

**Estimativa do potencial de sequestro de carbono em Reserva Particular de Patrimônio Natural do Bioma Amazônia por meio de Redes Neurais Convolucionais**

**Michael Buoro**

Trabalho de Conclusão de Curso  
MBA em Inteligência Artificial e Big Data

**UNIVERSIDADE DE SÃO PAULO**  
**Instituto de Ciências Matemáticas e de Computação**

---

Estimativa do potencial de  
sequestro de carbono em Reserva  
Particular de Patrimônio Natural do  
Bioma Amazônia por meio de Redes  
Neurais Convolucionais

***Michael Buoro***

---



Michael Buoro

## Estimativa do potencial de sequestro de carbono em Reserva Particular de Patrimônio Natural do Bioma Amazônia por meio de Redes Neurais Convolucionais

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Luiz Otavio Murta Junior

USP - São Carlos

2022

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi  
e Seção Técnica de Informática, ICMC/USP,  
com os dados inseridos pelo(a) autor(a)

B943e Buoro, Michael  
Estimativa do potencial de sequestro de carbono  
em Reserva Particular de Patrimônio Natural do Bioma  
Amazônia por meio de Redes Neurais Convolucionais /  
Michael Buoro; orientador Prof. Dr. Luiz Otavio  
Murta Junior. -- São Carlos, 2022.  
38 p.

Trabalho de conclusão de curso (MBA em  
Inteligência Artificial e Big Data) -- Instituto de  
Ciências Matemáticas e de Computação, Universidade  
de São Paulo, 2022.

1. sequestro de carbono. 2. redes neurais  
convolucionais. 3. sensoriamento remoto. I. Murta  
Junior, Prof. Dr. Luiz Otavio, orient. II. Título.

## AGRADECIMENTOS

Ao Prof. Dr. Luiz Otavio Murta Junior, por todo o apoio e orientação para o bom andamento deste trabalho e especialmente por nossas conversas nas tardes de sexta-feira, tão necessárias durante os longos meses de distanciamento por conta da pandemia.

A Amazônia é o ‘Tesouro da Terra’ que vem executando a exuberante sinfonia de convivência e harmonia entre a natureza e o homem desde o mais remoto passado. A Amazônia é a ‘Casa da Vida’ que sustenta a Terra e a humanidade, criando estabilidade no clima do planeta.

Daisaku Ikeda (2000)

## RESUMO

**BUORO, M. Estimativa do potencial de sequestro de carbono em Reserva Particular do Patrimônio Natural do Bioma Amazônia por meio de Redes Neurais Convolucionais.** 2022. 52 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2022.

Devido às mudanças ambientais e climáticas causadas pela redução de áreas florestais, é crescente a necessidade de instrumentos de aferição, que possibilitem a análise dos biomas e sua capacidade de captura de carbono (CO<sub>2</sub>) da atmosfera. Existem atualmente técnicas de análise de biomas, entretanto poucas fazem uso simultâneo de imagens de satélites e métodos de inteligência artificial. O presente trabalho pretende estimar o potencial de sequestro de carbono por reflorestamento no Bioma Amazônia, levando em consideração características fitossociológicas e de imagens. A área compreende a Reserva Particular de Patrimônio Natural Dr. Daisaku Ikeda que possui 52 hectares. No período entre 2020 e 2025, dez mil mudas estão sendo e serão plantadas. Espera-se que esse plantio contribua com a neutralização de aproximadamente 1,6 mil toneladas de Carbono (CO<sub>2</sub>). As mudas estão distribuídas entre mais de 50 espécies nativas e são georreferenciadas. Estudos indicam que as árvores tropicais sequestram 312 Kg de CO<sub>2</sub> ao longo de 20 anos, ou seu tempo de crescimento. Portanto a contribuição pretendida neste trabalho é o desenvolvimento e a validação de um instrumento de análise e medidas de capturas de carbono através de imagens de frações florestais.

Palavras-chave: Sequestro de carbono; Redes neurais convolucionais; Sensoriamento remoto.



## ABSTRACT

**BUORO, M. Estimation of the carbon capture potential in a Private Reserve of Natural Heritage of the Amazon Biome through Convolutional Neural Networks.** 2022. 52 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2020.

Due to the environmental and climate changes caused by the reduction of forested areas, there is a growing need for measuring instruments that allow for the analysis of biomes and their capacity to capture carbon (CO<sub>2</sub>) from the atmosphere. Although there are currently biome analysis techniques, few use simultaneously satellite images and artificial intelligence methods. The present work intends to estimate the potential for carbon capture by reforestation in the Amazon Biome, considering phytosociological and imaging characteristics. The area comprises the Dr. Daisaku Ikeda Private Natural Heritage Reserve, which has 52 hectares. Between 2020 and 2025, ten thousand seedlings are being and will be planted. It is expected that this planting will contribute to the neutralization of approximately 1.6 thousand tons of carbon (CO<sub>2</sub>). The seedlings are distributed among more than 50 native species and are georeferenced. Studies indicate that tropical trees sequester 312 kg of CO<sub>2</sub> over 20 years, i.e., their growing time. Therefore, the intended contribution in this work is the development and validation of an instrument for analyzing and measuring carbon capture through images of forest fractions.

**Keywords:** Carbon capture; Convolutional Neural network; Remote sensing.

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>11</b>
<b>2 REVISÃO BIBLIOGRÁFICA.....</b>	<b>12</b>
2.1 Inventário florestal.....	13
2.2 Sequestro de carbono.....	13
2.3 Uso de software especializado.....	15
2.4 Uso de aprendizado de máquina.....	16
2.5 Uso de redes neurais artificiais.....	17
2.6 Uso de aprendizagem profunda.....	18
2.7 Uso de redes convolucionais.....	19
2.8 Uso de sensoriamento remoto.....	21
2.9 Índices de vegetação.....	21
2.10 Considerações finais.....	22
<b>3 METODOLOGIA PROPOSTA E DESENVOLVIMENTO.....</b>	<b>23</b>
3.1 Características da área de estudo.....	24
3.2 Amostragem utilizada no estudo.....	25
3.3 Cálculo da biomassa.....	26
3.4 Cálculo dos índices de vegetação.....	27
3.5 Treinamento da rede neural.....	29
<b>4 RESULTADOS E DISCUSSÃO.....</b>	<b>31</b>
<b>5 CONCLUSÃO.....</b>	<b>36</b>
<b>REFERÊNCIAS.....</b>	<b>37</b>

## 1 INTRODUÇÃO

Observa-se que as referências existentes sobre o tema, mesmo as utilizadas para o Bioma Amazônia são provenientes de estudos de outros biomas, como por exemplo a Mata Atlântica. RODRÍGUEZ (2015), cita em seu trabalho sobre as referências de estudos anteriores, que por causa da influência que a localização geográfica e a composição florística têm na taxa de sequestro de carbono, foram levantados alguns estudos com valores para captura de CO<sub>2</sub> por reflorestamento na região da Mata Atlântica próximo ao Estado do Rio de Janeiro, São Paulo ou semelhante, utilizando espécies nativas. Segundo o autor, os valores do Painel Intergovernamental para Mudanças Climáticas - IPCC, para a taxa de captura de carbono em florestas tropicais naturais da América do Sul é subdividido por período, sendo considerada uma taxa para áreas de até 20 anos e outra para áreas em que o plantio florestal possui mais de 20 anos. Assim para o primeiro período a taxa calculada a partir dos parâmetros determinados é de 7,0829 tC/ha/ano ou 25,9942 tCO<sub>2</sub>/ha/ano; já para o segundo período, esta taxa é de 1,9960 tC/ha/ano ou 7,3253 tCO<sub>2</sub>/ha/ano. Assim, considerando qualquer projeto a ser desenvolvido que dure 20 anos, seriam capturados cerca de 519.884 tCO<sub>2</sub>/ha (RODRÍGUEZ, 2015). Os relatórios do IPCC, assim como outros estudos da área, recomendam que sejam desenvolvidos valores mais específicos por região a ser analisada. Dessa forma, a motivação de realizar a presente pesquisa, está em fazer uso de ferramentas de Inteligência Artificial para contribuir com uma melhor compreensão do comportamento típico do Bioma Amazônia onde devido ao clima e outras particularidades, as árvores crescem e florescem mais rapidamente e prestam um serviço melhor à natureza que em qualquer outra região. No Instituto Soka Amazônia, foco dessa pesquisa, no período entre 2020 e 2025, dez mil mudas de espécies nativas estão sendo plantadas. Espera-se que esse plantio contribua com a neutralização de aproximadamente 1,6 mil toneladas de Carbono (CO<sub>2</sub>). As mudas estão distribuídas entre mais de 50 espécies nativas e são georreferenciadas. Estudos indicam que as árvores tropicais sequestram 312 Kg de CO<sub>2</sub> ao longo de 20 anos, ou seu tempo de crescimento. Espera-se que a presente pesquisa, possa contribuir também com esse objetivo do Instituto. A pesquisa propõe a rotulação de um conjunto relativamente pequeno de indivíduos arbóreos e que o algoritmo aprenda a caracterizar estes elementos, sendo capaz de identificar padrões de acordo com características fitossociológicas e de imagens. Para o escopo desse trabalho, utiliza-se a metodologia de cálculo do IPCC (2006).

