

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

Maurício Pegoraro Stangarlin

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO
REMOTO PARA ESTIMATIVA DE BIOMASSA, CARBONO e CO₂
EQUIVALENTE ACIMA DO SOLO EM SISTEMA AGROFLORESTAL**

Santa Maria, RS
2023

Maurício Pegoraro Stangarlin

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO
PARA ESTIMATIVA DE BIOMASSA, CARBONO e CO₂ EQUIVALENTE ACIMA
DO SOLO EM SISTEMA AGROFLORESTAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Mestre em Engenharia Florestal**.

Orientador: Prof. Dr. Lúcio de Paula Amaral
Coorientador: Ana Paula Moreira Rovedder

Santa Maria, RS
2023

Stangarlin, Maurício

Utilização de inteligência artificial e sensoriamento remoto para estimativa de biomassa, carbono e CO2 equivalente acima do solo em sistema agroflorestal / Maurício Stangarlin.- 2023.

77 p.; 30 cm

Orientador: Lúcio de Paula Amaral

Coorientadora: Ana Paula Moreira Rovedder

Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós Graduação em Engenharia Florestal, RS, 2023

1. Redes Neurais Artificiais 2. Sensoriamento Remoto
3. Agroflorestas I. de Paula Amaral, Lúcio II. Moreira Rovedder, Ana Paula III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, MAURÍCIO STANGARLIN, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Dissertação) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Maurício Pegoraro Stangarlin

**UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO
PARA ESTIMATIVA DE BIOMASSA, CARBONO E CO₂ EQUIVALENTE ACIMA
DO SOLO EM SISTEMA AGROFLORESTAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Mestre em Engenharia Florestal**.

Aprovada em 17 de outubro de 2023

**Lúcio de Paula Amaral, Dr. (UFSM) - Videoconferência
(Presidente/Orientador)**

Luciano Farinha Watzlawick, Doutor (UNICENTRO) - videoconferência

Emanuel Araújo Silva, Doutor (UFRPE) - videoconferência

Santa Maria, RS
2023

AGRADECIMENTOS

Em primeiro lugar, agradeço ao meu orientador, Lúcio de Paula Amaral, cuja orientação, sabedoria e paciência foram fundamentais para o desenvolvimento deste estudo. Sua orientação meticulosa e insights valiosos moldaram não apenas esta dissertação, mas também meu crescimento como pesquisador.

À minha companheira Betina Camargo, gostaria de agradecer por seu amor incondicional, apoio constante e compreensão durante todas as fases deste desafiante empreendimento. Sua paciência e incentivo foram fundamentais para me manter motivado e focado.

Minha família merece um agradecimento especial. Seu apoio inabalável, encorajamento constante e crença em mim foram os pilares que sustentaram minha jornada acadêmica. Agradeço a meus pais, por seu amor e exemplo inspirador.

A ONG Centro Ecológico (CE) pelo convite para colaborar no projeto Combinação de renda e proteção florestal no Sul do Brasil, onde um dos objetivos era estimar o carbono sequestrado na vegetação em sistemas agroflorestais, foi uma jornada incrivelmente gratificante ao longo desses dois anos. Essa iniciativa não apenas representa um avanço significativo em nossa compreensão dos benefícios ambientais dos sistemas agroflorestais, mas também fortaleceu a parceria da UFSM com o CE em auxiliar no compromisso com a sustentabilidade. O trabalho árduo e a dedicação de todos os envolvidos nesta colaboração foi inestimável, a contribuir para a proteção do meio ambiente e para um futuro mais sustentável. Obrigado por essa oportunidade e por acreditar em nosso potencial para fazer a diferença.

À Universidade Federal de Santa Maria, pela oportunidade de realizar este mestrado, pelo acesso às instalações e recursos de pesquisa e pelo ambiente acadêmico enriquecedor. Agradeço também aos meus colegas do Laboratório de agricultura e floresta de precisão (LAFLOPE) do curso de Engenharia Florestal, que compartilharam ideias e experiências, enriquecendo meu percurso acadêmico.

