



ISSN:1984-2295

Revista Brasileira de Geografia Física

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



Distribuição da Biomassa vegetal e sequestro de carbono na sub-bacia do Rio Pirajibu no município de Sorocaba/SP

Jaciely Gabriela Melo da Silva¹, José Alberto Quintanilha², Carlos Henrique Grohmann³, Danilo Ribeiro da Costa⁴, José Mauro Santana da Silva⁵, José Douglas Monteiro da Costa⁶

¹ Mestranda no Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis (PPGPUR) na Universidade Federal de São Carlos (UFSCar), Rod. João Leme dos Santos, km 110 - SP-264. Bairro do Itinga - Sorocaba CEP 18052-780. jaciely.silva@estudante.ufscar.br (autor correspondente). ² Professor Associado Sênior na Divisão Científica de Gestão, Ciência e Tecnologia Ambiental do Instituto de Energia e Ambiente - IEE da Universidade de São Paulo. jaquinta@usp.br ³ Professor Associado de Geotecnologias do Instituto de Energia e Ambiente, Universidade de São Paulo, Brasil (IEE-USP). guano@usp.br ⁴ Dr. em Planejamento e Uso de Recursos Renováveis. Universidade Federal de São Carlos (UFSCar), Rod. João Leme dos Santos, km 110 - SP-264. Bairro do Itinga - Sorocaba CEP 18052-780. danilo.costa@ufscar.br ⁵ Professor Dr. no programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis. Universidade Federal de São Carlos (UFSCar), Rod. João Leme dos Santos, km 110 - SP-264. Bairro do Itinga - Sorocaba CEP 18052-780. josemauro@ufscar.br ⁶ Doutorando do Programa de Ciência Ambiental da Universidade de São Paulo - PROCAM/IEE/USP.

Artigo recebido em 14/11/2022 e aceito em 26/03/2023

RESUMO

A estimativa de biomassa, com base em dados de sensoriamento desempenha um importante papel a respeito da quantificação da matéria vegetal, tanto de florestas primárias quanto de florestas secundárias ou fragmentadas. Por isso, o objetivo central deste trabalho é mostrar a distribuição da biomassa vegetal e o fluxo de carbono na sub-bacia do rio Pirajibu em Sorocaba/SP. Como objetivo específico classificar os níveis de biomassa de acordo com o algoritmo de aprendizado de máquina Random Forest. As classes escolhidas para o treinamento foram: “Muito alta biomassa”, “alta biomassa”, “média biomassa”, “baixa biomassa” e “muito baixa biomassa”. Foram obtidas 100 amostras de treinamento. A classificação supervisionada foi realizada pelo método Random Forest, com 10 árvores de decisão e 5.000 de variáveis que foram selecionadas e treinadas. A classe muito alta biomassa foi encontrada em 4.833,34 ha (10,52%), a classe alta foi identificada em 8.425,94 ha (18,34%), a classe média biomassa em 12.026,28 ha (26,18%), a baixa biomassa em 11.881,05 ha (25,87%) e muito baixa biomassa em 8.753,80 ha (19,06%). Foi avaliada a acurácia da classificação, a previsão de acurácia total chegou em 84%. Para o índice CO2Flux, se obteve os valores de -0,43 para as áreas sem vegetação (área urbana), valores na faixa de 0,19 a 0,23 representam áreas de pastagem mais degradadas e com solo exposto, já os maiores valores de fluxo de CO₂ > 0,32 mostram uma maior concentração de estoque de carbono, são regiões com vegetação robusta e saudável. A distribuição da biomassa para as classes muito alta, alta e média pode ser ainda maior considerando outros reservatórios de carbono, como os reservatórios abaixo do solo. Palavras-chave: biomassa, sensoriamento remoto, random forest, CO2Flux.

Plant biomass distribution and carbon sequestration in the Pirajibu River sub-basin in the municipality of Sorocaba/SP