## 2 REVISÃO BIBLIOGRÁFICA

Este capítulo se inicia descrevendo de forma sucinta, a combinação a partir dos dados de inventário florestal com uma equação alométrica adequada para a região de estudo, como forma de estimar a quantidade de carbono em um reflorestamento. Além da alometria, metodologias para o cálculo do sequestro de carbono, como as metodologias do INPE e do IPCC, são abordadas. É apresentado o uso de software especializado que faz a combinação de imagens com uma tabela de parâmetros para estimar o potencial de sequestro de carbono. São trazidos casos com aplicação de Inteligência Artificial para uso florestal, utilizando algoritmos como Random Forest e casos em que foram treinadas redes neurais como classificadores. A aprendizagem profunda que tem sido utilizada com sucesso em aplicações comerciais desde os anos 90 e sua evolução, como as EfficientNets. Descreve as redes convolucionais, integrando-se à Aprendizagem Profunda, e que têm sido extremamente bem-sucedidas em aplicações práticas. O capítulo também traz o uso das técnicas de sensoriamento remoto, seja com imagens de satélite como alternativa à extensão territorial da região, dificuldades de acesso e custos elevados para realização de trabalhos de campo ou uso de sensoriamento remoto ativo de altíssima resolução. Abrange ainda os índices de vegetação, respectivamente o *CO2Flux*, desenvolvido com objetivo de mensurar o estoque de carbono em vegetação natural e o mapeamento da vegetação utilizando o *NDVI*, que permite estimar a biomassa da vegetação e consequentemente relacioná-la ao estoque de carbono.

### 2.1 Inventário florestal

Segundo RODRÍGUEZ (2015), um fator fundamental para o sucesso dos plantios, consiste na escolha das espécies mais apropriadas a serem utilizadas. Uma vez em poder da lista de espécies nativas que constituem a composição florística original da região, o passo seguinte é estabelecer a composição florística de um hectare de reflorestamento. A metodologia proposta para a determinação da quantidade de carbono em um reflorestamento de mata ciliar é: instalar um número significativo de parcelas amostrais fixos nos remanescentes de mata ciliar da região de estudo. As amostras devem ser georreferenciadas com auxílio de um GPS. Dentro de cada amostra, todas as árvores com Circunferência à altura do peito – CAP maior que 15 cm devem ser identificadas por espécie e classe de diâmetro e ter sua circunferência medida. A partir desses dados é possível determinar para cada amostra o número médio de indivíduos e o

CAP médio para cada espécie dentro de cada uma das categorias de diâmetro. Esses dados devem ser combinados com uma equação alométrica adequada para a região de estudo. Seguindo esse roteiro é possível estimar a quantidade de carbono que será fixado em um reflorestamento dentro dos parâmetros considerados neste estudo (RODRÍGUEZ, 2015).

Em termos gerais, a alometria pode ser definida como a relação entre variáveis de tamanho de um organismo. A alometria pode ser considerada como o estudo do crescimento de uma parte do organismo em relação ao todo, como o estudo das consequências do tamanho na forma do organismo, ou ainda, como a propriedade que têm certos objetos de conservarem sua geometria e forma enquanto eles variam de tamanho. A relação mais utilizada em alometria de plantas é aquela entre o diâmetro do tronco e a altura total da árvore. Métodos e técnicas para medir reservatórios de carbono em projetos florestais são de uso corrente, baseados em princípios comuns dos inventários florestais, amostras de solo e análises ecológicas. Inventários utilizam em geral amostras de tamanho fixo e permanentes, através da análise dessas amostras, todos os reservatórios de carbono de uma floresta podem ser medidos ou estimados. O erro total na medida de um reservatório de carbono é em função do erro na amostragem (número de amostras utilizadas para representar uma população de interesse), erros de medida (erro durante a medida do CAP) e erros de regressão (conversão do CAP da árvore em massa de biomassa utilizando equações alométricas). O erro de amostragem é, em geral, a maior fonte de erro (MARTINS, 2004).

## 2.2 Sequestro de carbono

De acordo com MARTINS (2004), para a biomassa viva, diâmetros de uma amostra de árvores são medidos e convertidos em estimativas de peso de biomassa utilizando-se equações de regressão alométricas. A relação mais utilizada em alometria de plantas é aquela entre o diâmetro do tronco e a altura total da árvore. Para a elaboração de um projeto de sequestro de carbono, é preferível que a estimativa do potencial seja subestimada a superestimada, o que seria um fator de desconfiança de um projeto. O mesmo ocorre com as árvores com CAP inferior à 15 cm, já que praticamente todas as equações alométricas que estão disponíveis não são válidas para árvores com esse padrão de CAP (MARTINS, 2004).

A metodologia do Instituto Nacional de Pesquisas Espaciais – INPE (2009) desenvolvida no projeto Mata Nativa, diz que não é simples utilizar um fator equivalente para realizar o cálculo de sequestro de carbono por árvore. A razão é que a dinâmica de crescimento de uma floresta não é linear e, portanto, a absorção de carbono também é irregular, além do

que, não é possível saber se todas as árvores vão sobreviver caso fossem plantadas. Por essa razão, assume-se que a plantação cresce a um ritmo constante, ou seja, que a taxa de crescimento da massa das árvores usada para o cálculo é constante durante o tempo e equivale ao crescimento durante os primeiros 20 anos. (ORDOÑEZ, 2014; RODRÍGUEZ, 2015). Desta maneira, Mata Nativa, que se desenvolve em uma área de 25,3 hectares no INPE de Cachoeira Paulista, os dados necessários para o cálculo do sequestro de carbono de uma plantação de árvores são a densidade da madeira ( $\rho_m$ ), o teor de carbono ( $tc$ ) e a velocidade de crescimento da massa das árvores por unidade e área ( $mha$ ); com isso pode-se calcular o fator sequestro de carbono anual médio por hectare de plantação ( $S$ ) conforme ilustrado na equação (2.1). A constante  $k$  representa a constante estequiométrica para fixar o carbono do  $CO_2$  atmosférico e tem um valor de 44/12.

$$S = mha * \rho_m * tc * k \quad (2.1)$$

Na metodologia do Painel Intergovernamental sobre Mudanças Climáticas - IPCC (2006), a taxa de captura de carbono em florestas tropicais naturais da América do Sul é subdividida por período, sendo considerada uma taxa para áreas de até 20 anos e outra para áreas em que o plantio florestal possui mais de 20 anos. Assim para o primeiro período a taxa calculada a partir dos parâmetros determinados é de 7,0829 tC/ha/ano ou 25,9942 tCO<sub>2</sub>/ha/ano; já para o segundo período, esta taxa é de 1,9960 tC/ha/ano ou 7,3253 tCO<sub>2</sub>/ha/ano.

O IPCC foi fundado em 1988 no âmbito da Organização das Nações Unidas – ONU, para fornecer aos líderes políticos avaliações periódicas das bases científicas das mudanças climáticas, seus impactos e riscos futuros, e opções em forma de adaptações e mitigações. Em 2006, a organização publicou um guia fornecendo metodologias para estimar inventários nacionais de emissões antropogênicas e sequestros de Gases do Efeito Estufa - GEE. O método utilizado pelo IPCC é oficial, além que considera a contabilização da parte aérea e raiz, ou seja, a de carbono na biomassa aérea e abaixo do solo, também porque considera um horizonte de tempo de 20 anos e de mais de 20 anos, e não assume como linear a velocidade de crescimento da árvore, portanto, o fator sequestro de carbono é mais próximo da realidade. Para a realização deste cálculo basta multiplicar o fator de sequestro de carbono pela área da reserva e multiplicar pelo horizonte de tempo, conforme ilustrado na equação (2.2), onde FSC= Fator de sequestro de carbono (25,9942 tCO<sub>2</sub>/ha/20anos).

$$S = FSC \times \text{Área da reserva} \times \text{horizonte de tempo} \quad (2.2)$$

De acordo com os cálculos do IPCC, cada árvore de clima tropical sequestra 312kg de CO<sub>2</sub> até chegar aos 20 anos de vida. Isso corresponde a uma captação de aproximadamente 16kg de CO<sub>2</sub> a cada ano. Depois desses 20 anos, continua captando aproximadamente 6 kg a cada ano restante de sua vida. “Muitas pessoas pensam que é necessário esperar os 20 anos que a planta leva para atingir seu ápice para que comece a captar carbono da atmosfera. Mas, a planta já começa a fazer isso desde que a semente germina.” (INSTITUTO SOKA AMAZÔNIA, 2021b).

