRIELLO, F.; SANTANA, M.D.O. Desertification risk assessment in Northeast Brazil: Current trends and future scenarios. **Land Degradation & Development**, v. 32, n. 1, p. 224-240, 2020.

VIRGENS, A.P.; BARRETO-GARCIA, P.A.B.; PAULA, A.; CARVALHO, F.F.; ARAGÃO, M.A.; MONROE, P.H.M. Biomassa de espécies florestais em área de Caatinga arbórea. **Pesquisa Florestal Brasileira**, v. 37, n. 92, p. 555-561, 2016.

XUE, J.; GE, Y.; REN, H. Spatial upscaling of green aboveground biomass derived from MODIS-based NDVI in arid and semiarid grasslands. **Advances in Space Research**, v. 60, n. 9, p. 2001-2008, 2017.

YAMAMOTO, J.K. **Avaliação e classificação de reservas minerais**. São Paulo: Editora da USP, 2001.

YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de Textos, 2013.

ZANELLA, M. E. Considerações sobre o clima e os recursos hídricos do semiárido nordestino. **Caderno Prudentino de Geografia**, v. Especial, n. 36, p. 126-142, 2014.

ZECH, D.F.; REFOSCO, J.C.; YOSHIZUMI, L.T.; ABREU, R.O.S. Uso de interpoladores espaciais na estratificação estatística de *Pinus taeda*. **Scientia Forestalis**, v. 46, n. 117, p. 87-96, 2018.