ABSTRACT

Biomass estimation, based on sensing data, plays an important role regarding the quantification of plant matter, both from primary forests and from secondary or fragmented forests. Therefore, the main objective of this work is to show the distribution of plant biomass and carbon flux in the Pirajibu River sub-basin in Sorocaba/SP. As a specific objective to classify the biomass levels according to the Random Forest machine learning algorithm. The classes chosen for training were: “Very high biomass”, “high biomass”, “medium biomass”, “low biomass” and “very low biomass”. 100 training samples were obtained. The supervised classification was performed by the Random method Forest, with 10 decision trees and 5,000 variables that were selected and trained. The very high biomass class was found in 4,833.34 ha (10.52%), the high class was identified in 8,425.94 ha (18.34%), middle class biomass in 12,026.28 ha (26.18%), low biomass in 11,881.05 ha (25.87%) and very low biomass in 8,753.80 ha (19.06%). The classification accuracy was evaluated, the total accuracy forecast reached 84%. For the CO2Flux index, values of -0.43 were obtained for areas without vegetation (urban area), values in the range of 0.19 at 0.23 represent more degraded pasture areas with exposed soil, whereas the higher values of CO₂ flux > 0.32 show a higher concentration of carbon stock, they are regions with robust and healthy vegetation. The biomass distribution for the very high, high, and medium classes can be even greater considering other carbon pools, such as the underground pools.

Keywords: biomass; remote sensing; random forest; CO2Flux.

Introdução

As florestas tropicais representam atualmente os biomas naturais de maior produtividade e variedade de espécies animais e vegetais, atuando como reguladores do clima do planeta, além de serem importantes fontes de recursos naturais que garantem a subsistência de diversas comunidades humanas. Contudo, uma importante função das florestas tropicais ao redor do mundo, que inclusive exerce influência sobre todos os benefícios acima citados, é o seu papel na ciclagem de carbono atmosférico, principalmente no que diz respeito à sua atuação enquanto sumidouros de carbono (Mitchard, 2018).

Estima-se que as florestas tropicais possuem capacidade de armazenagem média de um terço do carbono mantido na atmosfera, em um processo altamente dinâmico, capturando parte desse carbono sob a forma de CO₂ por meio da fotossíntese, e posteriormente liberando parte desse carbono por meio da respiração das plantas, animais, fungos e microrganismos desses ecossistemas (Mitchard, 2018). Por outro lado, o Relatório de Síntese do IPCC (AR6) mostra que as emissões de gases de efeito estufa continuaram a aumentar ao longo dos anos com contribuições históricas, contínuas e desiguais decorrentes das atividades humanas (IPCC, 2023).

Estimar a biomassa florestal é uma tarefa de relativa dificuldade, principalmente no que diz respeito a métodos que demandam um alto custo de capital e que sejam de alta precisão que possam cobrir grandes áreas, incluindo em escala global (Luo et al., 2019). Por exemplo, os métodos de amostragem em campo são, geralmente, trabalhosos, caros e possuem um potencial a serem invasivos; o sensoriamento remoto, por sua vez, representam meios menos invasivos, é prático e econômico (Luo et al., 2019), com a ressalva que não é sempre que o sensoriamento remoto será a melhor escolha, situações específicas exigem a precisão que somente o campo ou alternativas podem prover.

Atualmente, os métodos mais precisos para se estimar a biomassa florestal acima do solo têm sido a utilização de equações alométricas específicas das espécies e do local onde tal abordagem está sendo empregada, com base em parâmetros biométricos florestais medidos, como o diâmetro à altura do peito, fechamento da copa e densidade do caule (SU et al., 2020). Contudo, este método demanda tempo para a obtenção de dados em campo, fato este, que torna as informações de biomassa, muitas vezes, desatualizadas. Apesar do uso de equações alométricas específicas ser um método de alta precisão a nível regional, abordagens que utilizem apenas dados de campo

podem não ser suficientes para se estimar adequadamente a biomassa florestal, ao contrário de métodos que combinam dados de campo com informações auxiliares, como os dados de sensoriamento remoto por exemplo (Su et al., 2020).

Quando falamos de estimativa de biomassa florestal e o estoque de carbono em larga escala, o sensoriamento remoto desempenha um papel fundamental, pois tal método pode fornecer uma grande quantidade de dados de áreas extensas, além de permitir acesso a locais inacessíveis pelos métodos de amostragem de campo (Kumar e Mutanga, 2017).

Diante das vantagens e desvantagens do emprego tanto de imagens de alta resolução espacial, quanto de média ou grosseira resolução espacial, a combinação de dados de sensoriamento remoto óptico de diferentes escalas de resolução podem melhorar a precisão da estimativa de biomassa em escala nacional ou global, além de ser econômico, replicável e reduzir os requisitos de dados de campo para estimativa de biomassa e carbono, quando comparados com métodos de inventário baseados a amostragem das árvores presentes em uma determinada área (Koju et al., 2017).