### 2.3 Uso de software especializado

Se tratando de estimar o potencial de sequestro de carbono através da combinação de imagens com uma tabela de parâmetros, foi encontrado na literatura o uso de um software chamado *inVEST - Integrated Valuation of Ecosystem Services and Tradeoffs* da *Stanford University* que possui um módulo *Carbon Storage and Sequestration*. Segundo Tallis (2013), o módulo possui algumas limitações: O modelo simplifica bastante o ciclo de carbono, assumindo que nenhum uso e ocupação do solo (*LULC*) existente na paisagem ganha ou perde carbono ao longo do tempo. O modelo depende das estimativas do carbono sequestrado para cada classe de *LULC* cujos resultados serão tão detalhados quanto a classificação usada para as classes *LULC* o permitir. Uma vez que o sequestro de carbono pode variar não só entre classes *LULC* mas também dentro de cada classe de *LULC*, uma classificação menos detalhada poderá gerar resultados menos precisos. O modelo não contabiliza o carbono que se “move” de um *pool* para outro, ou seja, o modelo assume que o carbono que possa mover-se do *pool* “acima do solo” para o “solo” através da decomposição da folhada que cai da árvore, é automaticamente liberado para a atmosfera. Por fim, o modelo para a valoração econômica considera que o armazenamento de carbono ao longo do tempo assume um padrão linear em vez de um padrão não linear, não refletindo de fato que a taxa de sequestro é maior nos primeiros anos e baixa nos anos seguintes. Uma vez que assume uma taxa de variação constante, o modelo tende a sobrevalorizar o carbono sequestrado.

O funcionamento do módulo *Carbon Storage and Sequestration* utiliza como requisitos (*inputs*) mapas de classes de uso e ocupação do solo (*LULC*) em formato matricial (*raster*) e tabelas de coeficientes que relacionam o armazenamento de carbono com cada classe de uso e ocupação do solo do mapa. A quantidade de carbono armazenado em cada classe de uso e ocupação do solo (*LULC*) depende maioritariamente da dimensão dos quatro reservatórios (*pools*), respectivamente, acima do solo, abaixo do solo, matéria orgânica em decomposição e

o próprio solo (matéria orgânica morta), uma vez que o cálculo feito pelo modelo tem por base a quantidade de carbono armazenado numa determinada classe de uso e ocupação do solo e a área que essa classe representa na paisagem. O cálculo do carbono armazenado consiste na soma do carbono armazenado nos diferentes *pools* de carbono (acima do solo: casca dos troncos, folhas; abaixo do solo: todas as raízes; matéria orgânica em decomposição (o maior reservatório de carbono terrestre) e solo (matéria orgânica morta) para cada classe de ocupação do solo, obtendo-se o carbono armazenado em cada classe e/ou o carbono armazenado em toda a paisagem. A modelação do sequestro de carbono é feita em função da variação de classes de ocupação e uso do solo ao longo do tempo. No entanto, a estimativa para a variação do carbono armazenado ao longo do tempo só é possível caso exista um mapa/cenário futuro, uma vez que o cálculo do sequestro é feito em dois momentos no tempo, calculando a diferença de armazenamento entre os dois casos em cada unidade do mapa. Os *outputs* gerados pelo modelo são mapas do carbono armazenado (toneladas de carbono/pixel); carbono sequestrado (toneladas de carbono/pixel); valor atual do carbono sequestrado (unidade monetária/pixel).

O *inVEST* segue o modelo de inventário IPCC para atribuir valores de armazenamento de carbono por classes de cobertura do solo. O carbono armazenado é a soma dos quatro reservatórios. O sequestro de carbono é a diferença do armazenamento em um certo ponto e o armazenamento em um ponto anterior no tempo. O modelo requer duas entradas, a primeira é um mapa de uso da terra e o segundo é uma tabela biofísica, com valores de armazenamento de carbono para cada classe de cobertura de linha de uso da terra. Opcionalmente, se desejar calcular o sequestro de carbono, precisa de uma classe de cobertura de uso da terra para outro ponto no tempo. Sobre os resultados do modelo, de acordo com o autor, o mais importante é o mapa do carbono armazenado na paisagem. Será obtido um mapa para cada ponto no tempo. Se for mais de um, obterá o mapa de sequestro de carbono. Mesmo com as limitações, esse modelo é muito utilizado para estimar de maneira rápida carbono armazenado e carbono sequestrado em uma paisagem. É muito utilizado por ser o método IPCC, ser fácil de executar e não precisar de muitos dados, mas o resultado pode não ser um reflexo real da realidade (Invest Carbon Model, 2020).

## 2.4 Uso de aprendizado de máquina

De acordo com MOREIRA et al. (2021), a aplicação de Inteligência Artificial para uso florestal, tem sido utilizada entre outros, no monitoramento e no combate a incêndios, planejamento, otimização florestal e sensoriamento remoto. Os autores citam exemplos



utilizando Lógica *Fuzzy* em Sistemas de Informação Geográfica – SIG com as vantagens de permitir avaliar problemas complexos de forma prática, ser compreensível, permitir flexibilidade na combinação de mapas e de ser facilmente implementada.

Outra técnica de aprendizado de máquina utilizada, é a *Random Forest*, devido à robustez do algoritmo, facilidade de parametrização e métricas internas. Além disso, *Random Forest* está se tornando amplamente utilizada para predição espacial, estimativa de biomassa acima do solo, relação entre produtividade da floresta e os fatores de povoamento e clima, dentre outras (MOREIRA, T. et. al., 2021).

Estudos recentes utilizando aprendizado de máquina no contexto florestal também foram realizados por MIRANDA e AGUIAR (2021). Os autores avaliaram um modelo de suscetibilidade a deslizamentos de terra na área de Longhai na China, a partir de um banco de dados de mapas de inventários de deslizamento de terra com 93 locais e dados espaciais de 14 fatores condicionantes. Entre os métodos analisados, *Random Forest* se mostrou o mais eficiente, com curva característica de operação - *AUROC* (0,869), erro padrão (0,025), intervalo de confiança de 95%, maior valor de precisão (0,774), maior recall (0,662) e maior medida F (0,662) para o conjunto de dados de treinamento. Outro caso citado pelos autores ocorreu em Kenthii na Mongólia, com avaliação da regeneração florestal natural. Nesse experimento, o banco de dados foi compilado no campo através de medições de dados coletados como variáveis fatores de vegetação heterogênea, pressão de pastagem e fatores ambientais de 120 parcelas dispostas em 6 locais. Os dados foram centralizados, padronizados, verificou-se outliers, transformados com assimetria e análises multivariadas foram implementadas para ordenar os dados. Após testes de correlação linear e classificação foram testados os algoritmos de classificação *Random Forest*. Um terceiro estudo, trata da avaliação de desempenho de métodos de aprendizagem de máquina para previsão de incêndios florestais no Parque Nacional *Pu Mat*, no Vietnã. A aplicação de métodos como *Bayes Network* (BN), *Naive Bayes* (NV), Árvore de Decisão (DT) e Regressão Logística Multivariada (MLP) para a previsão e mapeamento da suscetibilidade de incêndio em todo o Parque, foram robustos em resposta à mudança de treinamento e validação do conjunto de dados. (MIRANDA E AGUIAR, 2021).

## 2.5 Uso de redes neurais artificiais

Classificação de estratos florestais utilizando redes neurais artificiais podem ser encontrados em GONÇALVES et al. (2016), utilizando dados provenientes de um inventário florestal do Instituto de Desenvolvimento Florestal do Estado do Pará – IDEFLOR BIO, de

uma área de 600 mil hectares e imagens de satélite escolhidas seguindo o critério de compatibilidade entre a data da imagem e a data de execução do inventário, com o objetivo de minimizar as variações temporais nas tipologias florestais. Foram treinadas redes neurais como classificadores de dois tipos florestais e avaliadas usando os indicadores matriz de confusão, cálculo de acurácia global, coeficiente *Kappa* e o gráfico de características do receptor operacional (*ROC*), sendo o melhor resultado obtido por meio da rede neural probabilística de função de base radial (*RBF newpnn*), evidenciando a aplicação dessa metodologia na análise de áreas com potencial para prestar serviços ecossistêmicos. Chagas et al. (2009), Espinhosa e Galo (2004) e Moreira et al. (2013) afirmam que nos últimos anos, as Redes Neurais Artificiais tiveram um crescente interesse e têm sido usadas com bastante êxito no gerenciamento de informações do ambiente e, em reconhecimento de padrões de imagens provenientes de Sensoriamento Remoto.

