



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Uso das geotecnologias na estimativa de biomassa e carbono florestal: Uma Revisão

José Douglas Monteiro da Costa¹, José Alberto Quintanilha²

¹Doutorando do Programa de Ciência Ambiental da Universidade de São Paulo - PROCAM/IEE/USP, e-mail: josedouglas@usp.br (autor correspondente). ²Professor Associado Sênior na Divisão Científica de Gestão, Ciência e Tecnologia Ambiental do Instituto de Energia e Ambiente - IEE da Universidade de São Paulo, e-mail: jaquinta@usp.br.

Artigo recebido em 11/04/2023 e aceito em 15/02/2024

RESUMO

As florestas tropicais são essenciais para a mitigação das mudanças climáticas, pois armazenam grandes quantidades de carbono na biomassa e na matéria orgânica do solo. Estudos utilizando dados de inventários florestais em modelos de interpolação geoestatística (krigagem) e sensoriamento remoto (imagens ópticas e radar de abertura sintética - SAR) têm revelado precisão satisfatória na estimativa da biomassa e carbono florestal. Frente à importância dessas ferramentas, o presente estudo teve como objetivo apresentar uma revisão que discorre sobre as aplicações das geotecnologias na estimativa de biomassa e carbono florestal. Estimativas mais precisas da biomassa e carbono florestal podem ser alcançadas quando a variabilidade espacial é levada em consideração. Fatores ambientais, como solo, relevo e clima, podem ser usados como preditores da distribuição espacial da biomassa e carbono florestal quando há uma relação entre essas variáveis e os diferentes tipos de vegetação, com o auxílio das geotecnologias. A krigagem, imagens de ópticas e de radar são geotecnologias que vêm auxiliando na modelagem de biomassa e carbono florestal, na construção de mapas de distribuição espacial, que podem ser utilizados como ferramentas para a orientação de políticas públicas, para inventários de emissões e estimativas de balanço de carbono, para determinar se o local atua como fonte ou sumidouro de carbono.

Palavras-chave: biomassa florestal, carbono, sensoriamento remoto, krigagem, geotecnologias.

Use of geotechnologies in the estimation forest biomass and carbon: A Review

ABSTRACT

Tropical forests are essential for mitigating climate change, as they store large amounts of carbon in biomass and soil organic matter. Studies using data from forest inventories in geostatistical interpolation models (kriging) and remote sensing (optical images and synthetic aperture radar - SAR) have revealed satisfactory accuracy in estimating forest biomass and carbon. In view of the importance of these tools, the present study aimed to present a review that discusses the applications of geotechnologies in estimating forest biomass and carbon. More accurate estimates of forest biomass and carbon can be achieved when spatial variability is taken into account. Environmental factors, such as soil, relief and climate, can be used as predictors of the spatial distribution of forest biomass and carbon when there is a relationship between these variables and the different types of vegetation, with the help of geotechnologies. Kriging, optical and radar images are geotechnologies that have been helping in the modeling of biomass and forest carbon, in the construction of maps of spatial distribution, which can be used as tools for guiding public policies, for emission inventories and estimates of carbon balance, to determine whether the site acts as a carbon source or sink.

Keywords: forest biomass, carbon, remote sensing, kriging, geotechnologies.

Introdução

Atualmente, uma das principais temáticas que movimentam os fóruns de discussões a respeito das questões ambientais que acometem tanto o meio natural como o urbano, é problemática das emissões de gases de efeito estufa e suas consequências relacionadas ao aquecimento global (Salgado Junior et al., 2017). Historicamente, o acúmulo de gases de efeito estufa na atmosfera se dá desde os meados da era industrial até os dias atuais, cuja intensificação das atividades humanas ligadas ao desenvolvimento do setor industrial, a queima de combustíveis fósseis e mudanças quanto ao uso da terra, como o desmatamento, produção e práticas agrícolas, por exemplo; aumentaram significativamente (Sodré et al., 2016, Arruda, 2018; Hui et al., 2022).

A crise do aquecimento global configura-se como uma das maiores problemáticas do século, em vista de suas mais variadas consequências, como altos custos ambientais diante do consumo energético e a utilização extensiva dos recursos naturais como requisito para a continuidade das atividades antropogênicas ligadas ao aumento da produção, e consequentemente, ao desenvolvimento econômico (Salgado Junior et al., 2017). Entretanto, o aumento de gases de efeito estufa associado ao aquecimento global geram consequências que vão muito além do prejuízo do setor econômico, que consistem nas mudanças climáticas, ou seja, as alterações nas condições climáticas decorrentes do acúmulo de gases como o dióxido de carbono (CO_2) e o metano (CH_4), por exemplo, e que possuem potencial de modificar tanto o espaço natural, quanto o urbano (Arruda, 2018; Turgut e Günlü, 2020).

Estima-se que a concentração média global de CO_2 aumentou de 280 ppm na revolução pré-industrial para mais de 400 ppm atualmente, consequentemente, estima-se que a temperatura média da superfície da Terra aumentará em um ritmo sem precedentes, podendo chegar a valores de 1,4 e 5,8 C ao longo de 100 anos, o que pode ocasionar em condições severas de inundações e secas (Hui et al., 2022; Maschler et al., 2022).

Os setores energético e industrial crescem devido a extensiva queima de combustíveis fósseis, como o carvão mineral, petróleo e gás natural, tanto pelas indústrias, de modo a aumentar a produção industrial, que cresce a fim de atender à crescente demanda por alimentos, roupas e habitações, como pelos diferentes meios de transportes, principalmente carros e caminhões, que emitem

gases pelo escapamento, são responsáveis pela maior parte das emissões anuais de gases de efeito estufa, especialmente o dióxido de carbono (CO_2) (Latake et al., 2015, Mikhaylov et al., 2020).

O setor agropecuário, é o terceiro maior responsável pelas emissões de gases de efeito estufa, metano (CH_4) e dióxido de nitrogênio (NO_2) basicamente (Latake et al., 2015, Mikhaylov et al., 2020). Atividades como por exemplo a fermentação entérica em ruminantes em decorrência da pecuária, a produção de dejetos de animais, o cultivo de arroz inundado, queima de resíduos agrícolas, e a emissão de dióxido de nitrogênio em solos devido ao uso e evaporação de fertilizantes e outros produtos agroquímicos, estão entre os principais processos geradores desses gases de efeito estufa (Besen et al., 2018, Mikhaylov et al., 2020).

Com o avanço do desenvolvimento urbano e as modificações de uso da terra, a vegetação e o solo têm sido substituídos por concreto e asfalto (Rocha et al., 2017). Gradativamente, têm-se surgido um consenso acerca das causas da fragmentação florestal em todo o mundo, no qual, muitos estudos as associam justamente com a agricultura comercial em larga escala, que está diretamente relacionada também a exportação de produtos agrícolas, principalmente se tratando de áreas florestadas da América Latina e do Sudeste Asiático (Rudel, 2017). Essa combinação de fatores de modificações de uso da terra, aliados ao desmatamento e a perda da biodiversidade, contribuem para o aumento da emissão de gases de efeito estufa, e consequentemente, podem acentuar modificações climáticas na Terra (Rocha et al., 2017).

Dentro deste contexto, formações vegetais como as florestas, proporcionam uma variedade de funções ecológicas e econômicas, sendo essencialmente importantes para a humanidade, pois fornecem água, meios de subsistência, além de exercerem controle sobre o clima, o solo e o balanço entre o O_2 e o CO_2 no planeta, além de serem fontes de diversidade estética, biodiversidade, madeira e bem-estar humano, assim como diversos outros serviços ecossistêmicos (Sinha et al., 2015; Ehlers et al., 2022; Francini et al., 2022; Knott et al., 2023).

As áreas florestadas desempenham um papel chave no processo atenuação das alterações climáticas, influenciadas pelo efeito de estufa antropogênico, pois atuam como verdadeiros

estoques de carbono por meio da absorção biológica de CO₂ (Büntgen et al., 2019; Migolet et al., 2022; Yu et al., 2022). Diante disto, as ações de monitoramento e estimativa dos recursos florestais tornam-se prioridades globais (Knott et al., 2023).

As plantas absorvem o CO₂ atmosférico, convertendo-o em carbono orgânico, que pode ser tanto estocado no solo, como utilizado pelas vias metabólicas das plantas para a produção de carboidratos, dessa forma, o aporte de resíduos vegetais com elevados níveis de carbono e nitrogênio, proporciona um aumento da matéria orgânica do solo, fazendo com que o mesmo se torne um dreno de CO₂ a longo prazo (Besen et al., 2018). Entretanto, como já mencionado anteriormente, a mudança do uso da terra e o desenvolvimento do setor agrícola, podem alterar potencialmente a dinâmica da matéria orgânica do solo, contribuindo de maneira significativa para a elevação nas emissões de CO₂, assim como de outros gases do solo para a atmosfera (Besen et al., 2018).

A biomassa vegetal consiste no material produzido pelas plantas, tanto em terra, como na água (algas), consumindo luz solar, água e nutrientes do solo (Cantero et al., 2019; Zheng et al., 2022). A biomassa vegetal é predominantemente terrestre, uma vez que as plantas que provêm da terra constituem mais de 99,5% do total da biomassa do planeta; além disso, as plantas são os organismos dominantes dos ambientes terrestres, moldando-os e, no caso das árvores, desenvolveram formas lenhosas de vida longa que permitem a criação e a manutenção de elevada biomassa (Díaz e Malhi, 2022; Yu et al., 2022).

A maior parte da biomassa, e consequentemente, do reservatório de carbono estão contidos nos ambientes florestais, com aproximadamente 80% dos estoques de carbono acima do solo (Cao et al., 2016; Zhao et al., 2022; Ahmad et al., 2023; Tian et al., 2023). Atualmente, existe uma crescente demanda com a finalidade de se monitorar e promover a gestão ambiental, especialmente da biomassa e da estrutura e diversidade florestal, devido a sua atuação como indicadores de mudanças climáticas e da saúde florestal (Sinha et al., 2015).

As estimativas de biomassa possuem muitas aplicações, as quais possibilitam que os agricultores avaliem o estado de crescimento das culturas e da fertilidade do solo, permitindo assim, estes implementem medidas de gestão eficientes, como a quantidade e momento de aplicação de fertilizantes, pesticidas e abastecimento de água para assegurar a saúde das culturas; além de ser

uma característica chave para o melhoramento de plantas, uma vez que medições precisas e não invasivas são de grande valor em diversos aspectos dentro da agricultura de precisão (Zheng et al., 2022).

Desta maneira, o uso de um método adequado e rigoroso para estimar com precisão o tamanho e distribuição da biomassa florestal é de suma importância (Shi e Liu, 2017). Tendo em vista que este elemento reflete a dinâmica e complexa entre a ciclagem de nutrientes e o fluxo de energia, e consequentemente, ao fornecimento das fontes de nutrientes e a base energética necessária para a funcionalidade de todo o ecossistema florestal (Tian et al., 2023).

As estimativas de biomassa florestal compõem um conjunto de elementos cruciais para o controle das emissões de carbono anuais e no planejamento de programas de reflorestamento, como por exemplo no reconhecimento preciso de espécies de árvores tropicais, o que é essencial no manejo de espécies florestais em relação a necessidade de se compreender melhor o papel dos ecossistemas florestais, dentre outras aplicações, dada a atual situação de combate ao aquecimento global (Wang et al., 2023; Zaki et al., 2023).