A estimativa de biomassa, com base em dados de sensoriamento, desempenha um papel a respeito da quantificação da matéria vegetal, tanto de florestas primárias quanto de florestas secundárias ou fragmentadas, o que tem importantes implicações em relação ao manejo florestal, e consequentemente, a conservação e preservação ambiental. As ferramentas de sensoriamento remoto possibilitam a caracterização de áreas naturais ou manejadas, podendo ser utilizada também para extrapolar relações específicas, dependendo da consistência e estabilidade da estrutura do ecossistema (Guerini Filho et al., 2019).

Dentre as análises de sensoriamento remoto pode-se destacar as métricas dos índices de vegetação, esses índices de vegetação consistem em meios utilizados para monitorar e quantificar as distribuições espaciais de vegetação por meio da combinação de reflectância de objetos em diferentes comprimentos de onda, com o intuito de destacar uma particularidade da estrutura da vegetação (Polonio, 2015). Diversos trabalhos apresentaram precisão nas estimativas de biomassa florestal, superiores a 80% a partir da utilização de índices que minimizam as influências do solo e da atmosfera, como por exemplo, o índice de vegetação aprimorada (EVI) e o índice de diferença normalizada de borda vermelha (NDRE); e de

índices sensíveis à matéria senescente, como é o caso do índice de refletância de senescência das plantas (PSRI) (Guerini Filho et al., 2019).

Um dos primeiros produtos analíticos de sensoriamento remoto, o índice de vegetação de diferença normalizada (NDVI), é comumente utilizado para simplificar as complexidades relativas às imagens multiespectrais, e eficaz para expressar o status da vegetação e os atributos quantificados da vegetação, desde que suas capacidades e limitações sejam bem compreendidas (Huang et al., 2021). Este índice, é amplamente utilizado pois ele apresenta ótima correlação linear com a biomassa da vegetação, principalmente em áreas de boa cobertura vegetal (Silva et al., 2015). O NDVI, juntamente com outros índices como por exemplo, o índice de vegetação ajustado ao solo (SAVI), têm sido utilizados amplamente para estimar os parâmetros de áreas agrícolas, resultando em muitas conquistas como o desenvolvimento do índice de área foliar (LAI) (Yue et al., 2019).

Todavia, o uso de índices de vegetação para estimativa de biomassa teve o seu sucesso limitado, pois dentre as problemáticas relacionadas a estes índices, temos a sua saturação sob alta cobertura de dossel, além da perda de sensibilidade em determinados estágios de crescimento reprodutivo, apesar disso, a combinação de diferentes texturas de imagens com diferentes

índices de vegetação, possibilita a melhoria das estimativas de biomassa em condições de alta cobertura de dossel (Yue et al., 2019).

O objetivo central deste trabalho é mostrar a distribuição da biomassa vegetal e o fluxo de carbono na sub-bacia do rio Pirajibu. Como objetivo específico classificar os níveis de biomassa de acordo com o algoritmo de aprendizado de máquina *Random Forest*.

Material e métodos

Caracterização da área de estudo

A área de estudo escolhida foi a sub-bacia do Rio Pirajibu que se sobrepõe aos municípios de Sorocaba, Itu, Alumínio e Mairinque no Estado de São Paulo. Localizado nas coordenadas UTM: 23k 262500 m E/ 7403460 m N somando uma área total de 45.920 ha. É uma sub-bacia importante para a região, pois, contribui para a produção e abastecimento de água do município e está inserida em uma região prioritária para a implantação do programa de Pagamentos por Serviços Ambientais (PSA) (Corrêa, et al, 2016) .

Na figura 1 é possível visualizar o mapa da área de estudo e sua localização com maior detalhamento.




Figura 1: Mapa da área de estudo

Pré-processamento das imagens Landsat

As imagens foram obtidas via catálogo do INPE – Instituto Nacional de Pesquisas Espaciais

Silva, J. G. M. et al.

(<http://www.dgi.inpe.br/catalogo/>), e os parâmetros para a busca das imagens foram:

Satélite: Landsat 8, instrumento: OLI, data início: 01/01/2021, data fim: 25/04/2022, país: Brasil, estado: São Paulo, município: Sorocaba. A imagem datada em 12 de dezembro de 2021 foi selecionada por ter menor cobertura de nuvens para a área do projeto. Após o download das imagens, foi realizado o pré-processamento das imagens com o plugin Semi-Automatic Classification Plugin (SCP). As imagens foram adicionadas no “Band set”, e na aba “clip multiple rasters” as imagens foram recortadas para a área de interesse.