Por fim, expresso minha gratidão à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) por seu apoio financeiro, que tornou possível a realização deste estudo. Este trabalho não teria sido concluído com êxito sem a ajuda e apoio dessas pessoas e instituições. Sou profundamente grato a todos que fizeram parte desta jornada.

Muito obrigado!

RESUMO

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL E SENSORIAMENTO REMOTO PARA ESTIMATIVA DE BIOMASSA, CARBONO e CO₂ EQUIVALENTE ACIMA DO SOLO EM SISTEMA AGROFLORESTAL

AUTOR: Maurício Pegoraro Stangarlin

ORIENTADOR: Lúcio de Paula Amaral

No Litoral Norte do Rio Grande do Sul, tem-se os sistemas agroflorestais (SAF) silvibananeiros, baseados no cultivo de bananeiras (*Musa sp*), palmiteiro (*Euterpe edulis* Mart.) e espécies arbóreas da Mata Atlântica. O objetivo deste trabalho foi obter modelos, ajustados por Redes Neurais Artificiais (RNAs), que estimem o dióxido de carbono equivalente (CO_{2eq}), com uso de dados de sensoriamento remoto (SR), sendo índices de vegetação (IV) e dados de reflectância, obtidos com diferentes sensores. Um SAF de 2,37 ha localizado em Morrinhos do Sul foi utilizado como área experimental. Em agosto de 2022 foi realizado um voo programado com aeronave remotamente pilotada (ARP) *Phantom 4 Advanced Plus (DJI)* contendo sensor RGB, para obtenção de dados de reflectância e índices de vegetação, o processamento foi realizado com o software *Agisoft Metashape*. Foi realizado o inventário florestal, sendo instaladas 32 unidades amostrais (ua) pelo método da sexta árvore de Prodan, georreferenciadas com receptor GNSS de navegação. Nestas ua foram identificadas as espécies arbóreas e palmeiras, mensurados CAP (cm) e altura (m), e nas bananeiras foi mensurado o CAP (cm). Os dados de CAP foram transformados em DAP (cm) e juntamente com a altura (m) foram utilizados para calcular biomassa para estimar o CO_{2eq} acima do solo, com uso de equações alométricas específicas para cada espécie. Para complementar os dados de SR, foram adquiridas imagens gratuitas, livres de cobertura de nuvens no local do SAF em estudo, dos sensores MSI Sentinel 2A e sensor WPM CBERS 4A. No QGIS foram calculados os IV e inseridas as imagens das bandas espectrais (RGB, NIR e RedEdge) e da ARP, gerados os limites de cada ua, e com uso da ferramenta estatística zonal (EZ) foram obtidos os valores mínimos, médio e máximos para todos os dados de SR disponíveis. Foi utilizada Análise Multivariada Fatorial (AF) para entender as relações entre as variáveis, com uso do software Statistica12. Para estimar o CO_{2eq} foi utilizado RNAs, visando obter modelo simples e prático e com menores resíduos possíveis. A AF mostrou não haver relações significativas em CO_{2eq} e dados de SR, fatores 1 e 2 foram definidos pelos sensores Sentinel 2A e CBRS 4-A, indicando dificuldade de modelagem a partir de dados de SR ópticos, portanto, o uso de RNA, se justifica. Através da RNAs foi gerado um modelo completo com todas as variáveis de SR e um reduzido utilizando os dados SR que apresentaram importância acima de 70 % no modelo completo, os modelos apresentaram RMSE de 22,92 e 50,20, Bias de -2,11 e -1,85 e um coeficiente de determinação na validação cruzada de 0,99 e 0,95 respectivamente, indicando precisão nos resultados de CO_{2eq} estimado em relação ao valor de CO_{2eq} obtido pelo método indireto. Concluiu-se que os modelos são eficientes para estimar CO_{2eq} com o uso de dados de SR em SAFs na região do estudo e mesmo o modelo completo ter apresentado melhores estatísticas, o modelo reduzido ainda se torna preciso e oferece uma ferramenta eficaz e prática por utilizar um menor número de variáveis.