O monitoramento dos níveis de carbono a partir das estimativas de biomassa, é um componente importante na elaboração de políticas globais, tendo em vista que, os ambientes florestais são altamente relevantes para o 13º e 15º objetivos dos ODS's (Objetivos do Desenvolvimento Sustentável) da ONU (Organização das Nações Unidas), centrados respectivamente na 'Ação Climática' e na 'Vida Terrestre' (Turton et al., 2022).

Ainda existe uma incerteza considerável a respeito dos reservatórios de carbono contidos nas florestas, além de um conhecimento limitado sobre o papel das mesmas sobre o ciclo global do carbono (Cao et al., 2016). Desta maneira faz-se necessário um entendimento sobre os estoques de carbono nessas florestas como forma de auxiliar no desenvolvimento de inventários nacionais de carbono florestal e políticas de gestão de carbono, ações estas que exigem métodos precisos de estimativa de biomassa (Cao et al., 2016).

Os métodos de estimativa de biomassa florestal podem ser caracterizados como medições de campo, abordagens baseadas em sensoriamento remoto e simulações de modelos ecológicos; dentre os quais uma estimativa rápida e precisa contínua a ser um desafio dentro do campo da pesquisa florestal (Tian et al., 2023).

Cada método está sujeito a determinadas limitações, seja de tempo ou espaço. Enquanto os

métodos tradicionais, como a medição de campo, por exemplo, são destrutivos/invasivos, trabalhosos, caros e demorados; a utilização de métodos de sensoriamento remoto requer o processamento de grandes quantidades de dados geoespaciais (Tamiminia et al., 2022; Huang et al., 2023).

É importante ressaltar também, que a utilização de cada método de estimativa de biomassa florestal varia frequentemente conforme a escala, além disso o tipo de abordagem está sujeito a variação espacial na biomassa florestal em diversos níveis, os quais devem ser explorados tanto usando dados de múltiplas fontes, quantos as abordagens múltiplas que foram empregadas (Shi e Liu, 2017).

Além disso, ainda existem muitos erros aleatórios ou sistemáticos que surgem durante a estimativa de biomassa florestal, como por exemplo as diferenças espaciais entre as medições de campo e os dados de sensoriamento remoto, erros de medições baseadas em campo como árvores perdidas e/ou contadas duas vezes, os quais compõem incertezas geralmente difíceis de serem previstas em florestas naturais; embora possam haver metodologias que possam ser utilizadas para reduzir determinados erros, como por exemplo, o aumento do tamanho da parcela (Yu et al., 2022).

Diante desta notoriedade nas últimas décadas na modelagem da biomassa florestal, o presente estudo teve como objetivo apresentar uma revisão que discorre sobre as aplicações das geotecnologias na estimativa de biomassa florestal.

Desenvolvimento

Geoestatística

As medições em campos são requisitos básicos no que compete a coleta de informações sobre as florestas, contudo, estas medições podem ser dispendiosas, demoradas e impraticáveis em grandes áreas. Enquanto as estatísticas convencionais não podem explicar completamente as variações espaciais, os métodos geoestatísticos garantem uma estrutura probabilística para a compreensão das características da distribuição espacial das variáveis florestais (Karahane e Ersahin, 2018).

A geoestatística pode ser entendida como um conjunto de ferramentas matemáticas originalmente desenvolvidas com o objetivo de se estudar fenômenos que variam no espaço, contudo, tal método evoluiu para ser aplicado a vários problemas dentro das ciências da terra (Kodong et al., 2023). A força da geoestatística reside em sua abordagem estocástica para a modelagem numérica, embora nem todas as ferramentas dentro

da geoestatística são de fato estocástica; constituindo um excelente método, uma vez que se concentra em fenômenos naturais que exibem correlação espacial, cujas continuidade ou variabilidade espacial, anisotropia espacial e tendências, são características tipicamente importantes dentro deste meio (Kodong et al., 2023).

De acordo com o estudo elaborado por Lima et al., (2017), objetivou a modelagem da biomassa de fuste de uma espécie de araucária em uma área de Floresta Ombrófila Mista, no qual, a geoestatística se mostrou como uma ferramenta de grande eficiência no que diz respeito ao mapeamento, modelagem e dinâmica espacial dos estoques de biomassa da espécie vegetal, sendo possível a identificação de um padrão espacial que sugere um aumento do estoque de carbono ao longo do inventário contínuo.

Com o passar dos anos a geoestatística desempenhou um papel em relação a análise das variáveis que se distribuem continuamente no espaço, chamadas de “variáveis regionalizadas”, objetivando sempre a previsão de valores de um atributo de destino em locais onde não foram realizadas amostragens (Karahane e Ersahin, 2018). A geoestatística possui a sua base na teoria das variáveis regionalizadas, na qual não descreve apenas quantitativamente a heterogeneidade espacial ou correlação espacial, mas também estabelece um modelo de predição espacial para interpolar e estimar dados espaciais (Su et al., 2020), além disso, muito de sua fundamentação teórica baseia-se no pressuposto de que as unidades amostrais próximas são mais similares entre si em relação àquelas mais distantes no plano espacial (Lima et al., 2017).

Um ponto importante a ser ressaltado é que, atualmente a modelagem geoestatística é uma das alternativas possíveis para facilitar a integração de dados, entretanto, a autocorrelação espacial de variáveis regionalizadas é um aspecto frequentemente negligenciado em estudos de sensoriamento remoto de vegetação, tendo em vista que a maioria dos estudos se baseia no emprego de modelos de regressão estatística para estimar parâmetros da vegetação, pois estes modelos são mais diretos, confiáveis e adequados para áreas de estudo específicas (Li et al., 2015). Contudo, alguns poucos métodos empregados em estudos de estimativa dos parâmetros de vegetação consideraram a dependência espacial dos parâmetros objetivos, dentre eles, a krigagem é o modelo espacial mais conhecido e que foi aplicado com sucesso para estimar as variáveis dependentes do espaço (Li et al., 2015).

Métodos geoestatísticos têm sido amplamente utilizados para analisar a distribuição espacial e mapeamento de biomassa florestal acima do solo em grandes áreas, na qual diferentes abordagens para derivar estruturas espaciais de biomassa acima do solo podem ser aplicadas conforme a disponibilidade de informações secundárias, onde muito trabalho utilizando as informações secundárias podem ser encontradas em aplicações de sensoriamento remoto (Kim et al., 2016). Ou seja, a biomassa acima do solo pode ser modelada a partir de dados de sensoriamento remoto, como por exemplo, *Lidar*, bandas espectrais, índices de vegetação, imagens de satélite, dentre outras, nas quais variáveis ambientais são frequentemente combinadas (solos, tipos de vegetação, altitude, etc.), seguida de uma avaliação dos resíduos da estrutura espacial por um método geoestatístico, conhecido como krigagem (Kim et al., 2016).

A krigagem constitui um método utilizado para estimar o valor de uma variável em um local não amostrado, o qual é calculado por interpolação usando médias móveis de pontos de amostragem (Barni et al., 2016). Tal método fornece a melhor previsão linear não enviesada (BLUP) dos valores das variáveis regionalizadas em uma área limitada, além disso, quando baseada na regressão linear, a krigagem precisa assumir a estabilidade espacial na análise da variação espacial dentro de uma distância limitada, o que pode compensar os defeitos dos modelos não paramétricos em certa medida (Su et al., 2020). Desta maneira, a geoestatística é uma ferramenta que permite analisar espacialmente o comportamento da floresta em que o interpolador de krigagem permite a obtenção de valores em locais não amostrados (Lima et al., 2017).

Uma das maiores vantagens da krigagem, principalmente se tratando de interpolação geoestatística, é a sua ampla disponibilidade em vários aplicativos de softwares relativamente fáceis de serem executados, não exigindo que os usuários tenham muito conhecimento sobre os detalhes e fundamentação matemática em que a técnica se baseia, pois, a interpolação é parcial ou totalmente automatizada (Veronesi e Schillaci, 2019). Desta maneira, esses aplicativos permitem que os usuários desestabilizem automaticamente os dados, ajustem o modelo de variograma e interpoem pontos para a elaboração de um mapa final, entretanto, podem permitir a utilização de um método sem que haja a sua compreensão de fato, exemplos desses aplicativos incluem o Analista geoestatístico no ArcGIS e o pacote automap em R (Veronesi e Schillaci, 2019).

Em seus múltiplos usos como método geoestatístico, a krigagem pode ser utilizada para preservar a correlação espacial e de atributos dos dados do programa de inventário e análise florestal e para contabilizar a dependência espacial no inventário e no monitoramento florestal, além de possuir aplicações na silvicultura, quanto ao mapeamento de recursos florestais, e análise de pragas de insetos (Temesgen e Hoef, 2015). Além disso, é importante ressaltar que por conta de sua praticidade, a krigagem é amplamente aceita por diversos cientistas como uma técnica apropriada para estimar infestações de ervas daninhas que são responsáveis por reduzir o rendimento de grãos em muitas áreas no sul da Europa (Jurado-Expósito et al., 2019). Assim, a krigagem pode constituir uma ferramenta extremamente valiosa para o setor agrícola quanto a tomada de decisões para a implementação de estratégias de previsão de distribuição e controle de espécies de ervas daninhas, como por exemplo, a elaboração de mapas com locais e densidades de infestações de plantas daninhas (Jurado-Expósito et al., 2019).

Como mencionado anteriormente, a krigagem representa um método adequado em estudos espaciais, com ênfase na estimativa de biomassa, por conta de seu caráter em obter valores de variáveis ambientais em locais não amostrados, além de ser aplicável em diversas áreas, mesmo assim, ainda existem indagações a respeito de seu desempenho como estimador, especialmente quanto a estimativa de biomassa florestal. Wang et al. (2016), utilizaram três métodos, incluindo a krigagem, para simular os padrões de estoque de carbono da vegetação florestal da província de Jiangxi na China, entretanto, a krigagem não foi apontada como a técnica de melhor desempenho, tendo sido superada pela modelagem de superfície de alta precisão (High Accuracy Surface Modeling, HASM) e pela abordagem baseada em dados de satélite (Satellite-data Based Approach, SBA). Entretanto, é importante ressaltar que neste trabalho, foram detectados erros de simulação de métodos ou de modelos que resultaram em fontes de incerteza quanto as simulações de padrão de estoque de carbono florestal, e consequentemente, levando a subestimações ou superestimações dos métodos ou modelos.

Os métodos geoestatísticos, de um modo geral, se concentram em decompor um valor desconhecido de qualquer área, em um componente médio e um componente de resíduos, em que a variabilidade do componente médio determina o método a ser empregado na modelagem subsequente, tendo isto em mente, se o valor do componente médio é considerado

constante, o que é considerado um caso raro na maioria das vezes, um método base-estacionária conhecido como krigagem comum é recomendado (Gwenzi e Lefsky, 2017).

A krigagem é um dos métodos geoestatísticos que consiste em uma técnica de interpolação ideal que regride contra pontos de dados observados, ponderando-os com base em valores de covariância espacial, ou seja, tal técnica estima o valor de uma variável em um local não mensurado a partir da utilização de valores observados de locais vizinhos (Kodong et al., 2023).

A krigagem comum (OK) é o tipo de krigagem mais frequentemente utilizado, pois fornece uma boa previsão linear imparcial de valores intermediários, além de estimar as variáveis em um local não amostrado, atribuindo pesos determinados advindos do semivariograma, que vem a ser a relação entre a semivariância dos locais amostrados com a distância de latência que os separam (Li et al., 2015; Ahmad et al., 2023). Estudos recentes aplicaram esta técnica para estudar a variação espacial dentro do local de estoque de carbono na camada orgânica de solos de florestas boreais, e para mapear a variação de carbono orgânico no solo de áreas aráveis e de terras altas para inferir os impactos das futuras mudanças climáticas (Scolforo et al., 2016).