Logo depois foram feitas as correções de reflectância das imagens de acordo com a seguinte equação: $\rho\lambda = M_p * Q_{cal} + A_p$ (USGS, 2013).

Em que:

$\rho\lambda$ = Reflectância Planetária

M_p = Fator de reescalonamento multiplicativo específico da banda dos metadados do Landsat.

A_p = Fator de redimensionamento aditivo específico da banda dos metadados do Landsat.

Q_{cal} = Valores de pixel de produto padrão quantizados e calibrados (DN).

Geração dos Índices sPRI, NDVI e o CO2Flux

O Índice de Reflectância Fotoquímica (PRI) é sensível às mudanças nos pigmentos carotenóides na folhagem. Tais pigmentos são indicativos da eficiência do uso da luz fotossintética ou da taxa de dióxido de carbono armazenada pela folhagem por unidade de energia absorvida (Almeida e Rocha, 2018).

Esse índice é usado para avaliar estresse ou saúde da vegetação. Os valores variam entre -1 e 1, e valores comuns para vegetação sadia ficam entre -0,2 e 0,2 (GAMON et al., 1992). Os dados do PRI devem ser reescalados para valores positivos, gerando um novo índice sPRI, que possui o mesmo significado que o PRI (equação $sPRI = (PRI + 1) / 2$)

$$PRI = (R1 - R2) / (R1 + R2) \quad (Eq.1)$$

Em que:

R1 = Reflectância relativa à banda 2 (região espectral da região do azul) do satélite Landsat 8

R2 = Reflectância relativa à banda 3 (região espectral da região do verde do satélite Landsat 8).

Proposto por Rouse et al (1973), o NDVI é a normalização do índice Razão Simples determinando o intervalo -1 a 1 aos seus valores (Ponzoni, Shimabukuro, 2009). Os maiores valores de NDVI relacionam-se às áreas de vegetação com maior vigor. Enquanto os menores valores representam as áreas de vegetação estressada ou

sem vegetação (Viganó et al., 2011).

$$NDVI = (IV - V) / (IV + V) \times 100 \quad (Eq.2)$$

Em que:

IV é o fluxo radiante refletido no Infravermelho próximo

V é o fluxo radiante refletido no vermelho da região do visível

O CO2Flux é a integração do índice de reflectância fotoquímica (Rahman et al., 2000). Esse índice correlaciona características de detecção remota hiperespectrais aos fluxos de CO2 de diferentes tipos de cobertura vegetal na superfície. Representa o vigor da vegetação fotossinteticamente ativa, o que torna possível integrar as feições de absorção decorrentes do sequestro de carbono (Baptista, 2003; Polonio, 2015).

$$CO2Flux = (NDVI * sPRI) \quad (eq.3)$$

Classificação

O treinamento e a classificação das imagens foram realizados utilizando o plugin Semi-Automatic Classification Plugin (SCP) no QGIS versão 3.24. Foi realizado um recorte em aproximadamente 30% da área de estudo em uma das áreas que foi considerada visualmente homogênea em todos os seus aspectos e se optou pela escolha de uma região específica ao invés de uma amostragem aleatória na área de estudo total.

As classes escolhidas para o treinamento foram: “Muito alta biomassa” cuja vegetação é extremamente densa, “alta biomassa” com vegetação densa, “média biomassa” compostas por áreas que possuem vegetação nativa com algumas falhas de cobertura, “baixa biomassa” que são áreas com pouca vegetação, com predomínio de pastagem e “muito baixa biomassa” que são áreas sem vegetação (áreas urbanas e estradas), somando ao todo 5 classes. Foram desenhadas 100 amostras de treinamento. a figura 2 observa-se a descrição das classes com as imagens de referência.



Classe	Imagem Google Earth (usada na avaliação da acurácia)	Composição 543 (usada para o treinamento)	Descrição
Muito alta biomassa			Vegetação extremamente densa
Alta biomassa			Vegetação densa
Média biomassa			Áreas de vegetação com algumas falhas na cobertura
Baixa biomassa			Áreas de pasto, com poucas gramíneas
Muito baixa biomassa			Área sem vegetação (área urbana, estradas)

Figura 2: Descrição das Classes

Classificação supervisionada pelo método Random Forest

O Random Forest é um algoritmo de aprendizado de máquina que é definido por Breiman (2001) como uma combinação de várias árvores de decisão de forma aleatória independentemente do comportamento das amostras.