## 2.6 Uso de aprendizagem profunda

Aprendizagem Profunda permite construir conceitos complexos a partir de conceitos simples. De acordo com GOODFELLOW et al. (2016), a quintessência de um modelo de aprendizagem profunda são os *perceptrons* multicamada (MLP). Um *perceptron* multicamada é apenas uma função matemática mapeando algum conjunto de valores de entrada para valores de saída. Essa função MLP é formada pela composição de outras funções mais simples e a aplicação de cada uma delas, proporciona uma nova representação da entrada. Suponha uma imagem representada como uma coleção de valores de pixels. A aprendizagem profunda faz uma série de mapeamentos simples aninhados, cada um descrito por uma camada diferente do modelo: a entrada é representada na camada visível, assim denominada porque contém as variáveis que podemos observar. Depois, uma série de camadas escondidas, seus valores não estão nos dados em si; em vez disso, o modelo deve determinar que conceitos são úteis para explicar as relações nos dados observados. Dados os pixels, a primeira camada visível pode facilmente detectar arestas, comparando a luminosidade dos pixels vizinhos. Dados os primeiros pixels escondidos, a segunda camada oculta pode facilmente procurar cantos e contornos alargados. A terceira camada oculta pode detectar partes inteiras de objetos específicos. Finalmente, esta descrição da imagem em termos das partes do objeto que contém, pode ser utilizada para reconhecer os objetos presentes na imagem. As redes com maior profundidade podem executar mais instruções em sequência. As instruções sequenciais são capazes de consultar os resultados das instruções anteriores. Ainda de acordo com o autor, não

existe consenso sobre a profundidade que um modelo requer para se qualificar como “profundo”.

A aprendizagem profunda tem sido utilizada com sucesso em aplicações comerciais desde os anos 90, mas era frequentemente considerada como sendo mais uma arte do que uma tecnologia, algo que só um especialista poderia utilizar. Os algoritmos de aprendizagem que atingem atualmente o desempenho humano em tarefas complexas são quase idênticos aos algoritmos utilizados para resolver *toy problems* nos anos 80, embora os modelos que treinamos com esses algoritmos sofreram alterações que simplificam a formação de arquiteturas muito profundas. A novidade é que hoje em dia podemos fornecer estes algoritmos com os recursos que necessitam para serem bem-sucedidos nessa era de *Big-Data*. Hoje os recursos computacionais podem executar modelos muito maiores. Redes maiores são capazes de alcançar maior precisão em tarefas mais complexas. A conectividade mais rápida da rede e a melhor infraestrutura de software de computação distribuída são uma das tendências mais importantes na história da aprendizagem profunda e espera-se que continue sendo para o futuro. Desde os anos 1980, a aprendizagem profunda tem melhorado na sua capacidade de proporcionar um reconhecimento e previsão precisos e tem sido consistentemente aplicada com sucesso a conjuntos de aplicações cada vez mais vasto, entre elas, a classificação de imagens.

O maior concurso de reconhecimento de objetos é a *ImageNet Large-Scale Visual Recognition Challenge* – ILSVRC, realizado anualmente de 2010 a 2017. Em oito anos de competição houve redução do erro de classificação de imagens em 10 vezes e melhoria da precisão da detecção em 3 vezes. A *ImageNet* é um conjunto de dados com mais de 15 milhões de imagens rotuladas de alta resolução pertencentes a cerca de 22.000 categorias (KAGGLE, 2022). Uma rede convolucional venceu esse desafio *ImageNet* com uma larga margem, baixando a taxa de erro dos 5 melhores lugares do estado da arte de 26,1% para 15,3%, o que significa que a rede convolucional produz uma lista classificada de categorias possíveis para cada imagem, e acertou para todos os exemplos de teste, exceto 15,3%. Desde então, estes concursos são consistentemente ganhos por redes convolucionais profundas e os avanços fizeram baixar a última taxa de erro dos 5 primeiros lugares neste teste para 3,6%. (GOODFELLOW et al., 2016).

## 2.7 Uso de redes convolucionais

Integrando a Aprendizagem Profunda, estão as Redes Neurais Convolucionais – *CNNs*. São um tipo especializado de rede neural para o processamento de dados, como séries

temporais, recolhendo amostras a intervalos regulares de tempo e dados de imagem. As redes convolucionais têm sido extremamente bem-sucedidas em aplicações práticas. O nome “rede neural convolucional” indica que a rede emprega uma operação matemática chamada “convolução”. A convolução é um tipo especializado de operação linear. Redes neurais convolucionais são redes neurais que utilizam a convolução em vez da multiplicação geral da matriz em pelo menos uma das suas camadas.

A convolução alavanca três ideias importantes que podem ajudar a melhorar um sistema de aprendizagem de máquina: interações esparsas, partilha de parâmetros e variantes. Além disso, a convolução proporciona um meio de trabalhar com produções de dimensão variável. Ao processar uma imagem de entrada, ela pode ter milhares ou milhões de pixels, mas podemos detectar características pequenas e significativas, tais como bordas com núcleos que ocupam apenas dezenas ou centenas de pixels. Isto significa que precisamos armazenar menos parâmetros, o que reduz os requisitos de memória do modelo e melhora sua eficiência. Significa também que o cálculo da saída requer menos operações. A partilha de parâmetros permite utilizar o mesmo parâmetro para mais de uma função no modelo. Em uma rede neural tradicional, cada elemento da matriz de peso é utilizado exatamente uma vez quando se calcula a saída de uma camada. Na rede neural convolucional, cada membro do núcleo é utilizado em cada posição da entrada. A partilha de parâmetros utilizada pela operação de convolução significa que em vez de aprendermos um conjunto separado de parâmetros para cada local, aprendemos apenas um conjunto.

Tipicamente, a parte mais dispendiosa da formação convolucional em rede é aprender as características. A camada de saída é normalmente relativamente barata devido ao número reduzido de características fornecidas como entrada para esta camada depois de passar por várias camadas de *pooling*. As camadas de *pooling* são utilizadas para simplificar as informações na saída da camada convolucional. Ao realizar um treinamento supervisionado com gradiente, cada passo de gradiente requer uma série completa de propagação para frente e para trás através de toda a rede. Uma forma de reduzir o custo da formação de redes de convolução é utilizar características que não são treinadas numa forma supervisionada. Hoje em dia, a maioria das redes convolucionais são treinadas de forma puramente supervisionada, usando uma propagação completa para a frente e para trás, através da rede de centros em cada interação de treino.

Embora as redes convolucionais tenham sido guiadas por muitos outros caminhos, alguns dos princípios chave de concepção de redes neurais foram extraídos da neurociência. A história das redes convolucionais começa com experiências neurocientíficas muito antes dos

modelos computacionais relevantes terem sido desenvolvidos. Redes Convolucionais têm desempenhado um papel importante na história do Aprendizado Profundo. São um exemplo chave de uma aplicação bem-sucedida de conhecimentos obtidos através do estudo do cérebro e aplicações de aprendizagem de máquina (GOODFELLOW et. al, 2016).

Uma família de modelos de rede neural, denominada EfficientNet, alcançam mais precisão e eficiência do que as Redes Neurais Convolucionais anteriores. Ao introduzir uma forma heurística de dimensionar o modelo, a EfficientNet fornece uma família de modelos (B0 a B7) que representa uma boa combinação de eficiência e precisão em uma variedade de escalas. (TAN e LE, 2020).

## 2.8 Uso de sensoriamento remoto

Sensoriamento remoto é a ciência que possibilita a aquisição de informações (espectral, espacial, temporal) de objetos materiais sem a necessidade de contato físico com o objeto de investigação. Nesse contexto, o uso das técnicas de sensoriamento remoto torna-se indispensável, sobretudo devido à extensão territorial da região, dificuldades de acesso e custos elevados para realização de trabalhos de campo (GONÇALVES et. al, 2016).

Além das imagens de satélites, amplamente utilizadas, existem tecnologias como o LIDAR – *Light Detection and Ranging*, um sistema de sensoriamento remoto ativo que pode ser usado para mapear estruturas, incluindo altura da vegetação, densidade e outras características da região. Por ser um sistema ativo, o próprio sistema gera energia, no caso a luz que é emitida por meio de um laser. Esta luz viaja para o solo e atinge objetos como ramos de árvore. Parte da luz refletida desses objetos regressa ao sensor, onde é registrada. A quantidade de energia que regressa ao sensor é conhecida como "intensidade". Entre as possibilidades estão a medição de biomassa, através de um sensor de reflectância ótica, determinar o índice de reflectância espectral, índice de vegetação por diferença normalizado – NDVI ou da altura da planta (INPE, 2021).

## 2.9 Índices de vegetação

Uma quantidade de energia luminosa ao atingir a planta, é refletida, enquanto outra parte é absorvida. Uma planta saudável consegue absorver a luz visível através da clorofila, já a luz do infravermelho próximo – *NIR*, é refletida pela estrutura celular das folhas das plantas. O *Índice de Vegetação por Diferença Normalizada - NDVI*, é a diferença entre a banda

infravermelha e vermelha do sensor, sendo associado a produção de biomassa e ao vigor das plantas. O *NDVI* mede o quanto cada planta consegue emitir e gera um valor entre -1 e 1. Por meio do *NDVI*, torna-se possível analisar as condições da vegetação. As coberturas vegetais mais densas e vigorosas são indicadas por valores mais elevados de *NDVI*, valores menores representam uma vegetação moderada e vegetação rasteira (COLTRI et al., 2009).