A krigagem de regressão (RK), por sua vez, é uma ferramenta que combina regressão estatística e krigagem para fazer previsões (Li et al., 2015). Esta constitui uma técnica de previsão espacial bastante eficiente, e que pode ser usada para interpolar amostras de variáveis ambientais, contínuas e categóricas, de grandes conjuntos de pontos (Ding et al., 2019). Na krigagem de regressão, duas partes das previsões são combinadas, uma sendo a tendência preditiva, obtido por regressão a variável primária no preditor auxiliar utilizando uma regressão linear, e a outra sendo os resíduos, que são interpolados usando a krigagem comum (Ding et al., 2019). De acordo com Gwenzi e Lefsky (2017), é indispensável o uso da krigagem de regressão para estudos mais abrangentes, pois os mesmos possuem o potencial de preservar o padrão espacial da variável primária, melhorando tanto as estimativas a nível local, quanto a nível global.

No estudo proposto por Ding et al. (2019), foi explorado o método de krigagem de regressão para estimar os estoques de carbono de pastagens no nordeste da China, os quais foram utilizadas cinco variáveis independentes para construir modelos de krigagem de regressão separadamente. Os resultados do estudo mostraram que os modelos

de krigagem de regressão para as variáveis amostradas, possuem uma precisão melhorada em relação aos métodos de regressão linear e a melhoria na precisão do modelo é atribuída principalmente ao aprimoramento da precisão de estimativa da estepe típica, além disso, foi observada uma tendência de aumento dos estoques de carbono do oeste para leste em pastagens na China.

Outra técnica de krigagem bastante conhecida é a cokrigagem, na qual diversas variáveis podem ser estimadas em conjunto com base na estrutura intervável e em informações espaciais, assim, neste método, as variáveis são espacialmente correlacionadas e têm um variograma cruzado, que é utilizado para quantificar a autocovariância cruzada-espacial entre a variável primária e a secundária, que por sua vez, é utilizada na interpolação do procedimento (Yadav e Nandy, 2015). Geralmente, a cokrigagem apresenta um desempenho melhor quando a variável primária de interesse é menos densamente amostrada do que as outras variáveis (Yadav e Nandy, 2015), situação em que claramente a variável secundária é fornecida por imagens de sensoriamento remoto que podem cobrir completamente a região de interesse, sendo assim, tal técnica oferece um meio barato de derivar uma cobertura espacial completa de informações ambientais para grandes áreas em intervalos regulares de tempo e, portanto, pode ser extremamente útil no fornecimento de estimativas de variáveis auxiliares (Jurado-Expósito et al., 2019).

Wai et al, (2022) utilizaram o método de krigagem ordinária em floresta aleatória para a reserva florestal de Namhton, e cokrigagem para a reserva florestal de Yinmar, ambas localizadas em Mianmar; as quais forneceram mapas robustos de biomassa acima do solo, essenciais para estimar o potencial de sequestro de carbono no contexto da Redução das Emissões por Desmatamento e Degradação florestal (REDD+), consequentemente, para estimular iniciativas de utilização e conservação florestal engajadas pela comunidade, com o intuito de promover o manejo florestal sustentável.

A krigagem com deriva externa (KED) é um dos modelos geoestatísticos híbridos comumente usados e que pressupõe que o valor em qualquer ponto é espacialmente dependente dos valores dos pontos vizinhos, mas a tendência de variação ou deriva é determinada externamente como uma função linear de um grupo de variáveis ambientais auxiliares (Paul et al., 2019). Ou seja, a krigagem de deriva externa é utilizada quando uma

variável principal (ou primária) apresenta relação de dependência com a variável auxiliar externa (secundária) (Rocha et al., 2016). Tal método consiste em uma abordagem direta onde a tendência e os resíduos são estimados como parte de um único sistema, obtendo sucesso em uma gama de estudos, dentre os quais podemos destacar, o mapeamento digital de solo, onde obteve precisões semelhantes ou melhores do que os mais simples modelos de krigagem, como a krigagem comum, ou dos mais novos e complexos modelos híbridos, como a krigagem de regressão (Paul et al., 2019). De acordo com Barni et al., (2016), a krigagem de deriva externa mostrou o melhor desempenho para representar a biomassa total do estado de Roraima, quando comparada com a krigagem comum e a cokrigagem, isto ocorreu devido à ausência de anisotropia (tendência espacial em uma determinada direção) e portanto, o modelo que empregou a técnica, foi considerado isotrópico para a variabilidade dos resíduos de biomassa, corroborando a eficiência da krigagem de deriva externa quando comparada com outras técnicas geoestatística.

No estudo elaborado por Costa (2020), foi utilizada a técnica de krigagem de deriva externa a partir de dados de inventários florestais com o intuito de gerar um mapa de alta resolução espacial da distribuição da biomassa de florestas do Estado do Amapá, dos quais foram obtidos uma estimativa total de estoques de biomassa de $536 \pm \times 10^9$ Mg em uma área de 107×10^3 km², além de uma estimativa de estocagem de 84% da biomassa florestal. Assim, tal estudo ressaltou a eficiência da krigagem de deriva externa na estimativa de biomassa florestal, pois tal técnica resultou em uma melhor representação da modelagem dos estoques de biomassa florestal, ressaltando também a contribuição dos modelos de interpolação geoestatística para a redução das incertezas na distribuição espacial da biomassa florestal e da essencialidade de mapas de alta resolução espacial para o balanço do carbono em diferentes escalas (Costa, 2020).

Barni et al., (2016) utilizaram três técnicas de krigagem para modelar a distribuição dos estoques de biomassa florestal original total e gerar mapas de referência do estado de Roraima, que resultou em um grande avanço na quantificação dos estoques de carbono e espacialização da biomassa florestal no estado, ressaltando o potencial e eficiência dessas técnicas e a sua contribuição quanto a redução da incerteza na distribuição espacial da biomassa florestal. Além disso, os mapas gerados neste estudo representam um meio de fácil de uso para a obtenção de

estimativas regionais de escala local e regional para estudos de emissões de gases de efeito estufa.

Diversos estudos anteriores demonstraram que os métodos geoestatísticos possuem maior precisão quando comparados com as técnicas de sensoriamento remoto; contudo cabe ressaltar que em algumas pesquisas, dados limitados de fatores topográficos, edáficos, climáticos e antropogênicos foram apontados como fatores que influenciam a precisão das técnicas de krigagem; de maneira semelhante, a distribuição espacial e a heterogeneidade dos gráficos de campo da biomassa exercem influência sobre a precisão de tais métodos (Ahmad et al., 2023).

É evidente que a propriedade de predição espacial, ou seja, estimar variáveis-alvo, proporcionada pelos modelos de krigagem tornaram-se muito populares com o passar dos anos, porém, a disseminação do sensoriamento remoto e o sistema aberto, compartilhado por diversas instituições públicas, com dados ambientais de alta resolução, fez com que os modeladores ecológicos estivessem cada vez mais interessados no uso de dados auxiliares, mudando substancialmente a forma com que a predição espacial é realizada, com os profissionais dependendo cada vez mais do subcampo da inteligência artificial conhecido como Machine learning (ML) (Veronesi e Schillaci, 2019). Nos últimos anos, houve um aumento considerável de trabalhos que apresentam o ML como tópico, demonstrando claramente que o ML vêm se tornando a primeira escolha quanto aos métodos de modelagem ecológica de muitos pesquisadores, embora, exista uma falta de evidências que corroborem uma diferença significativa no nível de precisão entre as duas abordagens (Veronesi e Schillaci, 2019).

Todavia, um aspecto chave a ser considerado em relação as técnicas geoestatística de krigagem, é que dado o contexto atual de projetar estratégias a fim de garantir paisagens cada vez mais resilientes em virtude das mudanças nas condições ambientais, se torna imprescindível a necessidade de se utilizar ferramentas técnicas para a obtenção de informações a respeito dos atributos das florestas em grandes paisagens nacionais e macroescalas, neste contexto, a krigagem de deriva externa representa um método de bastante eficiência, quando cuidadosamente elaborado, para atingir esta finalidade. Um exemplo claro que demonstra tal necessidade foi o estudo elaborado por Lochhead et al., (2018), em que a krigagem de deriva externa foi apontada como o método de maior precisão e consistência lógica quanto ao fornecimento de informações dos atributos de

florestas em uma zona boreal no Canadá, essenciais para os sistemas de suporte a decisões mais e abrangentes e complexas para orientar mudanças no manejo e na política florestal, e consequentemente, dar suporte a minimização de impactos frente às mudanças ambientais.

Imagens ópticas

Imagens ópticas consistem basicamente em pixels, incluindo informações de sensoriamento remoto passivo visível e comprimento de onda infravermelho (Dittmann et al., 2017), os quais utilizam a radiação do sol e fornecem uma vista bidimensional das florestas e de outras características da superfície terrestre (Timothy et al., 2016), consequentemente, possuem capacidade de estimar a biomassa acima do solo, isto ocorre devido ao fato de que resposta espectral nos dados do sensor óptico está relacionado com a interação entre a cobertura vegetal e a radiação solar, desta maneira, a biomassa pode ser estimada a partir da correlação entre a resposta espectral e os dados do solo obtidos nas plotagens de campo (Kumar et al., 2016).

A principal vantagem do uso de imagens ópticas é que estas possuem elevada disponibilidade e fácil acesso, além da sua operacionalidade de nível local e global, com sensores, como por exemplo, Landsat TM, AVHRR e MODIS, que fornecem globalmente uma variedade de dados espaciais, assim, uma série de estudos empregaram o sensoriamento remoto óptico como método de estimativa de biomassa acima do solo, tanto em pequena escala como em grande escala (Timothy et al., 2016; Ehlers et al., 2022; Tamiminia et al., 2022).

O sensoriamento remoto óptico tem a capacidade de estimar a biomassa acima do solo porque a resposta espectral nos dados do sensor óptico está relacionada à interação entre a cobertura vegetal e a radiação solar (Kumar et al., 2016), sendo estimada determinando a correlação entre a resposta espectral e os dados do solo obtidos nas plotagens de campo (Kumar et al., 2016).

Nas últimas décadas, o emprego de diversas tecnologias de sensoriamento remoto acabou por proporcionar um meio técnico e mais eficiente quanto a coleta de dados de observações de vegetação espacialmente contínuas e consistentes em múltiplas escalas espaciais; embora as imagens de sensoriamento remoto não forneçam estimativas diretas de biomassa florestal acima do solo, grande parte dos estudos elaboram modelos de regressão entre estimativas de biomassa de campo e índices de sensoriamento remoto, como o índice de vegetação por diferença

normalizada, por exemplo, com o objetivo de fornecer a biomassa florestal acima do solo espacialmente contínua (Yang et al., 2022).

O sensoriamento remoto óptico de alta e média resolução é comumente utilizado para a estimativa de biomassa florestal acima do solo; todavia, as imagens ópticas de alta resolução, geralmente, são muito caras e bastante difíceis de obter, embora forneçam resultados mais precisos de estimativa de biomassa, quando comparadas as imagens ópticas de média resolução (Li et al., 2023).

Sensores ópticos, como os multiespectrais, podem facilmente distinguir a distribuição básica da vegetação verde, no que diz respeito à fotossíntese das plantas, o que claramente está associado com a banda verde, esta por sua vez, pode ser diretamente correlacionada com biomassa, ou então primeiro transferida para os índices de vegetação e depois correlacionados com a biomassa (Dittmann et al., 2017). Os índices de vegetação multiespectrais (VIs) são amplamente utilizados para classificação de vegetação fina e estimativa de parâmetros biofísicos e bioquímicos, embora, uma alta precisão de estimativa ser de difícil alcance devido a problemas de saturação espectral em floresta densa (Shao e Zhang, 2016).