Palavras-chave: Redes Neurais Artificiais. Sensoriamento Remoto. Agroflorestas.

ABSTRACT

USE OF ARTIFICIAL INTELLIGENCE AND REMOTE SENSING TO ESTIMATE BIOMASS, CARBON and CO₂ EQUIVALENT ABOVE GROUND IN AGROFORESTRY SYSTEM

AUTHOR: Maurício Pegoraro Stangarlin

ADVISOR: Lúcio de Paula Amaral

On the North Coast of Rio Grande do Sul, there are silvi-banana agroforestry systems (SAF), based on the cultivation of banana trees (*Musa sp*), palm trees (*Euterpe edulis Mart.*) and tree species from the Atlantic Forest. The objective of this work was to obtain models, adjusted by Artificial Neural Networks (ANNs), that estimate carbon dioxide equivalent (CO₂eq), using remote sensing data (SR), being vegetation indices (IV) and reflectance data, obtained with different sensors. A 2.37 ha SAF located in Morrinhos do Sul was used as an experimental area. In August 2022, a scheduled flight was carried out with a remotely piloted aircraft (ARP) Phantom 4 Advanced Plus (DJI) containing an RGB sensor, to obtain reflectance data and vegetation indices, the processing was carried out with the Agisoft Metashape software. A forest inventory was carried out, with 32 sampling units (ua) installed using the Prodan sixth tree method, georeferenced with a GNSS navigation receiver. In these waters, tree and palm species were identified, CAP (cm) and height (m) were measured, and CAP (cm) was measured in banana trees. CAP data were transformed into DAP (cm) and together with height (m) were used to calculate biomass to estimate CO₂eq above ground, using specific allometric equations for each species. To complement the SR data, free images, free of cloud cover, were acquired at the SAF location under study, from the MSI Sentinel 2A sensor and the WPM CBERS 4A sensor. In QGIS, the IVs were calculated and images of the spectral bands (RGB, NIR and RedEdge) and ARP were inserted, the limits of each ua were generated, and using the zonal statistical tool (EZ) the minimum, average and maximum values were obtained. for all available SR data. Multivariate Factor Analysis (FA) was used to understand the relationships between the variables, using the Statistical12 software. To estimate CO₂eq, ANNs were used, aiming to obtain a simple and practical model with the lowest possible residues. AF showed no significant relationships in CO₂eq and SR data, factors 1 and 2 were defined by the Sentinel 2A and CBRS 4-A sensors, indicating difficulty in modeling from optical SR data, therefore, the use of ANN, if justifies. Through ANNs, a complete model was generated with all SR variables and a reduced one using the SR data that presented importance above 70% in the complete model, the models presented RMSE of 22.92 and 50.20, Bias of -2, 11 and -1.85 and a coefficient of determination in cross-validation of 0.99 and 0.95 respectively, indicating precision in the estimated CO₂eq results in relation to the CO₂eq value obtained by the indirect method. It was concluded that the models are efficient to estimate CO₂eq using SR data in SAFs in the study region and even though the complete model presented better statistics, the reduced model is still accurate and offers an effective and practical tool for using a smaller number of variables.