Encontra-se também na literatura a informação que para plantas de maior porte, com mais densidade no seu dossel, pode-se utilizar o índice *Diferença Normalizada do Vermelho Limítrofe* - *NDRE*. O *NDRE* não satura o mapa do mesmo modo que o *NDVI* e apresenta resultados em culturas mais densas e com maior produção de biomassa. Os índices espectrais como *NDVI* e o *Índice de Vegetação Fotossintético* - *PRI*, cooperam para a obtenção de outro índice, denominado *Carbon Dioxide Flux* - *CO2Flux*, que quantifica o sequestro de carbono, possibilitando o mapeamento da vegetação fotossinteticamente ativa em determinada área de estudo. Ressalta-se que o *CO2Flux* é proporcional ao fluxo de carbono e, dependente da integração entre o *NDVI* com o *PRI*, resultando nesse novo índice. O *CO2Flux* é eficiente para a modelagem do sequestro de carbono em diferentes ambientes, sendo visível uma proporcionalidade no sequestro e fluxo de carbono (COLTRI et al., 2009).

O sequestro de carbono pela vegetação depende da integração do *NDVI* com *PRI* gerando um novo índice, o *CO2Flux*, desenvolvido com objetivo de mensurar o estoque de carbono em vegetação natural. O mapeamento da vegetação utilizando o *NDVI* permite estimar a biomassa da vegetação e consequentemente relacioná-la ao estoque de carbono. Em seguida gerado o *PRI* que mensura os pigmentos de carotenoides (entre eles a xantofila) da folhagem. Esses pigmentos indicam o quanto a luz fotossintética é eficiente ou a taxa armazenada de dióxido de carbono na folhagem. Ainda, de acordo com o autor, a mensuração do estoque de carbono em vegetação natural através do *CO2Flux*, mostra-se como uma possibilidade a nível exploratório, visto que medidas *in loco* devem ser adicionadas a essa análise preliminar. (COLTRI et al., 2009).


## 2.10 Considerações finais

Dessa forma, foram trazidos da literatura disponível, alguns estudos no sentido de contribuir para o desenvolvimento da presente pesquisa, que tem por objetivo treinar e validar um algoritmo que seja capaz de estimar o potencial de sequestro de carbono em uma determinada região e possa ser aplicado em outras regiões.

### 3 METODOLOGIA PROPOSTA E DESENVOLVIMENTO

Para o desenvolvimento da aplicação de estimativa do potencial de sequestro de CO<sub>2</sub>, considerando os processos de Inteligência Artificial e *Big Data*, a base de dados (*Data Warehouse*) com os parâmetros fitossociológicos e georreferenciais dos indivíduos arbóreos foi preparada com base em arquivo de inventário, disponibilizados para essa finalidade. A partir do conjunto de dados com as amostras de espécies, subdivididas em 19 parcelas amostrais de áreas fixas, foram geradas as imagens coloridas divididas em classes. O conjunto de dados foi dividido em conjunto de treinamento e conjunto de testes. Para o experimento foram utilizadas uma rede neural convolucional *CNN* sequencial e uma rede *EfficientNet*, com a análise de imagens de satélite com coordenadas geográficas, geradas a partir do conjunto de dados e que foram transformadas para possibilitar a classificação por meio da análise de conjuntos de pixels. As imagens segmentadas em pequenos blocos, representam a quantidade de espécies existentes naquela determinada região, denominada de parcela, ilustradas na Figura 3.1.

Figura 3.1 – Distribuição das espécies em parcelas amostrais



Fonte: Elaboração própria (2022).

Esses pequenos blocos foram apresentados para a rede neural, treinando-a para aprender sobre o potencial de sequestro de carbono existente naquela representação e a partir daí ser capaz de estimar esse potencial em outras regiões.

Dessa forma, o inventário utilizado na presente pesquisa, consiste em 54 famílias, 372 espécies nativas e 2433 indivíduos amostrados. As amostras estão distribuídas em 19 parcelas de 2500 m<sup>2</sup>, amostrando uma área de 4,8 ha, equivalente a 9,2% da área total da reserva. Cada parcela possui 125 metros de comprimento e 20 metros de largura, alocadas entre intervalos de 75 metros de distância. Foram determinadas a localização geográfica de todos os indivíduos arbóreos com Diâmetro à altura do peito - DAP maior a 10 cm. Foram utilizadas planilhas de campo para levantamento dos dados de localização geográfica (GPS). Esses dados foram utilizados para a elaboração de mapas, arquivos georreferenciados e banco de dados das árvores matrizes digitalizados em planilha eletrônica. Foram inventariadas as árvores com DAP mínimo de 10 cm (ou 30 cm de circunferência). Para o inventário que compõe esse Projeto de Pesquisa o erro amostral é < 10% (INSTITUTO SOKA AMAZÔNIA, 2021a).

Entre os projetos do Instituto Soka Amazônia, instituição alvo desse Projeto de Pesquisa, está o plantio de 10.000 mudas em 5 anos, correspondente ao período entre 2020 e 2025. De acordo com o cálculo do IPCC, onde cada árvore de clima tropical sequestra 312kg de CO<sub>2</sub> até chegar aos 20 anos de vida, que resulta em:

$$10.000 \times 312 = 3.120,00 \text{ tCO}_2$$

Uma outra forma de estimar o sequestro de carbono, seria tomar como base a equação (2.2), considerando a área amostrada da reserva de 4,8 ha, em um horizonte de tempo de 20 anos, onde FSC= Fator de sequestro de carbono (25,9942 tCO<sub>2</sub>/ha/20anos), que resulta em:

$$S = 25,9942 \times 4,8 \times 20, \text{ que resulta em } S = 2.495,44 \text{ tCO}_2$$


### 3.1 Características da área de estudo

O presente estudo tem como base, o conjunto de dados do Instituto Soka Amazônia, localizado no bairro Colônia Antônio Aleixo, município de Manaus, no estado do Amazonas, a área total possui 52,06 ha. A área está ilustrada na Figura 3.2. De acordo com o IBGE, 2007, as fitofisionomias dominantes na área de trabalho são Floresta ombrófila densa de terras baixas ou submontanas e Floresta ombrófila aberta, dominada por palmeiras de grande porte, de terras baixas ou submontanas. A floresta apresenta aspecto sempre verde e grande número de espécies arbóreas, arbustivas e herbáceas, geralmente distribuídas em três estratos bem distintos. A cobertura vegetal ombrófila tem dossel uniforme com uma altura média de 20 a 30 m e árvores emergentes ocasionais. O clima é do tipo tropical de monção – AM, com estação seca e estação



chuvosa definidas pelo regime dos ventos. O clima é quente e úmido praticamente todo o ano, com precipitação média mensal de 213,7mm e média anual 2565mm, temperatura média de 26°C e umidade média relativa do ar variando de 83% a 90%, com média anual de 87% (INSTITUTO SOKA AMAZÔNIA, 2021c).

Figura 3.2 - Imagem de satélite da área do Instituto Soka Amazônia



Fonte: INPE (2022)

### 3.2 Amostragem utilizada no estudo

As amostras estão distribuídas em 19 parcelas de 2500m<sup>2</sup>, amostrando uma área de 4,8 ha, equivalente a 9,2% da área total. Cada parcela possui 125 m de comprimento e 20 m de largura, alocadas entre intervalos de 75 m de distância. Foram determinadas a localização geográfica de todos os indivíduos arbóreos com DAP > 10 cm. O total da amostra no conjunto de dados é de 1222 indivíduos.

Neste trabalho, espera-se que com a rotulação de um conjunto relativamente pequeno de indivíduos arbóreos, o algoritmo aprenda a caracterizar estes elementos e seja capaz de identificar padrões de acordo com características fitossociológicas, combinadas com imagens de satélite. A partir do conjunto de dados com as espécies, subdivididas em 19 parcelas amostrais, foram geradas as imagens em *Red, Green, Blue* - RGB. Posteriormente, o conjunto

de dados foi dividido em conjunto de treinamento e conjunto de testes. Para o experimento foram utilizadas uma rede neural convolucional *CNN* sequencial e uma rede *EfficientNet*, com a análise de imagens de satélite com coordenadas geográficas, geradas a partir do conjunto de dados, e que foram transformadas para possibilitar a classificação por meio da análise de conjuntos de pixels. As imagens segmentadas em pequenos blocos, representam a quantidade de espécies existentes naquela determinada região, denominada de parcela. Esses blocos são apresentados para a rede neural, que deverá aprender sobre o potencial de sequestro de carbono existente naquela representação e a partir daí ser capaz de estimar esse potencial em outras regiões. Dentre os resultados esperados, destacam-se:

Conseguir identificar padrões dentro de uma área georreferenciada e com isso treinar e validar o algoritmo para aplicar em outra região. A aplicação proposta deve ser capaz de estimar o potencial de sequestro de carbono (CO<sub>2</sub>) de uma determinada área, de acordo com características fitossociológicas e de imagens.