As árvores são criadas desenhando um subconjunto de amostras de treinamento por meio de substituição, podendo uma amostra ser selecionada várias vezes ou não (Breiman,2001; Belgiu & Drăguț, 2016). Dois parâmetros precisam ser selecionados para produzir o random forest, primeiro o número de árvores de decisão a serem geradas (Ntree) e o segundo, o número de variáveis a serem selecionadas e treinadas (Mtry)




Figura 3: Pontos para verificação da acurácia

(Breiman, 2001; Belgiu & Drăguț, 2016). Neste trabalho foram usadas $N_{tree} = 10$ e $M_{try} = 5.000$.

Avaliação da Acurácia

O AcATaMa é um plugin disponibilizado no QGIS para Avaliação de acurácia de mapas temáticos (Llano, 2022). Este plugin foi criado de acordo com a metodologia de Olofsson et al. (2014).

O tamanho geral da amostra e o número de pontos para cada estrato são calculados de acordo com a proporção da área de cada estrato no mapa (W_i), o erro padrão da precisão geral estimada e o desvio padrão de cada estrato. A área estimada para cada classe ou estrato e o erro padrão da área estimada são dados pela equação de Olofsson et al. (2014). Na figura 3 observa-se a distribuição dos pontos para verificação da acurácia e o quadro com as informações do número de amostras para cada classe.

áreas sem vegetação (áreas urbanas, solo exposto) e com pouca vegetação e 0,58 para as áreas com vegetação em diferentes estágios sucessionais. Valores próximos de 1 mostram uma vegetação sadia. Analisando a figura 4, os valores de NDVI encontrados demonstram maior densidade de vegetação nas mesmas regiões que obtiveram-se os maiores valores de sPRI, os autores Almeida e Rocha (2018) enfatizaram que a capacidade fotossintética está diretamente ligada a uma cobertura de vegetação mais densa, sendo que, os índices sPRI e NDVI alocados espacialmente nas mesmas áreas da região do estudo.

Os valores de NDVI variaram de -1 para as áreas pobres em vegetação e 0,92 para áreas ricas em vegetação, a média do NDVI foi de 0,61 e o desvio padrão foi de 0,19. Cherlinka (2020) aponta que os valores positivos entre 0,5 e 1,0 são considerados altos, vegetação esparsa possui um valor de 0,2 e 0,5 e solo exposto possuem valores ainda mais baixos entre 0,1 e 0,2, podendo alcançar outros valores dependendo do tipo de solo.




Figura 4: Índices sPRI, NDVI e CO2Flux

Neste estudo foram utilizadas imagens Google Satélite com resolução espacial menor e melhor em comparação a resolução do Landsat 8, por meio do plugin Quick Map Services versão 0.19.29.

Resultados e discussão

O valor médio de sPRI foi de 0,51 com desvio padrão de 0,009 e variaram de 0,45 para

Analisando o índice CO2Flux, se obteve os valores de -0,43 para as áreas sem vegetação (área urbana), valores na faixa de 0,19 a 0,23 representam áreas de pastagem mais degradadas e com solo exposto, já os maiores valores de fluxo de CO₂ > 0,32 mostram uma maior concentração de estoque de carbono, são regiões com vegetação robusta e saudável. Almeida e Rocha (2018) e Polônio (2015) também

obtiveram resultados parecidos. A média do índice foi de 0,25 e o desvio padrão foi de 0,07.

Na figura 5 observa-se o mapa classificado com os níveis de biomassa da sub-bacia. Ao norte e noroeste da sub-bacia predominam-se áreas com baixa (classe 4) e muito baixa biomassa (classe 5), o que pode ser relacionada com a quantidade de zonas urbanas, estradas, áreas em construção ou pastos (pecuária) com pouca ou sem gramíneas.

Na porção central da sub-bacia é possível enxergar áreas com média (classe 3) e baixa biomassa (classe 4), o que é compreensível, nessa área se encontram uma quantidade elevada de imóveis rurais em comparação a toda bacia de acordo com o observado no Sistema Nacional de Cadastro Ambiental Rural (SICAR, 2023). Ao sul da área de estudo verificam-se regiões com alta (classe 2) e muito alta biomassa (classe 1), são áreas com vegetação nativa densa e silvicultura (exemplo: plantio de eucalipto).