Keywords: Artificial Neural Networks, Remote Sensing, Agroforestry

LISTA DE ILUSTRAÇÕES

FIGURA 1 - Comportamento espectral da vegetação.	17
FIGURA 2 - Aprendizado Supervisionado para Redes Neurais Artificiais.	26
FIGURA 3 - Aprendizado Não-Supervisionado para Redes Neurais Artificiais.	26
FIGURA 4 - Localização do sistema agroflorestal em estudo em Morrinhos do Sul, Litoral Norte do Rio Grande do Sul.	27
FIGURA 5 - Inventário Florestal pelo método da sexta árvore de Prodan em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil - 2023.	30
FIGURA 6 - Distribuição das 32 unidades amostrais pelo método da sexta árvore de Prodan em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil - 2023.	31
FIGURA 7 - Dispersão das variáveis CO ₂ eq e dados de sensoriamento remoto (180 variáveis), segundo a Análise Fatorial, em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.	43
FIGURA 8 - Estrutura de aprendizado da RNA para estimar CO ₂ equivalente pelo modelo reduzido com dados de sensoriamento remoto (12 variáveis) em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.	48
FIGURA 9 - Destaque da dispersão (Análise Fatorial) das 12 variáveis (destacadas em vermelho) utilizadas para gerar o modelo reduzido pelas RNAs para estimar CO ₂ eq com dados de sensoriamento remoto, em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.	50
FIGURA 10 - Gráfico de Dispersão de Resíduos da Estimativa de CO ₂ equivalente, comparando os modelos completo RNAC e reduzido RNAR obtidos por redes neurais artificiais na vegetação acima do solo em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.	52
FIGURA 11 - Validação Cruzada para os valores de CO ₂ equivalente determinado por equações alométricas com dados de DAP (cm) e altura (m), e estimado pelos modelos completo (RNAC - A) e reduzido (RNAR - B) obtidos por redes neurais	

artificiais na vegetação acima do solo em Sistema Agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul – 2023.....	53
FIGURA 12 - Imagens das bandas espectrais dos sensores da câmera RGB, do sensor CBERS4A e o sensor Sentinel-2 ^a utilizadas para a obtenção dos IVs	53
FIGURA 13 - Estrutura de aprendizado da RNA para estimar CO2 equivalente pelo modelo reduzido com dados de sensoriamento remoto (12 variáveis) em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	66

LISTA DE TABELAS

Tabela 1 - Índices de vegetação calculados conforme as bandas espectrais dos sensores utilizados no imageamento sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	34
Tabela 2 - Equações alométricas utilizadas para o cálculo da biomassa das espécies Musa sp. (Bananeira) e Euterpe edulis (Juçara) no sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	36
Tabela 3 - Equação utilizada para o cálculo de biomassa para as espécies arbóreas nativas presentes no sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	37
Tabela 4 - Estatística descritiva para biomassa, carbono e CO ₂ equivalente determinados por equações alométricas em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	40
Tabela 5 - Importância das variáveis de entrada no modelo completo para estimar CO ₂ equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	45
Tabela 6 - Valores de importância, normalidade e correlação de spearman das covariáveis utilizadas para compor o modelo reduzido em RNA.....	46
Tabela 7 - Importância das 12 variáveis de entrada no modelo reduzido para estimar CO ₂ eq por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	47
Tabela 8 - Estatística descritiva para CO ₂ equivalente determinados por equações alométricas e estimados por modelagem de redes neurais artificiais em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.	51
Tabela 9 - Parâmetros estatísticos para os modelos obtidos por RNAs para a estimativa de CO ₂ eq em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	51
Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO ₂ equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.....	67

LISTA DE SIGLAS

ACP	Análise de Componentes Principais
AF	Análise Fatorial
APP	Área de Preservação Permanente
BAS	Biomassa Acima do Solo
C	Carbono
CE	Centro Ecológico
CO _{2eq}	Dióxido de carbono equivalente
EMATER	Assistência Técnica e Extensão Rural do Estado do Rio Grande do Sul
GEE	Gases do Efeito Estufa
GSD	<i>Ground Sample Distance</i>
ICRAF	Centro Internacional de Pesquisa Agroflorestal
IVs	Índices de Vegetação
NIR	<i>Near infrared</i>
ONG	Organização Não Governamental
RLs	Reservas Legais
RNA	Redes Neurais Artificiais
RPAs	Aeronaves Remotamente Pilotada
SAFs	Sistemas Agroflorestais
Uas	Unidades amostrais