### 3.3 Cálculo da biomassa

De acordo com MARTINS (2004), o tipo de clima para utilização de uma equação alométrica é definido em função do índice pluviométrico da região. Índices menores que 1.500mm a região é considerada seca. Índices entre 1.500 e 4.000mm a região é considerada úmida e para índices maiores que 4.000mm a região é considerada muito úmida. Para o escopo desta pesquisa, foi utilizada a equação para clima úmido, segundo Brown et al., (1989), ilustrada na equação (3.1). Sendo Y=Biomassa acima do solo em quilogramas e D=Diâmetro à altura do peito (cm):

$$Y = 42,69 - 12,800(D) + 1,242(D^2) \quad (3.1)$$

Na utilização da equação (3.1), o valor obtido para a biomassa (Y) é dividido por mil para obter o resultado em toneladas. O valor em toneladas é então multiplicado por 0,5 para obter as toneladas de carbono, já que na bibliografia disponível, em média, a matéria vegetal contém 50% de carbono, uma vez que a água é removida (MacDicken, 1997 apud Martins). O valor obtido é então dividido pelo tamanho da parcela amostrada (em m<sup>2</sup>) para então obter o valor em tC/m<sup>2</sup>. Multiplicando esse valor por 10.000 m<sup>2</sup>, obtém-se finalmente o valor em tC/ha (MARTINS, 2004). Foram calculados os valores de biomassa para cada parcela amostrada. Os valores foram ilustrados na Figura 3.3

Figura 3.3 – Valores de biomassa em cada parcela



### 3.4 Cálculo dos índices de vegetação

Para fins do presente projeto de pesquisa, foram considerados os índices de vegetação *NDVI* e *CO2Flux*, calculados a partir das imagens de satélite. Em termos do sensor, considerou-se inicialmente, utilizar o *SENTINEL-2*, com resolução espacial de 10 metros. No entanto, para possibilitar o recorte dos pixels das imagens, com a resolução de 10 metros, a área total do pixel cobriria uma extensão muito maior do que cada um dos pontos das coordenadas das amostras. Optou-se então por utilizar imagens do satélite *CBERS4A* com resolução espacial de 2 metros. Dessa forma, os pontos das coordenadas das amostras melhor se ajustariam à região dos pixels, possibilitando um recorte mais aproximado.

Foram obtidas imagens de satélite referentes ao ano de 2016 (ano da realização do inventário). O pré-processamento e o processamento de imagens georreferenciadas, foram realizados com software *QGIS* e a linguagem *python*. O Sistema de Referência de Coordenadas - SRC utilizado foi o SIRGAS 2000 UTM 20S - EPSG 31980. No software *QGIS*, foram plotadas as informações das coordenadas geográficas dos indivíduos arbóreos, obtidos através do inventário florestal e suas respectivas biomassas, calculados a partir da equação alométrica, ilustrada na equação (3.1). O tratamento de Reflectância na Superfície - SR também foi realizado com uso do software *QGIS* e utilizado na geração dos índices de vegetação descritos na Tabela 1. Após a transformação dos NDs (Números Digitais) em valores de reflectância real, foram calculados os índices *NDVI* e *PRI*. Após o cálculo do *PRI*, foi calculado o *SPRI*. Os índices *NDVI* e *PRI* foram combinados para gerar o índice *CO2Flux*. O cálculo do *NDVI* é dado pela razão entre a diferença das reflectâncias do infravermelho próximo e do vermelho, e a soma destas, conforme ilustrado na equação (3.2):

$$\text{NIR} - \text{RED} / \text{NIR} + \text{RED} \quad (3.2)$$

O cálculo do *PRI* está ilustrado na equação (3.3):

$$\text{GREEN} - \text{BLUE} / \text{GREEN} + \text{BLUE} \quad (3.3)$$

Como o resultado do *PRI* apresenta valores negativos, precisam ser reescalados, originando o *SPRI*. O cálculo do *SPRI* está ilustrado na equação (3.4):


$$(\text{PRI} + 1) / 2 \quad (3.4)$$

O *CO2Flux* mede a eficiência do sequestro de carbono pela vegetação. O cálculo do *CO2Flux* está ilustrado na equação (3.5):

$$\text{NDVI} + \text{SPRI} \quad (3.5)$$


Foram calculados os valores de NDVI para cada parcela amostrada. A figura 3.4 ilustra os valores de NDVI.

Figura 3.4 – Valores de NDVI por parcela



Foram calculados os valores de *CO2Flux* para cada parcela amostrada. A figura 3.5 ilustra os valores de *CO2Flux*.

Figura 3.5 – Valores de CO2Flux por parcela




Dessa forma, foram considerados os índices de vegetação *NDVI* e *CO2Flux*. De acordo com COLTRI et al (2009), o *CO2Flux* foi desenvolvido com objetivo de mensurar o estoque de carbono em vegetação natural. O mapeamento da vegetação utilizando o *NDVI* permite estimar a biomassa da vegetação e consequentemente relacioná-la ao estoque de carbono.

### 3.5 Treinamento da rede neural

O fluxo para o treinamento consistiu em utilizar a técnica de aumento de dados para os dados de treinamento, gerando novas observações da mesma imagem com pequenas edições. Realizar a regressão utilizando um otimizador, comparar o resultado da *EfficientNetB0* com uma *CNN* sequencial e com uma abordagem ingênua, considerando a média dos dados.

Utilizando o software QGIS, foram plotados os pontos das coordenadas das amostras. A partir da camada de pontos, foi realizado um recorte dos pixels das imagens em RGB, o mais próximo possível dos pontos das amostras. Foram gerados os recortes das imagens no formato 1 x 1 pixel para possibilitar o treinamento da rede neural, conforme ilustrado na Figura 3.6:

Figura 3.6 – Recorte dos pixels das imagens em RGB



Devido ao desbalanceamento no número de observações em cada parcela, conforme ilustrado na Figura 3.7, como alternativa, optou-se por realizar a alteração no conjunto de dados com o uso de subamostragem (*undersampling*). Pelo fato da técnica de subamostragem, utilizar como referência a classe minoritária para obter o número de elementos para as demais classes, optou-se por remover os elementos da parcela 9, já que nessa parcela havia menos de 10 elementos. Dessa forma, a parcela com o menor número de elementos passou a ser a parcela 5, com 38 elementos e que passou a ser a classe minoritária. Como resultado, o conjunto de dados com subamostragem, ficou com 684 elementos, sendo 38 elementos em cada classe. A nova distribuição com subamostragem está ilustrada na figura 3.8.

Figura 3.7 – Distribuição dos dados no conjunto original





Figura 3.8 – Distribuição dos dados com subamostragem



## 4 RESULTADOS E DISCUSSÃO

No conjunto de dados, observa-se que os atributos *NDVI* e *CO2Flux* são os que possuem maior correlação entre si. A menor correlação está entre os atributos Biomassa e *CO2Flux*, ilustrados nas Figura 4.1 e 4.2.

Figura 4.1 – Correlação de *Spearman* entre os atributos.


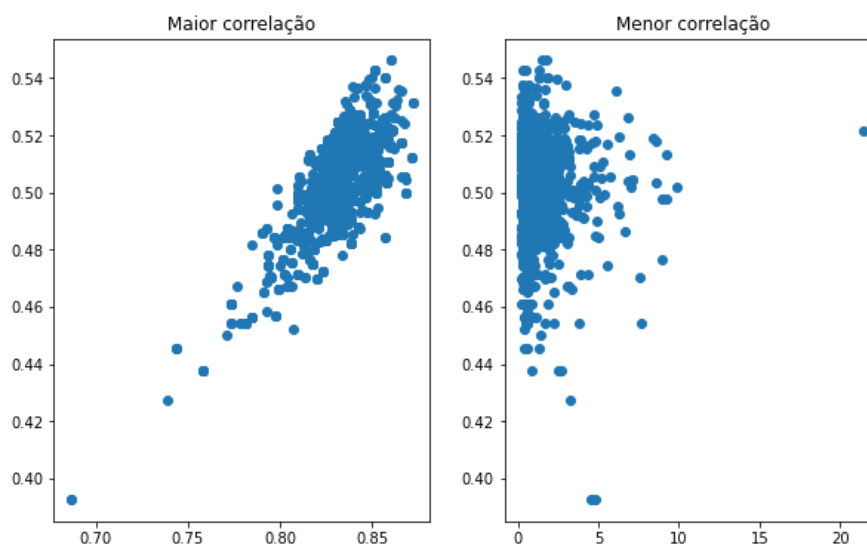


Figura 4.2 – Maior correlação entre *NDVI* e *CO2Flux* e menor correlação entre Biomassa e *CO2Flux*



O intuito de calcular a biomassa e os índices de vegetação, descritos nas sessões 3.3 e 3.4 respectivamente, foi obter valores de referência que pudessem ser comparados com os valores estimados pela rede neural. Os valores calculados para cada parcela com subamostragem, estão ilustrados na Tabela 4.1

Tabela 4.1 - Biomassa x Índices de Vegetação com subamostragem

<b>Parcela</b>	<b>Biomassa(tC/ha)</b>	<b>NDVI</b>	<b>CO2FLUX</b>
<b>1</b>	28.2124	31.2370	19.1097
<b>2</b>	43.0249	31.7606	19.4999
<b>3</b>	43.0029	30.8028	18.7339
<b>4</b>	44.0852	31.2718	18.8133
<b>5</b>	23.8247	31.4165	19.3651
<b>6</b>	33.1333	31.6877	19.4679
<b>7</b>	35.7861	31.6212	19.3456
<b>8</b>	36.5977	31.2644	18.6279
<b>9</b>	-	-	-
<b>10</b>	45.4419	31.6844	18.7627
<b>11</b>	31.4334	30.8682	18.5781
<b>12</b>	58.3916	31.2996	18.8540
<b>13</b>	38.0342	31.5579	19.2241
<b>14</b>	37.4021	31.6445	19.3861
<b>15</b>	48.0300	31.8766	19.2416
<b>16</b>	33.5928	31.9411	19.2524
<b>17</b>	103.4998	31.4610	18.9246
<b>18</b>	110.7775	31.7939	18.8678
<b>19</b>	58.5810	32.3416	19.6381

O conjunto de dados foi dividido em treino, validação e teste, na proporção 70, 20, 10. Para avaliar a eficiência dos modelos, foram utilizadas:

- Função de Perda (*LOSS*)
- Erro Percentual Médio Absoluto (*MAPE*).