A classe muito alta biomassa foi encontrada em 4.833,34 ha (10,52%), a classe alta foi identificada em 8.425,94 ha (18,34%), a classe média biomassa em 12.026,28 ha (26,18%), a baixa biomassa em 11.881,05 ha (25,87%) e muito baixa biomassa em 8.753,80 ha (19,06%).

Matriz de confusão

A matriz de confusão fornece informações sobre a magnitude dos erros de classificação que permitem um ajuste no estimador de área (Olofsson et al., 2013). Por meio AcATaMa foi avaliada a acurácia da classificação, a previsão de acurácia total chegou em 84%, o erro global foi de 16%, erro de quantidade foi de 24% e erro de alocação foi de 8% conforme figura 7.

A classe alta biomassa (2) teve o pior resultado em relação às outras classes, a acurácia individual foi de 74%. Durante a avaliação notou-se que o classificador diversas vezes ficou confuso




Figura 5: Intervalo de classes.

	1 - Muito alta biomassa	2 - Alta biomassa	3 - Média biomassa	4 - Baixa biomassa	5 - Muito baixa biomassa	Total	Acurácia do usuário	Erros de comissão	Erros de quantidade	Área total (ha)	Wi
1 - Muito alta biomassa	47	1	1	0	1	50	94%	6%	0%	4.833,34	0,11
2 - Alta biomassa	3	61	6	1	0	71	85%	15%	1%	8.425,94	0,18
3 - Média biomassa	0	16	78	7	1	102	76%	24%	1%	12.026,28	0,26
4 - Baixa biomassa	0	2	6	87	5	100	87%	13%	13%	11.881,05	0,26
5 - Muito baixa biomassa	1	2	4	6	60	73	82%	18%	9%	8.753,80	0,19
Total	51	82	95	101	67	396					
Acurácia do produtor	92%	74%	82%	86%	89%						
Erros de Omissão	8%	26%	18%	14%	11%						

Tabela 1: Matriz de confusão

e alocou amostras na classe média (erro de omissão em 26% e erro de comissão de 24%) . A classe muito alta biomassa (1) foi a classe com o melhor resultado individual, obteve a acurácia individual de 92% com erro de omissão de 8% e erro de comissão de 6%.

As diferenças entre o mapa de classificação de biomassa e o índice CO2Flux são sutis, em áreas urbanas, onde teve um predomínio da classe “muito baixa biomassa (5) são áreas onde o índice CO2Flux obteve um menor valor.

Conclusões

Neste artigo buscou-se entender como a biomassa vegetal e o fluxo de carbono se distribuíram na sub-bacia do rio Pirajibu. Além de classificar os níveis de biomassa de acordo com o algoritmo de aprendizado de máquina Random Forest.

De modo geral, os objetivos foram atendidos, foi realizada a distribuição da biomassa e a classificação da biomassa como pretendido inicialmente. A metodologia foi suficiente para atender os objetivos propostos, entretanto, como limitação deste estudo, foi identificado que a quantificação do carbono é necessária para estimar o estoque de carbono na sub-bacia e assim, complementar esse estudo. Como um dos objetivos propostos, o cálculo do fluxo de carbono foi feito por meio do índice CO2Flux. Neste trabalho, os valores para o potencial de sequestro de carbono foram significativos em relação aos outros índices e chegou a resultados semelhantes em outros trabalhos, como o de Polônio (2015).

Destaca-se ainda que a sub-bacia do Rio Pirajibu é uma bacia com características próprias e que os resultados encontrados dificilmente serão aplicados a outras bacias, contudo, a metodologia pode ser replicada para qualquer região de interesse.

Olhando para os resultados, a distribuição da biomassa para as classes muito alta, alta e média têm o potencial de ser maior considerando outros reservatórios de carbono, como os reservatórios acima e abaixo do solo (como por exemplo: raízes, serapilheira, madeira morta, carbono orgânico no solo). Dentro desse contexto, os estudos que têm por intuito estimar a biomassa florestal são de suma importância à medida que auxiliam a diminuir a incerteza em relação aos reservatórios de carbono das áreas florestadas, e consequentemente, ampliam o conhecimento acerca do ciclo global do carbono, além de contribuir para a tomada de decisões quanto ao manejo florestal (Silveira, 2010; Cao et al., 2016).

Agradecimentos

Ao PROCAM/IEE/USP, pelos conhecimentos adquiridos na disciplina “Uso de Classificadores e Análise de Imagens de Sensoriamento Remoto: Aplicações Ambientais” e ao CNPq pelas bolsas de pesquisa do Dr. José Alberto Quintanilha (305188/2020-8) e Dr. Carlos Henrique Grohmann (311209/2021-1). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 ao Programa de Pós-Graduação em Ciência Ambiental (PROCAM).