Para a remoção da variabilidade causada pela geometria do dossel, ângulo de visão do sol na estimativa de biomassa, foi desenvolvida uma relação entre os índices de vegetação e os parâmetros biofísicos da floresta, representando uma vantagem em potencial na estimativa de biomassa que varia de médias a grandes escalas (Kumar et al., 2016). Em resumo, o sensoriamento remoto óptico usa técnicas de modelagem com base nas relações biomassa-índice de vegetação para estimar a biomassa acima do solo, uma vez que utiliza as interações entre as ondas eletromagnéticas com a química ou estrutura da folhagem para medir os índices de vegetação, como o índice de vegetação de diferença normalizada (NDVI), índice de área foliar (IAF) (ou *leaf area index*, LAI), entre outros (Sinha et al., 2015).

As imagens ópticas podem ser classificadas de acordo a resolução espacial, em que, os dados tidos como de alta resolução espacial, possuem eficiência quanto a estimativa de biomassa a nível local (IKONOS e WORLDVIEW-2), dados de resolução média são conhecidos para estimativa a nível regional (Landsat), e por fim, dados de resolução baixa ou grosseira, considerada úteis em estimativas de biomassa a nível nacional e global (Kumar et al., 2016).

Imagens de alta resolução espacial contém informações abundantes de textura que caracterizam a distribuição espacial e estrutura dos dosséis da floresta, desta maneira, tais dados possuem uma certa vantagem sobre as respostas espectrais para estimativa de biomassa em florestas de estrutura complexa, e são reconhecidamente aceitos como promissores preditores de estimativa de biomassa acima do solo para florestas (Meng et al., 2016).

Vários tipos de imagens multiespectrais de alta resolução (VHRM) (GeoEye WV2, WV3, IKONOS e QB, por exemplo), podem ser utilizadas para quantificar a biomassa em uma gama variada de resoluções (espaciais, radiométricas, temporais e espectrais) e escalas, dependendo da sua finalidade e recursos necessários para a sua execução (Mohd Zaki e Latif, 2017). Contudo, cabe aqui ressaltar que em virtude do objetivo de quantificar e modelar a biomassa florestal acima do solo, é necessária a escolha do método adequado por parte do pesquisador (Mohd Zaki e Latif, 2017).

Uma importante vantagem de utilizar as imagens de satélite de alta resolução, é o potencial que estas representam quanto a capacidade de prever resultados precisos em diversos aspectos, tais como o mapeamento e avaliação de desmatamentos (área, localização, alteração ambiental), degradação florestal (redução na capacidade de produção, ou seja, volume de madeira/biomassa) e proxies de degradação florestal (fechamento de dossel, morfologia do dossel, número de árvores maduras, densidade e composição de espécies e incidência de incêndios e erosão na superfície do solo) (Ahmad et al., 2021).

Além disso, é importante destacar que o uso de variáveis independentes derivadas de satélites, como por exemplo as copas das árvores, textura da imagem, fração de sombra das árvores, altura das copas das árvores, e sobretudo dos VIs, possuem o potencial de produzir precisões de previsão superiores a 0,8 em escalas regionais (Zheng et al., 2022).

Uma variedade de características espectrais conhecidas como índices vegetativos (Vis), têm sido utilizados para estimativas de biomassa, devido o seu potencial de uso quanto a avaliação quantitativa da riqueza, o verde, a vitalidade da vegetação em experimentos de campo, e principalmente, no monitoramento de culturas de grão de interesse econômico, como o milho (*Zea mays* L.), cevada (*Hordeum vulgare*), arroz (*Oryza sativa*) e trigo (*Triticum spp.*) (Sharma et al., 2022).

Atualmente, as medições realizadas em campo enfrentam muitos desafios, isto ocorre devido a uma série de fatores, principalmente, a demora em coletar dados de campo suficiente a fim de cobrir toda a gama de mudanças em grandes áreas, cujas condições de crescimento da vegetação variam espacialmente, além da impossibilidade de se coletar grande quantidade de dados de campo suficientes para satisfazer as regras de amostragem estatística em virtude das condições florestais imprevisíveis (Shao et al., 2017). Assim, o emprego da tecnologia de sensoriamento na avaliação da biomassa tem se mostrado uma alternativa melhor aos métodos convencionais de estimativa de biomassa. Estudos que utilizam dados de sensoriamento remoto óptico nas estimativas de biomassa são geralmente feitos revelando a correlação entre biomassa e respostas espectrais e/ou índices de vegetação derivados de imagens multiespectrais (Sinha et al., 2015).

A saturação de refletância espectral constitui o principal fator limitante do uso de dados de sensoriamento remoto óptico para florestas possuem estruturas de dossel complexas, de múltiplas camadas e altos valores de biomassa acima do solo, ocasionando em superestimativas e subestimativas para valores menores e maiores, respectivamente, o que gera as imprecisões de estimativa e torna desafiador melhorar a precisão da estimativa de biomassa acima do solo da floresta (Ou et al., 2019; Moradi et al., 2022).

Contudo, a seleção de variáveis espectrais que possuem fortes interações com a biomassa acima do solo da floresta, pode ser a chave para aumentar a precisão de tal estimativa a partir do uso de dados de sensoriamento remoto, pois a utilização de diversas bandas espectrais ou outras variáveis derivadas das bandas, como os índices de vegetação, medidas de textura e imagens fracionárias, bem como, a combinação desses componentes com as variáveis ambientais, como a elevação e declive, possibilitam a construção de modelos de estimativa de biomassa acima do solo, com uma precisão maior que aqueles modelos construídos a partir das bandas originais (Ou et al., 2019).

Meng et al. (2016) aplicaram uma abordagem baseada em textura conhecida como FOTO (Fourier-based textural ordination), que usa uma combinação transformada de Fourier e análise de componentes principais (PCA) para detectar a heterogeneidade estrutural do dossel da floresta, cujos índices de textura podem ser considerados bons preditores biomassa acima do solo em florestas tropicais, de modo a caracterizar informações de textura que estavam relacionadas a

parâmetros estruturais da floresta como o tamanho da copa do dossel. O estudo mostrou alta precisão do método em relação a estimativa de biomassa em regiões maiores, além de exibir grande potencial para estimar a biomassa florestal sem saturação em zonas temperadas, além de ressaltar o auxílio que o FOTO pode proporcionar em melhorar a eficiência e a precisão da estimativa no monitoramento e no rastreamento da biomassa florestal.

De acordo com Ahmad et al. (2021), a copa das árvores é a variável mais amplamente utilizada dentre as variáveis independentes derivadas de satélite utilizadas para a elaboração de modelos precisos de estimativa de biomassa florestal, seguida pela textura da imagem. Entretanto, é importante ressaltar que dada a complexidade dos ambientes florestais ao redor do mundo, cada qual, possuem suas particularidades quanto aos fatores bióticos e abióticos, é difícil estabelecer um único sensor específico, tido como o melhor quando comparados com os demais (Ahmad et al., 2021).

As imagens de sensoriamento remoto têm sido largamente utilizadas nas estimativas de biomassa em áreas vegetadas de difícil acesso, cujas faixas e índices de vegetação derivadas das imagens ópticas variam de acordo com o conteúdo de água e clorofila, e a estrutura da cavidade foliar da vegetação que estão correlacionados com ao tipo de planta ou seus estágios de crescimento, assim, estes podem ser usados para monitorar a biomassa das florestas, bem como, auxiliar no mapeamento de distúrbios florestais ao redor do mundo, sob diferentes escalas temporais e a partir de inúmeras abordagens (Zhu et al., 2020; Francini et al., 2022).

Apesar das imagens ópticas estarem amplamente disponíveis, como é o caso do Espectrorradiômetro de imagem de resolução moderada (MODIS), Landsat, IKONOS, SPOT e imagens do WorldView-2, esses sensores não são capazes de penetrar na superfície das copas das florestas para obter sua estrutura e as alturas das árvores necessárias para estimativa de biomassa (Zhu et al., 2020).

Sensores ópticos de resolução média (30m), como os dos satélites Landsat, são caracterizados por possuírem um tempo de revisita de 16 dias, tornando difícil a obtenção de observações sem a cobertura de nuvens em grandes áreas (Rodríguez-Veiga et al., 2016). Apesar de novos produtos, como o Landsat WELD serem capazes de gerar composições de radiâncias mensais, sazonais e anuais da superfície atmosférica com resolução de 30 m globalmente, estas mesmas composições estão limitadas a terem o seu uso em área pouco nubladas no mundo,

diferente dos sensores ópticos de resolução mais grosseira (250 m), como o MODIS, que apesar de também apresentarem suas devidas limitações metodológicas, possuem um tempo de revisita de 24 h, e portanto, mais oportunidades de criar imagens em condições sem nuvens que os satélites Landsat (Rodríguez-Veiga et al., 2016).

Atualmente o sensoriamento remoto no monitoramento do estoque de carbono florestal é um desafio na região neotropical, isto corre porque a biomassa florestal acima do solo excede 400 Mg ha⁻¹ e a maioria dos sensores de satélites não detectam a variação de biomassa florestal acima de 150 Mg ha⁻¹ (Ploton et al., 2017). Tal situação é bem documentada tanto em sensores ópticos passivos de resolução espacial intermediária, como o Espectrorradiômetro de Imagem de Resolução Moderada (MODIS) ou o mapeador temático Landsat, quanto em sinais de radar, e portanto, constitui uma limitação dos dados de sensoriamento remoto (Ploton et al., 2017). Outra problemática envolvendo as regiões tropicais é a alta cobertura de nuvens, que em parte, é o fator responsável por inviabilizar o uso da técnica nesta região (Sinha et al., 2015). Assim, o sensoriamento remoto tem tido sucesso na estimativa de biomassa florestal, entretanto, apenas em regiões geográficas limitadas (Sinha et al., 2015).

Uma técnica alternativa que tem mostrado grande potencial quanto ao mapeamento de biomassa florestal acima do solo, é a técnica de detecção de luz e alcance (*light detection and ranging*, Lidar), que consiste em um sensor 3D que mede a distância por meio de um laser que atinge o objeto-alvo, sendo capaz de penetrar o dossel da floresta de forma eficaz, pois utiliza um pulso laser de comprimento de onda curta focado, fornecendo estimativas precisas de métricas de árvores, como por exemplo a altura das árvores, que está intimamente relacionada com a biomassa acima do solo (Su et al., 2016; Ehlers et al., 2022; Jiang et al., 2022; Narvaes et al., 2023).

Diferentemente do sensoriamento remoto óptico passivo, o Lidar não sofre os efeitos de saturação, mesmo densidades elevadas de biomassa florestal, o que excede em muito as capacidades do sensoriamento remoto óptico passivo e radar no que se refere ao mapeamento das florestas, entretanto, nenhuma das plataformas principais de tecnologia Lidar (aeronaves e satélites) fornecem cobertura global completa da superfície terrestre, podendo, muitas vezes, estarem disponíveis apenas para determinadas áreas pequenas ao redor do globo, principalmente se tratando de dados Lidar aerotransportados (Su et al., 2016).

Embora as imagens ópticas passivas produzam estimativas de biomassa acima do solo de menor precisão quando comparadas com as imagens ativas como LIDAR e Radar, as imagens ópticas passivas possuem reconhecidamente uma ampla disponibilidade de dados em arquivos mais longos do que das imagens ativas, portanto o desenvolvimento de métodos de estimativa de biomassa acima do solo que usem imagens ópticas ainda é de elevada importância (Zhu e Liu, 2015).