A Função de Perda e o Erro Percentual Médio Absoluto dos modelos *CNN* sequencial e *EfficientNet* foram comparados com a Média dos dados de treinamento. Foram avaliados três atributos alvos (*targets*): Biomassa, *NDVI* e *CO2Flux*. A descrição dos dados do treinamento está representada na tabela 4.2.

Tabela 4.2 - Estatísticas Descritivas do Treinamento

	Biomassa	NDVI	CO2Flux
<b>Contagem</b>	478.0000	478.0000	478.0000
<b>Média</b>	1.179846	0.829937	0.502597
<b>Desvio Padrão</b>	1.325217	0.017737	0.016280
<b>Mínimo</b>	0.260280	0.743890	0.437720
<b>25%</b>	0.416731	0.822080	0.493050
<b>50%</b>	0.659094	0.830025	0.504365
<b>75%</b>	1.464796	0.841200	0.514340
<b>Máximo</b>	9.216084	0.871860	0.546150

A Tabelas 4.3 ilustra o resultado do teste no conjunto de dados com subamostragem para os atributos Biomassa, *NDVI* e *CO2Flux*.

Tabela 4.3 – Desempenho dos modelos EfficientNet e CNN sequencial

Modelo	% Erro Médio Absoluto-MAPE			Função de Perda-LOSS		
	Atributos			Atributos		
-	Biomassa	NDVI	CO2Flux	Biomassa	NDVI	CO2Flux
<b>EfficientNet</b>	<u>47.9693</u>	<u>1.7465</u>	<u>2.8390</u>	<u>1.0155</u>	<u>0.0142</u>	0.0141
<b>CNN</b>	<u>74.0516</u>	40.3987	65.6392	1.2318	0.3354	0.3313
<b>Média dos</b>	128.5309	2.0371	2.8450	1.0893	0.0165	<u>0.0138</u>

Observa-se que para o atributo Biomassa, tanto o modelo *EfficientNet* quanto o modelo *CNN* sequencial alcançaram o Percentual de Erro Médio Absoluto-MAPE inferior ao da Média dos Dados, sendo que *EfficientNet* obteve o percentual de erro mais baixo, se comparado à *CNN* sequencial. Na Função de Perda-Loss, apenas o modelo *EfficientNet* alcançou o resultado inferior ao da Média dos Dados. Esse resultado é interpretado como favorável, já que ambas *EfficientNet* e *CNN* sequencial, mostraram melhor desempenho do que a abordagem ingênua de simplesmente tomar a média dos dados como referência.

Para o atributo *NDVI*, apenas a *EfficientNet* alcançou o Percentual de Erro Médio Absoluto-*MAPE* inferior ao da Média dos Dados. A Função de Perda-*Loss* apenas no modelo *EfficientNet* foi menor do que a Média dos Dados. Esse resultado parece sugerir que a *EfficientNet*, alcança mais precisão e eficiência do que as Redes Neurais Convolucionais anteriores, como a CNN sequencial.

Para o atributo *CO2Flux*, apenas a *EfficientNet* alcançou o Percentual de Erro Médio Absoluto-*MAPE* inferior ao da Média dos Dados. Porém para esse atributo, a Função de Perda no modelo *EfficientNet* foi ligeiramente maior do que a Média dos Dados. De toda forma, os resultados apresentados para o Percentual de Erro Médio Absoluto-*MAPE* e para a Função de Perda, para o atributo Biomassa, continuaram sendo melhores na *EfficientNet* do que na CNN sequencial. O gráfico de desempenho dos testes com o atributo Biomassa, NDVI e CO2Flux estão ilustrados na Figuras 4.3, 4.4 e 4.5, respectivamente.

Figura 4.3 – Desempenho para o atributo Biomassa

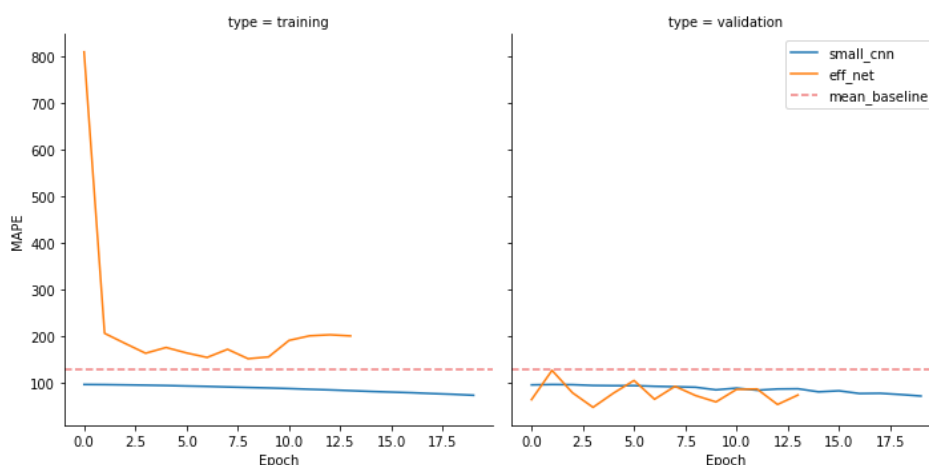


Figura 4.4 – Desempenho para o atributo *NDVI*

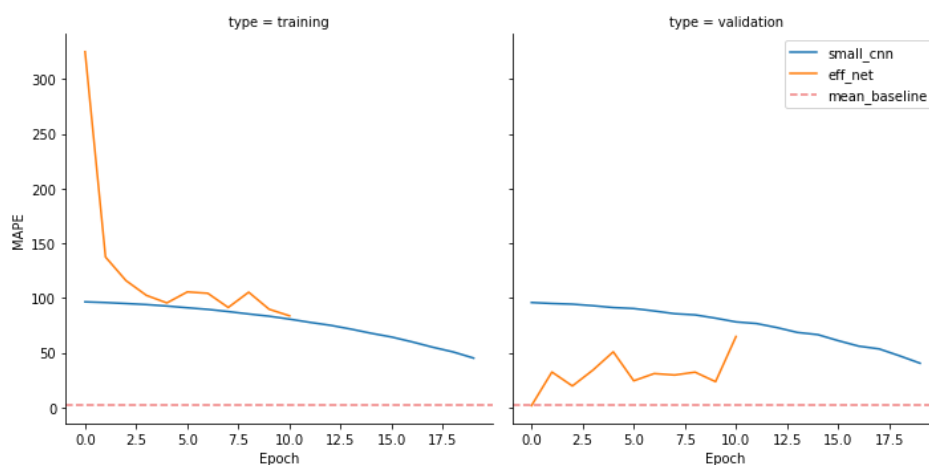
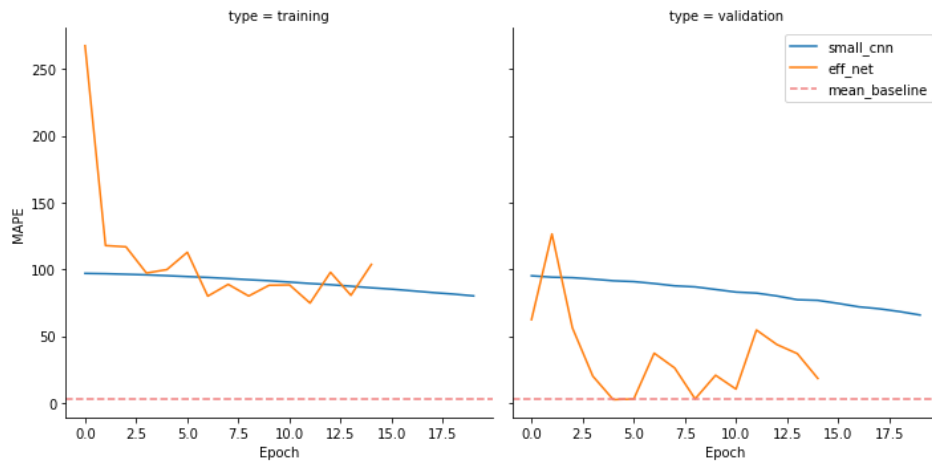


Figura 4.5 – Desempenho para o atributo *CO2Flux*

As tabelas 4.4, 4.5, 4.6 e 4.7 descrevem as configurações das redes utilizadas no teste.