Referências

- Almeida, J. R. R.; Rocha, K. S. 2018. Aplicação dos índices de vegetação NDVI, PRI, e CO2flux na caracterização da cobertura vegetativa da área de proteção ambiental Raimundo Irineu Serra. Anais 7º Simpósio de Geotecnologias no Pantanal, Jardim, MS. [online]. Disponível em: <https://www.geopantanal.cnptia.embrapa.br/Anais-Geopantanal/pdfs/p151.pdf>. Acesso em: 06 jul. 2022.
- Baptista, G. M. M. 2003. Validação da Modelagem de sequestro de carbono para ambientes tropicais de cerrado, por meio de dados Aviris e Hyperion. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 11., Belo Horizonte. Anais. São José dos Campos: INPE, 2003. Artigos, p. 1037-1044. [online]. Disponível em: http://marte.dpi.inpe.br/col/lid.inpe.br/sbsr/2002/09.07.21.45/doc/10_002.pdf. Acesso em: 12 de jul.2022.
- Belgiu, M.; DRĂGUŢ, L. 2016. Random Forest in remote sensing: a review of applications and future directions. ISPRS Journal of Photogrammetry and Remote Sensing, [S.L.], v. 114, p. 24-31, abr. Elsevier BV. [online]. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2016.01.011>. Acesso em: 12 de jul.2022.
- Breiman, L. 2001. Random Forests. Machine Learning 45, 5–32. [online]. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acesso em: 12 de jul.2022.
- 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, v. 178, p. 158-171.
- Corrêa, C, J. P.; Tonello, K. C.; Franco, F. S. 2016. Análise hidroambiental da microbacia do Pirajibu-Mirim, Sorocaba, SP, Brasil. Ambiente

- e Água - An Interdisciplinary Journal Of Applied Science, v. 11, n. 4. Instituto de Pesquisas Ambientais em Bacias Hidrográficas (IPABHI). [online]. Disponível em: <http://dx.doi.org/10.4136/ambi-agua.1969>. Acesso em: 18 de jun.2022.
- Cherlinka, Vasyi. 2020. NDVI FAQ: Tudo O Que você precisa saber sobre o índice. Disponível em: <https://eos.com/pt/blog/ndvi-faq/>. Acesso em: 21 out. 2022.
- Dittmann, S.; Thiessen, E.; Hartung, E. 2017. Applicability of different non-invasive methods for tree mass estimation: A review. *Forest Ecology and Management*, v. 398, p. 208-215.
- Gamon, J. A.; Penuelas, J.; Field, C. B. A. 1992. narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, v.41, n.1, p.35-44.
- Guerini Filho, M.; Kuplich, T. M.; Quadros, F. L. F. D. 2020. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. *International Journal of Remote Sensing*, v. 41, n. 8, p. 2861-2876.
- Huang, S.; Tang, L.; Hupy, J. P.; Wang, Y.; Shao, G. 2021. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, v. 32, n. 1, p. 1-6.
- INPE - Instituto Nacional de Pesquisas Espaciais. 2022. LANDSAT. Disponível em: <http://www.dgi.inpe.br/documentacao/satelites/landsat>. Acesso em: 16 jun. 2022.
- IPCC. 2023. Climate Change 2023: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press. Disponível em: https://report.ipcc.ch/ar6syr/pdf/IPCC_AR6_S_YR_SPM.pdf, Acesso em: 30 mar. 2023.
- Koju, U.; Zhang, J.; Gilani, H. 2017. Exploring multi-scale forest above ground biomass estimation with optical remote sensing imageries. In: *IOP Conference Series: Earth and Environmental Science*. IOP Publishing, p. 012011.
- Kumar, L.; Mutanga, 2017. O Remote sensing of above-ground biomass. *Remote Sensing*, v. 9, n. 9, p. 935.
- Llano, X. C. .2022. AcATaMa - QGIS plugin for Accuracy Assessment of Thematic Maps, version 19.1. Disponível em: <https://plugins.qgis.org/plugins/AcATaMa/>.
- Lu, D.; Chen, Q.; Wang, G.; Liu, L.; Li, G.; Moran, E. 2016. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth*, v. 9, n. 1, p. 63-105.
- Luo, S.; Wang, C.; Xi, X.; Nie, S.; Fan, X.; Chen, H.; Ma, D.; Liu, J.; Zou, J.; Lin, Y.; Zhou, G. 2019. Estimating Forest aboveground biomass using small-footprint full-waveform airborne LiDAR data. *International Journal of Applied Earth Observation and Geoinformation*, v. 83, p. 101922.
- Malhi, Y. 2012. The productivity metabolism and carbon cycle of tropical forest vegetation. *Journal of Ecology*, v. 100, n. 1, p. 65-75.
- Mitchard, E. T. A. 2018. The tropical forest carbon cycle and climate change. *Nature*, v. 559, n. 7715, p. 527-534.
- Olofsson, Pontus; Foody, Giles M.; Herold, Martin; Stehman, Stephen V.; Woodcock, Curtis E.; Wulder, Michael. 2013. A Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, 129, p. 122-131. Elsevier BV. [online]. Disponível: <https://doi.org/10.1016/j.rse.2012.10.031>. Acesso em: 18 de jun.2022.
- Olofsson, Pontus; Foody, Giles M.; Herold, Martin; Stehman, Stephen V.; Woodcock, Curtis E. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, v. 148, p. 42-57. Elsevier BV. [online]. Disponível em: <http://dx.doi.org/10.1016/j.rse.2014.02.015>. Acesso em: 18 de jun.2022.
- Polônio, V. D. 2015. Índices de vegetação na mensuração do estoque de carbono em áreas com cana-de-açúcar. 73 f. Dissertação (mestrado). Botucatu. Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências Agrônômicas.
- Polônio, V. D. 2015. Avaliação temporal do sequestro de carbono por meio de imagens orbitais na região de Botucatu-SP. *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, Brasil. [online]. Disponível em: <http://www.dsr.inpe.br/sbsr2015/files/p0797.pdf> f. Acesso em: 06 jul. 2022.
- Ponzoni, F. J.; Shimabukuro, Yosio Edemir. 2009. Sensoriamento Remoto no Estudo da Vegetação. 1ª edição. Parêntese. São José dos Campos.
- Rahman, A.F.; Gamon, J.A.; Fuentes, D.A.; Roberts, D.; Prentiss, D.; Qiu, H. 2000. Modeling CO2 flux of boreal forests using narrow-band indices from AVIRIS imagery.