SUMÁRIO

1	INTRODUÇÃO.....	9
1.1	OBJETIVOS.....	11
1.1.1	Objetivo geral.....	11
1.1.2	Objetivos específicos.....	12
2	REVISÃO DE LITERATURA.....	13
2.1	SISTEMAS AGROFLORESTAIS: CONTRIBUIÇÕES PARA A MITIGAÇÃO DO EFEITO ESTUFA E SEQUESTRO DE CARBONO.....	13
2.2	SENSORIAMENTO REMOTO.....	16
2.2.1	AERONAVE REMOTAMENTE PILOTADA.....	18
2.2.2	PLATAFORMAS ORBITAIS E SENSORES.....	18
2.2.3	ÍNDICES DE VEGETAÇÃO.....	20
2.2.4	OBTENÇÃO DE ÍNDICES DE VEGETAÇÃO COM SENSORES EMBARCADOS EM RPA E SATÉLITES PARA QUANTIFICAÇÃO DE CO ₂ eq NA VEGETAÇÃO ESTOCADO ACIMA DO SOLO.....	22
2.3	ANÁLISE MULTIVARIADA FATORIAL PARA CORRELAÇÃO DE VARIÁVEIS.....	23
2.4	ANÁLISE DE REDES NEURAS ARTIFICIAIS PARA MODELAGEM DE EQUAÇÕES.....	24
3.	MATERIAIS E MÉTODOS.....	27
3.1	ÁREA DE ESTUDO.....	27
3.2	AQUISIÇÃO DE IMAGENS E COLETA DE DADOS NO SAF.....	28
3.2.1	Aquisição das imagens com sensores embarcados em RPA e satélites.....	28
3.2.2	Inventário Florestal para determinação indireta de biomassa, carbono e estimativa de CO ₂ equivalente.....	29
3.3	PROCESSAMENTO DE DADOS.....	31
3.3.1	Processamento das imagens da RPA.....	31
3.3.2	Processamento das imagens de satélite.....	32

3.3.3 Índices de vegetação.....	33
3.3.4 Obtenção de dados nos mosaicos das Bandas e IVs, utilizando a ferramenta estatística zonal no SIG Qgis.	35
3.3.5 Estimativa da biomassa, carbono e CO ₂ equivalente estocados na vegetação do SAF acima do solo.....	35
3.3.6 Análise de Multivariada fatorial e Modelagem por redes neurais artificiais.....	37
4 RESULTADOS E DISCUSSÃO	40
5 CONSIDERAÇÕES FINAIS	56
REFERÊNCIAS	57
APÊNDICE A – IMAGENS DAS BANDAS ESPECTRAIS DOS SENSORES UTILIZADOS NA PESQUISA.	65
APÊNDICE B - ESTRUTURA DE APRENDIZADO DA RNA PARA O MODELO COMPLETO (180 VARIÁVEIS).	67
APÊNDICE C – IMPORTÂNCIA DAS VARIÁVEIS DE ENTRADA DO MODELO COMPLETO, PARA ESTIMAR CO _{2eq} EQUIVALENTE POR REDE NEURAL ARTIFICIAL.....	68

1 INTRODUÇÃO

Nos últimos anos, tem-se observado um aumento considerável no apoio e promoção de sistemas de produção que enfatizam a sustentabilidade ambiental, como os Sistemas Agroflorestais (SAFs). Essa tendência é motivada por diversas razões. Em primeiro lugar, tais sistemas de produção promovem a produção de alimentos saudáveis, um fator cada vez mais relevante na sociedade. Além disso, os SAFs desempenham um importante papel na captura e retenção de carbono atmosférico, contribuindo para a redução das emissões de dióxido de carbono (CO_{2eq}) na atmosfera, o que é de importância significativa no contexto das mudanças climáticas.

Isso ocorre porque a preservação desse carbono é fundamental para evitar sua transformação em CO_{2eq}, que, por sua vez, é um dos principais contribuintes para o agravamento do efeito estufa e a consequente intensificação das mudanças climáticas. Assim, a pesquisa sobre a estimativa de biomassa, carbono e CO_{2eq} na vegetação acima do solo em SAFs é importante para a compreensão das implicações de longo prazo em relação ao meio ambiente e às mudanças climáticas.