Além disso, diferentes tipos de dados ópticos podem ser combinados de modo a melhorar a precisão das estimativas de biomassa. No estudo elaborado por Zhu et al. (2020), a integração de dados ópticos GF-2 e GF-3 de um modelo para estimar a biomassa acima do solo de uma plantação de mangue rendeu uma precisão maior que os modelos usando apenas um desses conjuntos de dados, apresentando uma redução de 2,32 % e 3,49%, respectivamente, do erro quadrático médio relativo (relative root-mean-square error, RMSEr), que é utilizado para expressar a precisão dos resultados numéricos.

Bourgoin et al. (2018), avaliaram o potencial do sensoriamento remoto de múltiplas fontes livremente acessíveis para modelagem e mapeamento de parâmetros estruturais de florestas degradadas na parte nordeste do estado do Pará, onde foram utilizados indicadores derivados de fontes de sensoriamento remoto ativo e passivo, que foram combinados com dados de biomassa acima do solo, coletados *in situ*, em um modelo de regressão de floresta aleatório para prever a biomassa em uma resolução de 20 m, resultando em um mapeamento que revelou um percentual de 87% de áreas degradadas por atividades madeireiras ilegais e bordas florestais impactadas, e consequentemente, uma abordagem que pode ser utilizada no melhoramento do manejo de florestas degradadas em escala regional.

No estudo elaborado por Molinier et al. (2016), um novo tipo de abordagem de estimativa de biomassa com o envolvimento do público em geral, no que se refere ao processo e coleta de dados ecológicos, sobretudo nas regiões tropicais, abordagem conhecida como sensoriamento participativo que vêm como uma abordagem promissora para aumentar as coberturas espaciais e temporais de observações florestais *in situ* de maneira econômica.

O mesmo estudo validou a eficácia do aplicativo gratuito de smartphone apresentado pelos autores como Relasphone, quanto a coleta de dados de medições de inventários florestais e estimativas de biomassa florestal *in situ*, que foram usadas para calcular mapas de biomassa na

Finlândia e no México a partir de imagens GeoEye e Landsat-8, cuja precisão foi avaliada por comparação com dados de plotagem de inventário florestal de referência de dois locais de floresta mista nesses dois países, representando o futuro no que confere a ciência cidadã, ou seja, o envolvimento do público em geral em atividades científicas.

Imagens de Radar

O radar de abertura sintética (Synthetic Aperture Radar, SAR), é uma técnica ativa de sensoriamento remoto que envia pulsos de radiação de micro-ondas e calcula distâncias baseadas em interferometria; cuja quantidade de radiação emitida aumenta à medida que aumenta o volume de vegetação em uma área, sendo esta uma característica vantajosa e útil quanto ao emprego do SAR para os inventários florestais (Dittmann et al., 2017; Turton et al., 2022). Como citado anteriormente, o sistema SAR é baseado em pulsos de radiação de micro-ondas que são transmitidos para as áreas-alvo e que posteriormente retornam sob a forma de ecos, cujos dados, em princípio, são processados sob a forma de imagens 2D que contém as informações de intensidade do sinal espelhado, fase da radiação recebida, que é relativa ao alcance entre a antena SAR, e o alcance da antena até a célula de resolução (Kaasalainen et al., 2015).

O sensor remoto SAR pode usar imagens de diferentes parâmetros, como os ângulos de incidência e a configuração de polarização do sensor, para obter uma riqueza de informações, assim, o sensoriamento remoto de radar exibe um potencial considerável em diversos campos, como por exemplo, no campo agrícola, que merece destaque em virtude de seu viés econômico, cujos dados obtidos por meio do SAR podem apresentar diversas vantagens, como por exemplo, a capacidade de adquirir dados em más condições climáticas, assim, o SAR pode ter grande valor na área do sensoriamento remoto agrícola, além disso, tal recurso apresenta uma ampla fonte de dados, que têm se expandido cada vez mais, e com desenvolvimento de sistemas pequenos e leves, como os veículos SAR aéreos não tripulados, podem vir a proporcionar uma contribuição significativa do SAR na agricultura, (Liu et al., 2019).

Uma das principais características de um sistema SAR é a banda de frequência em que opera, a qual é inversamente proporcional ao tamanho da onda de micro-ondas (Kaasalainen et al., 2015). O retroespalhamento total de uma floresta constitui de uma combinação do retroespalhamento do solo

e da vegetação, no qual a radiação de micro-ondas é espalhada de modo direto e difuso no solo e nos componentes da vegetação, como nos galhos, caules, folhas, e suas interações (Santi et al., 2017).

Existem cinco comprimentos de ondas comuns disponíveis para a pesquisa científica que são comumente utilizadas para se obter as informações do solo e da vegetação, sendo estas, os sistemas de banda X-(~69 cm), C-(~6 cm), S-(~15 cm), L-(~24 cm) e banda P-(~69 cm) (Kaasalainen et al., 2015). Assim, diferenças quanto o comprimento de onda de cada sistema de banda, resultam em ferramentas com potencial de identificar diferentes componentes da estrutura da vegetação, e consequentemente, torna possível a estimativa precisa da biomassa florestal.

Apesar do SAR constituir a principal forma de se prever a biomassa, desde que se descobriu uma forte relação com a biomassa acima do solo; este possui algumas limitações, por exemplo, o retroespalhamento aumenta rapidamente com a biomassa acima do solo até atingir um ponto de saturação de cerca de 100-150 Mg/há para dados de banda L, sendo este o ponto de saturação que torna dificultada o mapeamento preciso de áreas densamente florestadas (Turton et al., 2022).

Santi et al., (2017), avaliaram a sensibilidade da multifrequência de dados SAR para as características da floresta e para explorar o potencial do retroespalhamento SAR para estimar o estoque crescente de biomassa em áreas mediterrâneas, que resultou na elaboração de um algoritmo de inversão baseado em Redes Neurais Artificiais (RNA), que além de apresentar uma elevada robustez e independência do local, permitiu a aplicação da teoria de transferência radiativa, de modo a simular o retroespalhamento das bandas L e C em várias polarizações de um alvo florestal.

A banda L, por exemplo, exibiu um coeficiente de espalhamento com uma relação clara com a biomassa da floresta em áreas de teste, apesar ter exibido diferentes sensibilidades e linhas de regressão nestas áreas, assim, tal estudo indica o algoritmo de inversão elaborado pode funcionar em áreas mediterrâneas heterogêneas e fragmentadas, caracterizadas por diferentes tipos de florestas, variações climáticas e condições orográficas.

De acordo com Dittmann et al. (2017), técnicas baseadas em imagens de radar podem ser diferenciadas pelo tipo de plataforma de movimento que emite o pulso de radiação de micro-ondas, podendo ser, uma abordagem de radar baseada em aviões ou em satélites. Ambas as abordagens tiveram o seu pico de desenvolvimento

quanto ao potencial nas observações de radar para estimar a biomassa acima do solo da floresta na década de 1990, a qual se destaca pelas plataformas AIRSAR e CARABAS (aeronaves), e ERS-1/2, JERS-1, SIR-C/X-SAR (satélites) (Santoro e Cartus, 2018). Abordagens de radar, tanto baseadas em aviões, quanto as baseadas em satélites são utilizadas para estimativas de biomassa de grandes áreas, entretanto, tais abordagens alcançam melhores precisões apenas em florestas esparsas ou florestas em regeneração com pouca biomassa (Dittmann et al., 2017).

A banda C tem comprimento de onda capaz de penetrar as folhas, a banda L tem um comprimento de onda mais longo, podendo penetrar em troncos e galhos espessos, a banda P, por sua vez, representa o componente dos sistemas de banda mais adequado para a quantificação de biomassa acima do solo, pois apresenta um comprimento de onda capaz de penetrar no dossel da floresta, entretanto, os dados de banda P possuem a desvantagem de ainda não estarem disponíveis gratuitamente (Debastiani et al., 2019).

Diferentemente das imagens de sensores ópticos, o SAR possui uma independência em relação a cobertura de nuvens e a radiação solar, e uma capacidade de penetração significativa através da vegetação, poluição atmosférica e até mesmo através da neblina, podendo capturar imagens durante o dia ou à noite, sob todas as condições climáticas, operando em diferentes polarizações (HH, VV, HV e VH) e comprimentos de onda (Z, C, e L, por exemplo); assim, as técnicas que operam por meio de frequência de micro-ondas têm se mostrado como uma banda espectral adequada para investigações florestais (Santi et al., 2017; Georgopoulos et al., 2022).

Tal afirmação só se torna evidente após o lançamento de novos satélites que dispõem de sensores SAR abordo, como por exemplo, TerraSAR-X, ALOS-2 e Sentinel-1, que possuem a vantagem de fornecer imagens sem cobertura de nuvens e com uma resolução fina, representando assim, uma vantagem para o monitoramento de locais com uma cobertura densa de nuvens, como a Amazônia, por exemplo (Debastiani et al., 2019).

De acordo com Singh et al., (2022), as imagens de satélite Sentinel-2 podem ser utilizadas com muito mais eficácia e precisão para mapeamentos de biomassa florestal acima do solo durante a estação chuvosa, uma vez que, as bandas de nova geração (Red Edge e Narrow NIR) presentes no satélite Sentinel-2 têm maior sensibilidade às mudanças na estrutura da vegetação.

Além disso, devido à cobertura frequente de nuvens, sobretudo nas regiões tropicais, o sensoriamento remoto por Radar de Abertura Sintética (SAR) tem se mostrado uma ferramenta importante para a avaliação de biomassa florestal acima do solo em regiões tropicais, tal fato se deve à capacidade dos sistemas SAR de penetrar nas nuvens e interagir com os dosséis da vegetação, sendo o componente de retroespalhamento volumétrico uma função da estrutura do dossel (Pereira et al., 2018).

Embora os sistemas SAR não sejam capazes de recuperar a estrutura vertical da vegetação tão facilmente quanto os sistemas de aeronaves de detecção e alcance de luz (Lidar), a capacidade de cobertura orbital de ampla faixa dos sistemas SAR é útil para avaliar grandes ecossistemas pantanosos, como as várzeas ao longo dos rios amazônicos, conhecidas por sua biodiversidade, complexidade e difícil acesso (Pereira et al., 2018).

Sensores de radar de abertura sintética transportados pelo espaço como, como o radar avançado de abertura sintética de banda L do tipo *phased array* de observação terrestre (ALOS PALSAR), fornecem imagens SAR de polarização quádrupla (*quad polarization, quad pol*), devido ao fato de incluírem informações de intensidade e fase para quatro canais de polarização com as mesmas características do alvo do sensor, possuindo assim inúmeras aplicações, tais como, densidade de biomassa e medições de variação, monitoramento de mudanças na produção agrícola, medições de distribuição florestal global e monitoramento de desastres (Sharifi e Amini, 2015). O uso de dados polarimétricos melhorou significativamente o emprego do sensoriamento remoto ativo em estudos florestais, fato atribuído considerando a capacidade de penetração da radiação de micro-ondas através de nuvens, neblinas, chuvas e densidade foliar (Sharifi e Amini, 2015).

Por certo, a estimativa de biomassa é uma das aplicações mais importantes de dados SAR em florestas, com os recursos polarimétricos mais simples, como o retroespalhamento de radar, que é adequado para esta finalidade, além disso, alguns parâmetros que podem ser determinados a partir de imagens SAR polarimetrizadas, incluindo o índice de biomassa (*biomass index, BMI*), o índice de estrutura do dossel (*canopy structure index, CSI*) e o índice de espalhamento de volume (*volume scattering index, VSI*), que são índices biofísicos diretamente relacionados com as características da vegetação (Sharifi e Amini, 2015). Portanto, os produtos SAR, como o *quad pol*, possibilitam aos pesquisadores o mapeamento da estrutura da

vegetação, estimando a contribuição relativa do solo, dossel e dos troncos para o sinal recebido (Debastiani et al., 2019).