- AVIRIS Workshop, JPL/NASA, Pasadena, California.
- Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W.1973. Monitoring vegetation systems in the great plains with ERTS. In Earth Resources Technology Satellite- 1 Symposium,3 Proceedings. 309-317.
- SICAR. 2023. Consulta Pública. Disponível em: <https://www.car.gov.br/publico/imoveis/index>. Acesso em: 30 mar. 2023.
- Silva, D. A. A. D.; Santi, A. L.; Santos, M. S. D.; Dal Bello, R. A. M.; Martini, R. T. 2015. Uso de Índice de Vegetação na Estimativa da Produção de Biomassa de Plantas de Coberturas do Solo. Enciclopédia Biosfera, v. 11, n. 22.
- Silveira, P. 2010. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. Floresta, 40, 4.
- 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 7, 1-20.
- Su, Y.; Guo, Q.; Xue, B.; Hu, T.; Alvarez, O.; Tao, S.; Fang, J. 2016. Spatial distribution of forest aboveground biomass in China: Estimation through combination of spaceborne lidar, optical imagery, and forest inventory data. Remote Sensing of Environment 173, 187-199.
- Urbazaev, M.; Thiel, C.; Cremer, F.; Dubayah, R.; Migliavacca, M.; Reichstein, M.; Schimmlus, C. , 2018. Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. Carbon Balance and Management 13, 1-20.
- USGS - United States Geological Survey.2022. Using the USGS Landsat Level-1 Data Product. Disponível em: <https://www.usgs.gov/landsat-missions/using-usgs-landsat-level-1-data-product>. Acesso em: 15 de out. 2022.
- Viganó, Heloise Amadori et al. 2011. Análise do desempenho dos Índices de Vegetação NDVI e SAVI a partir de imagem Aster. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.14.17.45/doc/p1364.pdf>. Acesso em: 06 jul. 2022.
- Yue, J.; Yang, G.; Tian, Q.; Feng, H.; Xu, K.; Zhou, C. 2019. Estimate of winter-wheat above-ground biomass based on UAV ultrahigh-ground-resolution image textures and vegetation indices. ISPRS Journal of Photogrammetry and Remote Sensing 150, 226-244.