Os SAFs são sistemas agrícolas que combinam a produção de culturas agrícolas e/ou de animais com o cultivo de árvores ou outras plantas perenes, formando um ecossistema complexo que se assemelha a uma floresta natural. Os SAFs podem ser baseados em consórcios simultâneos, onde várias culturas são cultivadas juntas, ou em consórcios em sequência, onde diferentes culturas são cultivadas em rotação ao longo do tempo (GLIESSMAN, 2009).

Na região Litoral Norte do Estado do Rio Grande do Sul os SAFs são constituídos pela conversão de bananais convencionais em bananais agroflorestais, denominados de sistemas silvibananeiros. Além deste sistema, a presença de consórcio de variedades de bananeiras (*Musa* sp), palmito juçara (*Euterpe edulis* Mart), árvores nativas, frutíferas, e uma diversidade de plantas não arbóreas nativas e exóticas, manejadas no sistema de agricultura ecológica, são exercidos pelos agricultores familiares da região, com apoio técnico e científico de organizações não governamentais, como exemplo o Centro Ecológico (CE) – Litoral Norte (AMARAL et al., 2021).

Os SAFs silvibananeiros nesta região do país, desempenham um papel significativo na economia regional, um número crescente de agricultores está adotando práticas de cultivo em sistemas agroflorestais e produções orgânicas, contando com o suporte técnico do CE. Neste contexto, é essencial promover e apoiar esses métodos de produção, uma vez que demonstram um compromisso com práticas de manejo de baixo impacto ambiental, e também apresentam

potencial na retenção de carbono e mitigação das emissões de CO_{2eq} na vegetação acima do solo que está intrinsecamente ligada à questão das mudanças climáticas.

A relação entre biomassa e os ecossistemas da Mata Atlântica, especialmente em sistemas agroflorestais (SAFs), é crucial para compreender a dinâmica ambiental e a sustentabilidade. A biomassa vegetal nos SAFs desempenha um papel fundamental na regulação do carbono atmosférico e na manutenção da biodiversidade. A precisão na quantificação do carbono e CO_{2eq} armazenado no sistema está intrinsecamente relacionada à precisão das estimativas da biomassa (SHI; LIU; 2017). Métodos diretos para avaliar a biomassa envolvem frequentemente extensas campanhas de campo e etapas de laboratório, às vezes sem a obtenção de todos os dados necessários para modelar e espacializar esse parâmetro.

Como alternativa, o sensoriamento remoto (SR) oferece potencial para a quantificação dessas variáveis em SAFs devido à sua capacidade de capturar imagens em grandes áreas com pouca intervenção manual, juntamente com múltiplas resoluções espaciais, espectrais e radiométricas (DE LIMA et al., 2022).

Modelos de quantificação indireta baseiam-se em variáveis dendrométricas para uso em equações alométricas e dados de SR, onde a relação entre a variação da biomassa e as propriedades espectrais das imagens é considerada para estabelecer correlações significativas (BOLFE et al., 2012; WATZLAWICK et al., 2009). Embora essa abordagem tenha sido testada ao longo de vários anos, ainda não foi amplamente adotada. Portanto, análises e validações adicionais dos resultados são necessárias para abordar os fluxos de carbono em SAFs (LU et al., 2005; LU et al., 2019).

A estimativa de biomassa é frequentemente realizada com uso de dados obtidos por sensores remotos embarcados em satélites ou outras plataformas/veículos e mais recentemente adotando o uso de Aeronaves Remotamente Pilotada (RPAs), também conhecidas popularmente como drones. Goetz et al. (2009) e Bolfe et al. (2012) estimaram a biomassa usando sensoriamento remoto orbital. Estes trabalhos demonstraram a viabilidade dessa abordagem, além de ser uma alternativa com valor mais baixo para aquisição de imagens em relação as RPAs, quando utilizado satélites que disponibilizam imagens gratuitas, como CBERS 04A e Sentinel 2 (DE LIMA et al., 2022). Porém, com o uso de RPAs tem-se as principais vantagens a alta resolução espacial, muitas vezes da ordem de centímetros, o que permite um detalhamento mais preciso do terreno-alvo (FORNACE et al., 2014; TORRES-SÁNCHEZ et al., 2014) e a versatilidade do usuário definir a data das coletas de dados conforme sua necessidade.