No estudo elaborado por Sharifi e Amini (2015), dados de polarização quádrupla de sensores (ALOS PALSAR) foram usados para estimar biomassa florestal nas florestas hircanianas no Irã, cujo o uso de diversos recursos polarimétricos de retroespalhamento de radar proporcionaram melhores recursos que o uso de apenas um único recurso, permitindo uma descrição da densidade do dossel, orientação das hastes, a biomassa e uma medição intrínseca do ângulo de inclinação do alvo, foi concluído também que o método de regressão de vetor de relevância multivariada (*multivariate relevance vector regression, MVRVR*) empregado, foi um dos melhores métodos para estimativa de biomassa, apresentando o maior valor de R^2 e o menor valor de RMSE, confirmando o seu potencial quanto a estimativa de biomassa.

Em 2023 está previsto o lançamento do satélite *BIOMASS SAR* realizada pela Agência Espacial Europeia, que possui por objetivo a utilização de operar na banda P em uma frequência relativamente baixa (centrado em 435 MHz), a qual permite que as ondas eletromagnéticas penetrem o dossel e se reflitam em estruturas maiores, como galhos e caules de árvores, onde boa parte da biomassa está concentrada, o que torna a banda P particularmente sensível à biomassa florestal acima do solo, como consequência ao aumento da penetração do dossel, o solo pode agregar valor para o retroespalhamento total (Monteith e Ulander, 2021). Entretanto, devido aos regulamentos de transmissão da banda P na Europa e na América do Norte, nem todas as florestas do mundo serão cobertas pela *BIOMASS*, o que implica em uma perda estimada em 18,2% dos estoques de carbono da biomassa global (Monteith e Ulander, 2021).

Como qualquer outro método, o sensoriamento remoto por radar também tem limitações, como incerteza nas estimativas, saturação, conjunto de dados caros, dificuldades no processamento de dados e interações complexas com as florestas (Sinha et al., 2015). Dificuldades estas que podem ser superadas pela integração dos dados de sensores de radar com dados de sensores ópticos, por exemplo, em que tal combinação poderiam melhorar as estimativas de biomassa acima do solo de ecossistemas florestados, reduzindo a influência do fundo do solo e das condições meteorológicas, superando assim, as limitações de cada sensor (Wang et al., 2019).

Ao longo do tempo, o sensoriamento remoto se tornou uma ferramenta de suma importância quanto ao monitoramento preciso das mudanças dinâmicas temporais e espaciais que ocorrem nas florestas, no entanto, os dados de sensoriamento remoto não são capazes de revelar diretamente a biomassa acima do solo e suas alterações, sendo assim, é necessário o processamento e a transformação dos dados de sensoriamento remoto, e posteriormente, a sua combinação com os dados de levantamento terrestre para estimar a evolução temporal e espacial da biomassa acima do solo (Wang et al., 2021).

Apesar das observações a partir de um único sensor serem úteis para compreender até que ponto a biomassa pode ser prevista com a configuração do sensor (frequência, polarização, direção de visão, resolução espacial, ruído térmico, etc.), a chave para a recuperação de biomassa parece ser a combinação de dados de fontes múltiplas (Santoro e Cartus, 2018). Assim, a integração de diferentes conjuntos de dados pode fornecer estimativas precisas da biomassa florestal. No trabalho elaborado por Shao e Zhang (2016), a combinação simples de dados ópticos e de micro-ondas independentes melhoraram os resultados das estimativas de biomassa acima do solo de uma floresta a nordeste da Região Autônoma da Mongólia Interior, China, quando comparados com dados apenas ópticos ou apenas de micro-ondas, independentemente de qual algoritmo de predição ou tamanho de amostra utilizado, antes e depois da seleção das variáveis preditoras.

Huang et al. (2019), realizaram um mapeamento (resolução de 30 m), de uma floresta nacional da China, cuja biomassa florestal acima do solo, foi calculada através dos dados do Geoscience Laser Altimeter System (GLAS), e depois relacionado com diversas variáveis derivadas de imagens Landsat e dados SAR de banda L de matriz de fases (PALSAR), constituindo assim em um estudo de combinação de dados de imagens ópticas e de radar, resultando em uma estimativa de biomassa florestal correspondente com os inventários de biomassa acima do solo de outras áreas florestadas das dez principais províncias chinesas, além de um mapa que pode servir como linha de base que permite o estudo dos estoques de carbono e mudanças relacionadas a ele em toda China, demonstrando como o uso combinado de diferentes conjuntos de dados, como as imagens ópticas e de radar para melhoras as estimativas de biomassa florestal.

Os dados ópticos, por exemplo, podem permitir a estratificação de espécies ou

complementar as observações de SAR para recuperar biomassa florestal, assim avanços substanciais podem ser previstos em relação a sinergia óptica-radar, uma abordagem bastante nova, além do aumento da quantidade de observações repetidas por sensores orbitando atualmente, principalmente Sentinels, complementando ainda mais as observações de retroespalhamento, que refletem a estrutura horizontal de uma floresta, ou seja, a densidade com observações de estrutura vertical, como as fornecidas por PolInSAR, TomoSAR e LiDAR, fornecendo uma representação tridimensional da vegetação, portanto, potencialmente levando a melhores estimativas quando comparado ao uso das observações de um único sensor (Santoro e Cartus, 2018).

No contexto das regiões tropicais, alguns estudos têm se mostrado promissores quanto as estimativas de biomassa a partir da combinação de múltiplos conjuntos de dados e métodos estatísticos. Benitez et al. (2016), avaliaram três métodos geoestatísticos na estimativa e distribuição de biomassa acima do solo, incluindo a krigagem, de uma parte da floresta amazônica, localizada no Equador, aplicadas a um mesmo conjunto de dados incluindo dados de sensoriamento remoto de alta resolução espacial. O estudo concluiu a krigagem forneceu estimativas satisfatórias com menor erro de precisão quando comparada com os outros métodos, além de apontar que 75% da biomassa acima do solo foi explicada pela combinação de dados de sensoriamento remoto e variáveis ambientais, dentre as quais, o tipo de formação vegetal a variável de maior importância para estimar a biomassa florestal.

Conclusão

O estudo destacou como a aplicação de diferentes métodos geoestatísticos e de sensoriamento remoto podem colaborar na redução de erro e melhoramento da precisão quanto a estimativa da biomassa e carbono florestal acima do solo nas regiões tropicais, que representam grandes áreas de estocagem de carbono a nível global.

Estimar com precisão a biomassa florestal compreende uma tarefa essencial no que concerne a realização de ações voltadas para o manejo, preservação e conservação dos ambientes florestais, além de contribuir para o entendimento do papel do carbono proveniente dos ambientes florestais quanto a manutenção do equilíbrio global de carbono. Desta maneira, é fundamental a realização de cada vez mais pesquisas que

evidencie a eficiência quanto ao uso de métodos em que a biomassa florestal acima do solo é estimada, bem como as diferentes abordagens que podem ser empregadas com o intuito de reduzir os erros de precisão, e consequentemente, aumentar a fidedignidade dos mapas de biomassa florestal.

Referências

- Ahmad, A., Gilani, H., Ahmad, S. R., 2021. Forest Aboveground Biomass Estimation and Mapping through High-Resolution Optical Satellite Imagery—A Literature Review. *Forests* [online] 12. Disponível: <https://doi.org/10.3390/f12070914>. Acesso: 23 jun. 2022.
- Ahmad, N., Ullah, S., Zhao, N., Mumtaz, F., Ali, A., Ali, A., Tariq, A., Kareem, M., Imran, A. B., Khan, I. A., Shakir, M., 2023. Comparative Analysis of Remote Sensing and Geo-Statistical Techniques to Quantify Forest Biomass. *Forests*, [online] 14. Disponível: <https://doi.org/10.3390/f14020379>. Acesso: 24 jan. 2024.
- Arruda, H. B. O., 2018. Mapeamento das emissões de gases de efeito estufa em uma empresa do setor energético. *Conexões-Ciência e Tecnologia* [online] 12. Disponível: <https://doi.org/10.21439/conexoes.v12i3.1148>. Acesso: 05 jan. 2021.
- Barni, P. E., Manzi, A. O., Condé, T. M., Barbosa, R. I., Fearnside, P. M., 2016. Spatial distribution of forest biomass in Brazil's state of Roraima, northern Amazonia. *Forest Ecology and Management* [online] 377. Disponível: <https://doi.org/10.1016/j.foreco.2016.07.010>. Acesso: 15 ago. 2020.
- Benitez, F. L., Anderson, L. O., Formaggio, A. R., 2016. Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. *Acta Amazonica* [online] 46. Disponível: <https://doi.org/10.1590/1809-4392201501254>. Acesso: 20 ago. 2020.
- Besen, M. R., Ribeiro, R. H., Monteiro, A. N. T. R., Iwasaki, G. S., Piva, J. T., 2018. Práticas conservacionistas do solo e emissão de gases do efeito estufa no Brasil. *Scientia Agropecuaria* [online] 9. Disponível: <https://doi.org/10.17268/sci.agropecu.2018.03.15>. Acesso: 17 jun. 2020.
- Büntgen, U., Krusic, P. J., Piermattei, A., Coomes, D. A., Esper, J., Myglan, V. S., Kirdyanov, A. V., Camarero, J. J., Crivellaro, A., Körner, C., 2019. Limited capacity of tree growth to mitigate the global greenhouse effect under predicted warming. *Nature communications* [online] 10. Disponível: <https://doi.org/10.1038/s41467-019-10174-4>. Acesso: 09 set. 2020.
- Bourgoin, C., Blanc, L., Bailly, J. S., Cornu, G., Berenguer, E., Oszwald, J., Tritsch, I., Laurent, F., Hasan, A. F., Sist, P., Gond, V., 2018. The potential of multisource remote sensing for mapping the biomass of a degraded Amazonian forest. *Forests* [online] 09. Disponível: <https://doi.org/10.1038/s41467-019-10174-4>. Acesso: 14 out. 2021.
- Cantero, D., Jara, R., Navarrete, A., Pelaz, L., Queiroz, J., Rodríguez-Rojo, S., Cocero, M. J., 2019. Pretreatment processes of biomass for biorefineries: current status and prospects. *Annual review of chemical and biomolecular engineering*, [online] 10. Disponível: <https://doi.org/10.1146/annurev-chembioeng-060718-030354>. Acesso: 17 fev. 2021.
- Cao, L., Coops, N. C., Innes, J. L., Sheppard, S. R. J., Fu, L., Ruan, H., She, G., 2016. Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data. *Remote Sensing of Environment* [online] 178. Disponível: <https://doi.org/10.1146/annurev-chembioeng-060718-030354>. Acesso: 03 mar. 2021.
- Costa, J. D. M., Distribuição espacial da biomassa florestal do Amapá. *Dissertação (Mestrado). Programa de Pós-Graduação em Ciências Ambientais, Universidade Federal do Amapá.*
- Debastiani, A. B., Sanquetta, C. R., Corte, A. P. D., Rex, F. E., Pinto, N. S. Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest. *Annals of Forest Research*, 62, 109-122, 2019.
- Díaz, S., Malhi, Y. 2022. Biodiversity: Concepts, patterns, trends, and perspectives. *Annual Review of Environment and Resources*, [online] 47. Disponível: <https://doi.org/10.1146/annurev-environ-120120-054300>. Acesso: 24 jan. 2024.
- Ding, L., Li, Z., Wang, X., Yan, R., Shen, B., Chen, B., Xin, X., 2019. Estimating Grassland Carbon Stocks in Hulunber China, Using Landsat8 Oli Imagery and Regression Kriging. *Sensors* [online] 19. Disponível: <https://doi.org/10.3390/s19245374>. Acesso: 19 abr. 2020.
- Dittmann, S., Thiessen, E., Hartung, E., 2017. Applicability of different non-invasive methods for tree mass estimation: A review. *Forest Ecology and Management* [online] 398. Disponível:

- <https://doi.org/10.1016/j.foreco.2017.05.013>. Acesso: 21 abr. 2020.
- Ehlers, D., Wang, C., Coulston, J., Zhang, Y., Pavelsky, T., Frankenberg, E., Woodcock, C., Song, C., 2022. Mapping forest aboveground biomass using multisource remotely sensed data. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14051115>. Acesso: 25 jan. 2024.
- Francini, S., D'Amico, G., Vangi, E., Borghi, C., Chirici, G., 2022. Integrating GEDI and Landsat: spaceborne lidar and four decades of optical imagery for the analysis of forest disturbances and biomass changes in Italy. *Sensors* [online] 22. Disponível: <https://doi.org/10.3390/s22052015>. Acesso: 25 jan. 2024.
- Georgopoulos, N., Sotiropoulos, C., Stefanidou, A., Gitas, I. Z., 2022. Total Stem Biomass Estimation Using Sentinel-1 and-2 Data in a Dense Coniferous Forest of Complex Structure and Terrain. *Forests*, [online] 13. Disponível: <https://doi.org/10.3390/f13122157>. Acesso: 26 jan. 2024.
- Gwenzi, D., Lefsky, M. A., 2017. Spatial modeling of Lidar-derived woody biomass estimates collected along transects in a heterogeneous savanna landscape. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online] 10. Disponível: <https://doi.org/10.1109/JSTARS.2016.2582148>. Acesso: 02 nov. 2020.
- Huang, H., Liu, C., Wang, X., Zhou, X., Gong, P., 2019. Integration of multi-resource remotely sensed data and allometric models for forest aboveground biomass estimation in China. *Remote Sensing of Environment* [online] 221. Disponível: <https://doi.org/10.1016/j.rse.2018.11.017>. Acesso: 05 nov. 2020.
- Huang, T., Ou, G., Wu, Y., Zhang, X., Liu, Z., Xu, H., Xu, X., Wang, Z., Xu, C., 2023. Estimating the Aboveground Biomass of Various Forest Types with High Heterogeneity at the Provincial Scale Based on Multi-Source Data. *Remote Sensing*, [online] 15. Disponível: <https://doi.org/10.3390/rs15143550>. Acesso: 26 jan. 2024.
- Hui, D., Deng, Q., Tian, H., Luo, Y. 2022. Global Climate Change and Greenhouse Gases Emissions in Terrestrial Ecosystems. In: Lackner, M., Sajjadi, B., Chen, W. Y. (Eds.). *Handbook of Climate Change Mitigation and Adaptation*. 3 Ed. Springer.
- Jiang, F., Sun, H., Ma, K., Fu, L., Tang, J., 2022. Improving aboveground biomass estimation of natural forests on the Tibetan Plateau using spaceborne LiDAR and machine learning algorithms. *Ecological Indicators* [online] 143. Disponível: <https://doi.org/10.1016/j.ecolind.2022.109365>. Acesso: 26 jan. 2024.
- Jurado-Expósito, M., Castro, A. I. D., Torres-Sánchez, J., Jiménez-Brenes, F. M., López-Granados, F., 2019. Papaver rhoeas L. mapping with cokriging using UAV imagery. *Precision Agriculture* [online] 20. Disponível: <https://doi.org/10.1007/s11119-019-09635-z>. Acesso: 10 jan. 2021.
- Karahan, G., Erşahin, S., 2018. Geostatistics in characterizing spatial variability of forest ecosystems. *Eurasian Journal of Forest Science* 6, 9-22.
- Kaasalainen, S., Holopainen, M., Karjalainen, M., Vastaranta, M., Kankare, V., Karila, K., Osmanoglu, B., 2015. Combining lidar and synthetic aperture radar data to estimate forest biomass: status and prospects. *Forests* [online] 06. Disponível: <https://doi.org/10.3390/f6010252>. Acesso: 22 dez. 2020.
- Kim, T. J., Bullock, B. P., Wijaya, A., 2016. Spatial interpolation of above-ground biomass in Labanan concession forest in East Kalimantan, Indonesia. *Mathematical and Computational Forestry & Natural Resource Sciences* 8, 26-38.
- Knott, J. A., Liknes, G. C., Giebkink, C. L., Oh, S., Domke, G. M., McRoberts, R. E., Quirino, V. F., Walters, B. F., 2023. Effects of outliers on remote sensing-assisted forest biomass estimation: A case study from the United States national forest inventory. *Methods in Ecology and Evolution* 00, 1-16.
- Kodong, F. R., Abdollah, M. F. B., Othman, M. F. I. B., 2023. Geostatistics and digital image analysis for optimizing rice production. *Journal of Theoretical and Applied Information Technology* 101, 5745-5758.
- Kumar, K. K., Nagai, M., Witayangkurn, A., Kritiyutanant, K., Nakamura, S., 2016. Above ground biomass assessment from combined optical and SAR remote sensing data in Surat Thani Province, Thailand. *Journal of Geographic Information System* [online] 08. Disponível: <https://doi.org/10.4236/jgis.2016.84042>. Acesso: 15 mar. 2021.
- Latake, P. T., Pawar, P., Ranveer, A. C., 2015. The greenhouse effect and its impacts on environment. *International Journal of Innovative Research and Creative Technology* 1, 333-337.

- Liu, C. A., Chen, Z. X., Shao, Y., Chen, J. S., Hasi, T., Pan, H. Z., 2019. Research advances of SAR remote sensing for agriculture applications: A review. *Journal of integrative agriculture* [online] 18. Disponível: [https://doi.org/10.1016/S2095-3119\(18\)62016-7](https://doi.org/10.1016/S2095-3119(18)62016-7). Acesso: 20 abr. 2021.
- Lima, L. F. D., Pelissari, A. L., Figueiredo Filho, A., 2017. Modelagem geoestatística da biomassa do fuste de *Araucaria angustifolia* em remanescente de floresta ombrófila mista. *Agrarian Academy* [online] 4. Disponível: https://doi.org/10.18677/AGRARIAN_ACAD_EMY_2017B19. Acesso: 19 abr. 2021.
- Li, L., Zhou, B., Liu, Y., Wu, Y., Tang, J., Xu, W., Wang, L., Ou, G., 2023. Reduction in Uncertainty in Forest Aboveground Biomass Estimation Using Sentinel-2 Images: A Case Study of *Pinus densata* Forests in Shangri-La City, China. *Remote Sensing* [online] 15. Disponível: <https://doi.org/10.3390/rs15030559>. Acesso: 26 jan. 2024.
- Li, W., Niu, Z., Liang, X., Li, Z., Huang, N., Gao, S., Wang, C., Muhammad, S., 2015. Geostatistical modeling using LiDAR-derived prior knowledge with SPOT-6 data to estimate temperate forest canopy cover and above-ground biomass via stratified random sampling. *International Journal of Applied Earth Observation and Geoinformation* [online] 41. Disponível: <https://doi.org/10.1016/j.jag.2015.04.020>. Acesso: 25 abr. 2021.
- Lochhead, K., Lemay, V., Bull, G., Schwab, O., Halperin, J., 2018. Multivariate estimation for accurate and logically consistent forest-attributes maps at macroscales. *Canadian Journal of Forest Research* [online] 4. Disponível: <https://doi.org/10.1139/cjfr-2017-0221>. Acesso: 19 abr. 2020.
- Maschler, J., Bialic-Murphy, L., Wan, J., Andresen, L. C., Zohner, C. M., Reich, P. B., Luscher, A., Schneider, M. K., Müller, C., Moser, G., Duques, J. S., Schmidt, I. K., Bilton, M. C., Zhu, K., Crowther, T. W., 2022. Links across ecological scales: Plant biomass responses to elevated CO₂. *Global change biology* [online] 28. Disponível: <https://doi.org/10.1111/gcb.16351>. Acesso: 24 jan. 2024.
- Mikhaylov, A., Moiseev, N., Aleshin, K., Burkhardt, T., 2020. Global climate change and greenhouse effect. *Entrepreneurship and Sustainability Issues* [online] 7. Disponível: [https://doi.org/10.9770/jesi.2020.7.4\(21\)](https://doi.org/10.9770/jesi.2020.7.4(21)). Acesso: 24 mar. 2021.
- Meng, S., Pang, Y., Zhang, Z., Jia, W., Li, Z., 2016. Mapping aboveground biomass using texture indices from aerial photos in a temperate forest of Northeastern China. *Remote Sensing* [online] 8. Disponível: <https://doi.org/10.3390/rs8030230>. Acesso: 24 jun. 2021.
- Migolet, P., Goïta, K., Pambo, A. F. K., Mambimba, A. N., 2022. Estimation of the total dry aboveground biomass in the tropical forests of Congo Basin using optical, LiDAR, and radar data. *GIScience & Remote Sensing* 59, 431-460.
- Mohd Zaki, N. A., Abd Latif, Z., 2017. Carbon sinks and tropical forest biomass estimation: a review on role of remote sensing in aboveground-biomass modelling. *Geocarto International* [online] 32. Disponível: <https://doi.org/10.1080/10106049.2016.1178814>. Acesso: 13 fev. 2020.
- Monteith, A. R., Ulander, L. M. H., 2021. Temporal characteristics of P-band tomographic radar backscatter of a boreal forest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online] 14. Disponível: <https://doi.org/10.1109/JSTARS.2021.3050611>. Acesso: 2 ago. 2020.
- Moradi, F., Darvishsefat, A. A., Pourrahmati, M. R., Deljouei, A., Borz, S. A., 2022. Estimating aboveground biomass in dense Hyrcanian forests by the use of Sentinel-2 data. *Forests* [online] 13. Disponível: <https://doi.org/10.3390/f13010104>. Acesso: 25 jan. 2024.
- Narvaes, I. D. S., Santos, J. R. D., Conceição Bispo, P. D., Alencastro Graça, M. D., Guimarães, U. S., Gama, F. F., 2023. Estimating Forest Above-Ground Biomass in Central Amazonia Using Polarimetric Attributes of ALOS/PALSAR Images. *Forests* [online] 14. Disponível: <https://doi.org/10.3390/f14050941>. Acesso: 26 jan. 2024.
- Paul, S. S., Coops, N. C., Johnson, M. S., Krzic, M., Smukler, S. M., 2019. Evaluating sampling efforts of standard laboratory analysis and mid-infrared spectroscopy for cost effective digital soil mapping at field scale. *Geoderma* [online] 356. Disponível: <https://doi.org/10.1016/j.geoderma.2019.113925>. Acesso: 12 set. 2020.
- Pereira, L. O., Furtado, L. F. A., Novo, E. M. L. M., Sant'ana, S. J. S., Liesenberg, V., Silva, T. S. F. Multifrequency and full-polarimetric SAR