Tabela 4.4 – Camadas do modelo *CNN* sequencial

Camada(tipo)	Neurônios	Tam.Filtro	Parâmetros	Func.Ativação	Tam.Entrada
Convolutacional	8	1,1	32	Relu	1,1,3
Flatten	-	8	0	-	-
Densa	-	1	9	-	-

Tabela 4.5 – Configuração do modelo *CNN* sequencial

Total de parâmetros	Parâmetros treináveis	Parâmetros não-treináveis
41	41	0

Tabela 4.6 – Configuração do modelo EfficientNet

Total de parâmetros	Parâmetros treináveis	Parâmetros não-treináveis
4,055,972	3,841	3,841

Tabela 4.7 – Valores dos parâmetros utilizados para o treinamento das redes.

	<i>EfficientNet</i>	<i>CNN</i> Sequencial
Quantidade de Épocas	20	20
Tamanho do Batch	64	64
Taxa de Aprendizagem	0.09	0.01

## 5 CONCLUSÃO

Com base nos testes com o conjunto de dados, a *EfficientNet* mostrou melhor desempenho nos atributos Biomassa, *NDVI* e *CO2Flux*, se comparado à *CNN* sequencial. O teste ainda sugeriu que o atributo Biomassa foi o que obteve melhor resultado em comparação aos atributos *NDVI* e *CO2Flux*. Isso pode se dever ao fato de que o atributo Biomassa, foi calculado diretamente sobre os dados tabulares do conjunto de dados por meio da equação (3.1), resultando nos valores de biomassa para cada parcela amostrada. Já os atributos *NDVI* e *CO2Flux* não foram calculados diretamente sobre os dados tabulares. Eles são resultado de um processamento de recortes de imagens de satélite, que estão sujeitos a variação de precisão, como a dificuldade de aproximação dos pontos das coordenadas com o pixel das imagens, a resolução das imagens, ao tratamento de Reflectância, entre outras descritas em detalhes na sessão 3.4. Sendo assim, as causas da disparidade dos resultados entre os atributos Biomassa e os demais, *NDVI* e *CO2Flux* estariam na qualidade dos dados de imagem, e não necessariamente nas redes em si. Todavia, essa análise ficaria como sugestão para trabalhos futuros.

Os resultados do treinamento da rede neural, mostraram que mesmo utilizando os recursos da rede pré-treinada *EfficientNet*, o Erro Percentual Médio Absoluto (*MAPE*) e a Função de Perda, ficaram elevados. Ainda assim, apresentaram melhor resultado do que a abordagem ingênua, de simplesmente tomar a média dos dados como referência. Possivelmente devido à pequena quantidade de dados disponíveis para o treinamento, especialmente de imagens.

Quanto ao objetivo de conseguir identificar padrões dentro de uma área georreferenciada e com isso treinar e validar o algoritmo para aplicar em outra região e a proposta do algoritmo ser capaz de estimar o potencial de sequestro de carbono ( $\text{CO}_2$ ) de uma determinada área, de acordo com características fitossociológicas e de imagens, embora o estudo mostre a possibilidade de inferir as taxas de biomassa para novas imagens, existe a necessidade de aferir com maior precisão as taxas previstas, assim como aprimorar o uso dos índices de vegetação. À medida que mais imagens e com melhor resolução forem disponibilizadas para treinamento, essa técnica poderá ser melhorada. Em trabalhos futuros, se houver a possibilidade de utilizar imagens com maior resolução espacial, obtidas por meio de drones ou torres de observação, poderá trazer maior precisão aos estudos.

## REFERÊNCIAS

- [1] BERRA E. et al. Estimativa do volume total de madeira em espécies de eucalipto a partir de imagens de satélite Landsat. **Rev. Ciência Florestal**, v. 22, n. 4, p.853–864, 2012.
- [2] BEZERRA, U. et al. **Comparativo do Índice de Vegetação de Diferença Normalizada (NDVI) entre os Sensores OLI - Satélite Landsat-8 e MSI – Satélite Sentinel-2 em Região Semiárida**. Anuário do Instituto de Geociências. 2018. UFRJ, RJ.
- [3] COLTRI, P. et al. Utilização de índices de vegetação para estimativas não destrutivas da biomassa, estoque e sequestro de carbono do cafeeiro Arábica. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, p.121-128, 2009. Natal, RN.
- [4] FOLHARINI, S.; OLIVEIRA, R. Cálculo do índice espectral CO2Flux em área de Mata Atlântica e sua relação com processos gravitacionais no município de Cubatão. **XVII Simpósio Brasileiro de Geografia Física Aplicada**. 2017. Campinas. SP
- [5] GONÇALVES, G.W.; RIBEIRO, C.M.H.; SÁ, S.A.J.; MORALES, P.G.; FILHO, F.R.H.; ALMEIDA, C.A. Classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto. 2016. **Rev. Ambient. Água**, v. 11, n. 3, p.612–624, 2016.
- [6] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. 2016. MIT Press. **Deep Learning**. Disponível em: < <https://www.deeplearningbook.org>>. Acesso em: 30 set. 2022.
- [7] INPE, 2021. **Catálogo**. Disponível em: <<http://www2.dgi.inpe.br/catalogo/explore>>. Acesso em: 30 set. 2022.
- [8] IKEDA, D. Mensagem alusiva como membro correspondente da Academia Amazonense de Letras. 2000. **Brasil Seikyo**, n. 1579, p. A10, 2000.
- [9] INSTITUTO SOKA AMAZÔNIA. Manaus. 2021. Disponível em: <<https://institutosoka-amazonia.org.br/plante-arvores-o-planeta-agradece/>>. Acesso em: 30 set. 2022.
- [10] INVEST CARBON MODEL. Natural Capital Project (NatCap), 2020. 1 vídeo (14:10 min). Disponível em: <[https://youtu.be/DlegxD\\_ma5I?list=PLSFk2iLV3UfNqRZGwfcgyoZZZqZDnj2V7](https://youtu.be/DlegxD_ma5I?list=PLSFk2iLV3UfNqRZGwfcgyoZZZqZDnj2V7)>. Acesso em: 30 set. 2022.

[11] JUNIOR, L.V.J.M. Inventário florestal e florístico da Reserva Particular de Patrimônio Natural Dr. Daisaku Ikeda. 2016. Universidade Federal do Amazonas, Brasil, 2016

[12] MARTINS, S.O. **Determinação do potencial de sequestro de carbono na recuperação de matas ciliares na região de São Carlos - SP.** 2004. Tese (Doutorado) – Universidade Federal de São Carlos, Brasil, 2004.

[13] MIRANDA, F.; AGUIAR, N. **Comparison of machine learning techniques for classifying restored forests using context indicators and landscape metrics.** ICMC USP, São Carlos, Brasil, 2021.

[14] MOREIRA, T. et al. **Inteligência artificial aplicada às ciências florestais e agricultura.** Alegre, ES: CAUFES, 2021. Doi:[10.29327/552680](https://doi.org/10.29327/552680)

[15] RODRÍGUEZ, M.R.C. **Estimativa do potencial de sequestro de carbono em áreas de preservação permanente de cursos d'água e topos de morros mediante reflorestamento com espécies nativas no município de São Luiz do Piraitinga.** 2015. Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, Brasil, 2015.

[16] ROSENFELDER, M. **Transfer learning with EfficientNet for image regression in Keras – Using custom data in Keras,** 2020. Disponível em: <<https://rosenfelder.ai/keras-regression-efficient-net>>. Acesso em 30 set. 2022.

[17] SANTANA, M.; OIKO, T.O. Pegada de carbono: Em busca de definições e métodos para uma logística verde. **Revista Gepros**, v. 14, n. 4, p.197-214, 2019. Maringá, Paraná.

[18] SCHAEFER, M.T.; LAMB, D.W. A Combination of Plant NDVI and LiDAR Measurements Improve the Estimation of Pasture Biomass in Tall Fescue (*Festuca arundinacea* var. Fletcher). **Remote Sens.** 2016, 8, 109.<https://doi.org/10.3390/rs8020109>.

[19] SILVA, M.; ANJOS, C. Análise do sequestro de carbono na região do Parque Nacional da Chapada dos Veadeiros utilizando técnicas de sensoriamento remoto. 2016. **Rev. Brasileira de Geomática**, v. 9, n. 3, p.251–270, 2021.

[20] STANFORD UNIVERSITY, Natural Capital Project, **Invest**, 2021. Disponível em: <https://naturalcapitalproject.stanford.edu/software/invest>. Acesso em 30 set. 2022.

[21] TAN. M, LE V. **EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.** 2020. Disponível em: <<https://arxiv.org/pdf/1905.11946.pdf>>