As variações espaciais, a densidade e as condições fisiológicas das plantas podem ser melhor avaliadas por meio de índices de vegetação (IVs) baseados na relação matemática entre as bandas espectrais de refletância (SAKAMOTO et al., 2012) a partir de imagens geradas por sensores embarcados em RPAs (DE LIMA et al., 2022) ou em satélites. A biomassa acima do solo (BAS) é uma variável crucial na quantificação do estoque de carbono e no seu sequestro atmosférico, sendo um serviço ecossistêmico estratégico para a tomada de decisões (TEMESGEN et al., 2015). A obtenção de estimativas precisas de BAS para a quantificação de carbono (C) e dióxido de carbono equivalente ($\text{CO}_{2\text{eq}}$), depende principalmente de métodos eficientes de coleta de dados e monitoramento ao longo do tempo (BONIN et al., 2018). No entanto, o monitoramento e as estimativas de $\text{CO}_{2\text{eq}}$ em sistemas agroflorestais apresentam um desafio complexo devido à diversidade de espécies envolvidas (REZENDE et al., 2006). Estes desafios envolvem ampliar a aplicação de novas tecnologias e metodologias para estimar BAS para a quantificação de C e $\text{CO}_{2\text{eq}}$ estocados acima do solo, que possam ser precisas e economicamente viáveis, sendo atualmente uma necessidade para os SAFs.

Neste contexto, essa pesquisa busca estabelecer um modelo, através da correlação da estimativa de BAS, C e $\text{CO}_{2\text{eq}}$ na vegetação acima do solo mensurados por equações alométricas, com dados de sensoriamento remoto obtidos de diferentes sensores, para isso utilizando análise fatorial para entender as correlações entre as variáveis e inteligência artificial (Redes Neurais Artificiais) para estabelecer modelos de $\text{CO}_{2\text{eq}}$. Deste modo se valoriza ainda mais os sistemas agroflorestais, para seu reconhecimento e seu potencial na contribuição para a sustentabilidade ambiental, mas também oferecendo uma alternativa economicamente viável para a estimativa dessas variáveis. Portanto, esta pesquisa busca também contribuir no conhecimento científico, podendo fornecer diretrizes valiosas para a tomada de decisões relacionadas à conservação e ao desenvolvimento sustentável no Litoral Norte do Estado do Rio Grande do Sul, Brasil.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo deste estudo foi elaborar modelos para a estimativa de $\text{CO}_{2\text{eq}}$, utilizando dados de sensoriamento remoto obtidos de diferentes sensores, para isso utilizando ferramentas estatísticas e inteligência artificial.

1.1.2 Objetivos específicos

- Quantificar BAS para estimar o $\text{CO}_{2\text{eq}}$, utilizando método indireto através de equações alométricas já estabelecidas em outras pesquisas, através de dados dendrométricos obtidos a campo na área de estudo na região do litoral norte do Rio Grande do Sul.
- Realizar levantamento de dados de diferentes sensores para obtenção das bandas espectrais e índices de vegetação para estimar $\text{CO}_{2\text{eq}}$ utilizando o método indireto e através de Redes Neurais Artificiais;
- Entender as relações entre os valores de $\text{CO}_{2\text{eq}}$ estimados pelo método indireto com os dados do sensoriamento remoto obtidos de diferentes sensores;
- Propor um modelo final que possa ser replicado para estimativa de $\text{CO}_{2\text{eq}}$ estocado acima do solo através de dados de sensoriamento remoto na região do estudo.