- assessment for estimating above ground biomass and Leaf Area Index in the Amazon Várzea Wetlands. *Remote Sensing* [online] 10. Disponível: <https://doi.org/10.3390/rs10091355>. Acesso: 10 set. 2020.
- Ploton, P., Barbier, N., Couteron, P., Antin, C. M., Ayyappan, N., Balachandran, N., Barathan, N., Bastin, J. F., Chuyong, G., Dauby, G., Droissart, V., Gastellu-Etchegorry, J. P., Kamdem, N. G., Kenfack, D., Libalah, M., Mofack II, G., Momo, S. T., Pargal, S., Petronelli, P., Proisy, C., Réjou-Méchain, M., Sonké, B., Texier, N., Thomas, D., Verley, P., Zebaze Dongmo, D., Berger, U., Péliissier, R., 2017. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote sensing of environment* [online] 200. Disponível: <https://doi.org/10.1016/j.rse.2017.08.001>. Acesso: 18 jul. 2021.
- Rocha, S. S., Pitombo, C. S., Salgueiro, A. R., 2016. Interpolação espacial de viagens urbanas por transporte coletivo através de amostra sistemática desagregada artificial. *Revista Brasileira de Cartografia* [online] 68. Disponível: <https://doi.org/10.14393/rbcv68n4-44277>. Acesso: 22 nov. 2020.
- Rocha, W. D. O., Pereira, A. M., Silva, A. E. D., Fraga, J. A., 2017. Estimativa de biomassa vegetal e sequestro de carbono no Parque Natural Municipal Flor do Ipê, Várzea Grande, MT. *Multitemas*, [online] 22. Disponível: <https://doi.org/10.20435/multi.v22i51.1284>. Acesso: 12 nov. 2020.
- Rodríguez-Veiga, P., Saatchi, S., Tansey, K., Balzter, H., 2016. Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sensing of Environment* 183, 265-281.
- Rudel, T. K., 2017. The dynamics of deforestation in the wet and dry tropics: a comparison with policy implications. *Forests* 8, 108.
- Salgado, A. P., Pimentel, L. A. D. S., Oliveira, M. M. B. D., Novi, J. C., 2017. O impacto nas variações das matrizes energéticas e uso da terra: estudo sobre a eficiência ambiental do G20. *REAd. Revista Eletrônica de Administração* (Porto Alegre) 23, 306-332.
- Santi, E., Paloscia, S., Pettinato, S., Fontanelli, G., Mura, M., Zolli, C., Maselli, F., Chiesi, M., Bottai, L., Chirici, G., 2017. The potential of multifrequency SAR images for estimating forest biomass in Mediterranean areas. *Remote Sensing of Environment* 200, 63-73.
- Santoro, M., Cartus, O., 2018. Research pathways of forest above-ground biomass estimation based on SAR backscatter and interferometric SAR observations. *Remote Sensing*, 10, 608.
- Scolforo, H. F., Scolforo, J. R. S., Mello, J. M. D., Mello, C. R. D., Morais, V. A., 2016. 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* 376, 24-35.
- Sharifi, A., Amini, J., 2015. Forest biomass estimation using synthetic aperture radar polarimetric features. *Journal of Applied Remote Sensing* [online] 82. Disponível: <https://doi.org/10.14358/PERS.83.1.41>. Acesso: 8 out. 2021.
- Sharma, P., Leigh, L., Chang, J., Maimaitijiang, M., Caffé, M., 2022. Above-ground biomass estimation in oats using UAV remote sensing and machine learning. *Sensors* [online] 22. Disponível: <https://doi.org/10.3390/s22020601>. Acesso: 26 jan. 2024.
- Shao, Z., Zhang, L., 2016. Estimating forest aboveground biomass by combining optical and SAR data: a case study in Genhe, Inner Mongolia, China. *Sensors* [online] 16. Disponível: <https://doi.org/10.3390/s16060834>. Acesso: 23 ago. 2021.
- Shao, Z., Zhang, L., Wang, L., 2017. Stacked sparse autoencoder modeling using the synergy of airborne LiDAR and satellite optical and SAR data to map forest above-ground biomass. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10, 569-5582.
- Shi, L., Liu, S., 2017. Methods of estimating forest biomass: A review. In: TUMULURU, J. S. (Ed.). *Biomass volume estimation and valorization for energy*. BoD–Books on Demand.
- Singh, C., Karan, S. K., Sardar, P., Samadder, S. R., 2022. Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis. *Journal of Environmental Management* [online] 308. Disponível: <https://doi.org/10.1016/j.jenvman.2022.114639>. Acesso: 26 jan. 2024.
- Sinha, S., Jeganathan, C., Sharma, L. K., Nathawat, M. S., 2015. A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology* 12, 1779-1792.
- Sodré, C. F. L., Silva, Y. J. A. D., Monteiro, I. P., 2016. Acidificação dos Oceanos: fenômeno,

- consequências e necessidades de uma governança ambiental global. *Revista Científica do Centro de Estudos em Desenvolvimento Sustentável da UNB* 1.
- Su, H., Shen, W., Wang, J., Ali, A., Li, M. 2020. Machine learning and geostatistical approaches for estimating aboveground biomass in Chinese subtropical forests. *Forest Ecosystems* [online] 7. Disponível: <https://doi.org/10.1186/s40663-020-00276-7>. Acesso: 25 jul. 2021.
- Su, Y., Guo, Q., Xue, B., Hu, T., Alvarez, O., TAO, S., Fang, J. Spatial distribution of forest aboveground biomass in China: Estimation through combination of spaceborne lidar, optical imagery, and forest inventory data. *Remote Sensing of Environment* [online] 173. Disponível: <https://doi.org/10.1016/j.rse.2015.12.002>. Acesso: 13 mar. 2021.
- Tamiminia, H., Salehi, B., Mahdianpari, M., Beier, C. M., Johnson, L., 2022. Mapping two decades of New York State forest aboveground biomass change using remote sensing. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14164097>. Acesso: 26 jan. 2024.
- Temesgen, H., Hoef, J. M. V., 2015. Evaluation of the spatial linear model, random forest and gradient nearest-neighbour methods for imputing potential productivity and biomass of the Pacific Northwest forests. *Forestry: An International Journal of Forest Research* [online] 88. Disponível: <https://doi.org/10.1093/forestry/cpu036>. Acesso: 27 out. 2021.
- Tian, L., Wu, X., Tao, Y., Li, M., Qian, C., Liao, L., Fu, W., 2023. Review of Remote Sensing-Based Methods for Forest Aboveground Biomass Estimation: Progress, Challenges, and Prospects. *Forests* 14, 1086.
- Turgut, R., Günlü, A., 2020. Estimating aboveground biomass using Landsat 8 OLI satellite image in pure Crimean pine (*Pinus nigra* JF Arnold subsp. *pallasiana* (Lamb.) Holmboe) stands: a case from Turkey. *Geocarto International* 37, 720-734.
- Turton, A. E., Augustin, N. H., Mitchard, E. T. A., 2022. Improving estimates and change detection of forest above-ground biomass using statistical methods. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14194911>. Acesso: 25 jan. 2024.
- Tymothy, D., Onisimo, M., Cletah, S., Adelabu, S., Tsitsi, B., 2016. Remote sensing of aboveground forest biomass: A review. *Tropical Ecology* 57, 125-132.
- Veronesi, F., Schillaci, C., 2019. Comparison between geostatistical and machine learning models as predictors of topsoil organic carbon with a focus on local uncertainty estimation. *Ecological Indicators* [online] 101. Disponível: <https://doi.org/10.1016/j.ecolind.2019.02.026>. Acesso: 07 out. 2022.
- Wai, P., Su, H., Li, M., 2022. Estimating aboveground biomass of two different forest types in myanmar from sentinel-2 data with machine learning and geostatistical algorithms. *Remote Sensing*, [online] 14. Disponível: <https://doi.org/10.3390/rs14092146>. Acesso: 24 jan. 2024.
- Wang, J., Du, H., Li, X., Mao, F., Zhang, M., Liu, E., Ji, J., Kang, F., 2021. Remote Sensing Estimation of Bamboo Forest Aboveground Biomass Based on Geographically Weighted Regression. *Remote Sensing* [online] 13. Disponível: <https://doi.org/10.3390/rs13152962>. Acesso: 07 out. 2022.
- Wang, J., Xiao, X., Bajgain, R., Starks, P., Steiner, J., Doughty, R. B., Chang, Q., 2019. Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. *ISPRS Journal of Photogrammetry and Remote Sensing* [online] 154. Disponível: <https://doi.org/10.1016/j.isprsjprs.2019.06.007>. Acesso: 26 out. 2020.
- Wang, S., Liu, C., Li, W., Jia, S., Yue, H., 2023. *International Journal of Applied Earth Observation and Geoinformation* [online] 122. Disponível: <https://doi.org/10.1016/j.jag.2023.103431>. Acesso: 25 jan. 2023.
- Wang, Y., Yue, T., Lei, Y., Du, Z., Zhao, M., 2016. Uncertainty of forest biomass carbon patterns simulation on provincial scale: a case study in Jiangxi Province, China. *Journal of Geographical Sciences* [online] 26. Disponível: <https://doi.org/10.1007/s11442-016-1286-z>. Acesso: 25 out. 2020.
- Yadav, B. K. V., Nandy, S., 2015. Mapping aboveground woody biomass using forest inventory, remote sensing and geostatistical techniques. *Environmental Monitoring and Assessment* [online] 187. Disponível: <https://doi.org/10.1007/s10661-015-4551-1>. Acesso: 25 out. 2020.
- Yang, Q., Su, Y., Hu, T., Jin, S., Liu, X., Niu, C., Liu, Z., Kelly, M., Wei, J., Guo, Q., 2022. Allometry-based estimation of forest

- aboveground biomass combining LiDAR canopy height attributes and optical spectral indexes. *Forest Ecosystems*, [online] 9. Disponível: <https://doi.org/10.1016/j.fecs.2022.100059>. Acesso: 25 jan. 2024.
- Yu, Y., Pan, Y., Yang, X., Wenyi, F., 2022. Spatial scale effect and correction of forest aboveground biomass estimation using remote sensing. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14122828>. Acesso: 25 jan. 2024.
- Zaki, N. A. M., Asri, A. M., Zulkiflee, N. I. M., Latif, Z. A., Razak, T. R., Suratman, M. N., 2023. Assessment of Forest Aboveground Biomass Estimation from SuperView-1 Satellite Image Using Machine Learning Approaches. In: *Concepts and Applications of Remote Sensing in Forestry*. Singapore: Springer Nature Singapore, 115-133.
- Zhao, J., Zhao, L., Chen, E., Li, Z., Xu, K., Ding, X., 2022. An improved generalized hierarchical estimation framework with geostatistics for mapping forest parameters and its uncertainty: a case study of forest canopy height. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14030568>. Acesso: 25 jan. 2024.
- Zheng, C., Abd-Elrahman, A., Whitaker, V., Dalid, C., 2022. Prediction of Strawberry Dry Biomass from UAV Multispectral Imagery Using Multiple Machine Learning Methods. *Remote Sensing* [online] 14. Disponível: <https://doi.org/10.3390/rs14184511>. Acesso: 24 jan. 2024.
- Zhu, Y., Liu, K., Myint, S. W., Du, Z., Li, Y., Cao, J., Liu, L., Wu, Z. 2020. Integration of GF2 optical, GF3 SAR, and UAV data for estimating aboveground biomass of China's largest artificially planted mangroves. *Remote Sensing* [online] 12. Disponível: <https://doi.org/10.3390/rs12122039>. Acesso: 03 dez. 2021.
- Zhu, X., Liu, D., 2015. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. *ISPRS Journal of Photogrammetry and Remote Sensing* [online] 102. Disponível: <https://doi.org/10.1016/j.isprsjprs.2014.08.014>. Acesso: 15 nov. 2021.