2 REVISÃO DE LITERATURA

2.1 SISTEMAS AGROFLORESTAIS: CONTRIBUIÇÕES PARA A MITIGAÇÃO DO EFEITO ESTUFA E SEQUESTRO DE CARBONO

Em 1977, o Centro Internacional de Pesquisa Agroflorestal (ICRAF), também conhecido como *International Center for Research in Agroforestry*, recomendou a expansão dos estudos agrícolas e florestais em propriedades rurais. Essa recomendação resultou na criação do termo "agrofloresta", que se refere à prática de integração da agricultura e da silvicultura em um mesmo sistema produtivo. (YOUNG, 2003). Recentemente, a agrofloresta tem sido reconhecida como uma ciência multidisciplinar que se concentra no estudo do agroecossistema e envolve o diálogo com saberes tradicionais para desenvolver novos conhecimentos ecológicos (MANSANI et al., 2022).

O ambiente agroflorestal apresenta características como elevada biodiversidade, estrutura complexa e grande quantidade de biomassa, e também pode ser usada para aumentar a conectividade em paisagens florestais fragmentadas (HAGGAR et al., 2019). Além disso, esse modelo de agricultura explora a relação ecológica entre plantas e animais, contribui para a preservação do solo através da ciclagem de nutrientes e combate à erosão. Outra vantagem é a melhor utilização da radiação solar e a dispensa do uso de adubos químicos, no caso dos sistemas que adotam a abordagem da agricultura orgânica (OLIVEIRA et al., 2010).

Os principais objetivos dos SAFs é maximizar a utilização da terra, combinando a produção florestal com a produção de alimentos. Nesse sistema, várias espécies nativas são plantadas, gerando diversos produtos em diferentes épocas do ano, o que proporciona maior rentabilidade para o agricultor e preserva a biodiversidade local. Assim, os SAFs podem ajudar a resolver questões relacionadas ao uso sustentável de recursos naturais e socioeconômicos (ALABARCE et al., 2016).

Anteriormente, de acordo com o antigo Código Florestal (Lei nº 4771/1965), o manejo agroflorestal sustentável só era permitido em áreas de Reservas Legais (RLs) de pequenas propriedades rurais. Isso limitava consideravelmente a área disponível para a agricultura nessas propriedades. No entanto, com a introdução do Novo código Florestal (Lei nº 12651/2012), às pequenas propriedades rurais agora têm permissão para utilizar sistemas agroflorestais em suas áreas de Preservação Permanente (APPs) e RLs, desde que esses sistemas sejam gerenciados de forma sustentável e submetidos a planos de manejo aprovados pelo órgão estadual do meio ambiente responsável (GUERRA, 2012).

Os SAFs têm se mostrado uma alternativa sustentável para a agricultura e a produção de alimentos. No Litoral Norte do Estado do Rio Grande do Sul, os SAFs têm sido utilizados como uma estratégia para a conservação ambiental e a melhoria da qualidade de vida das comunidades locais (BORGES et al. 2015). Estudos têm demonstrado que os SAFs nessa região são capazes de aumentar a biodiversidade, melhorar a qualidade do solo, reduzir o uso de pesticidas e herbicidas, aumentar a produtividade das culturas e aumentar a renda dos agricultores locais (DA ROCHA et al. 2021).

A proposta de SAF na região começou em 1990, por alguns técnicos do Centro Ecológico e pelo engenheiro agrônomo, Jorge Luiz Vivam, que na época atuava na Empresa de Assistência Técnica e Extensão Rural do Estado do Rio Grande do Sul (EMATER). A proposta do SAF na região, sempre foi o consórcio de banana, principal cultivo das áreas de encosta, com outras espécies da Mata Atlântica, entre elas a *Euterpe edulis*, conhecida como palmeira juçara (VIEIRA et al. 2022).

O Centro Ecológico é uma organização não governamental que desde 1985 trabalha para viabilizar a produção agrícola sustentável por meio da adoção de tecnologias e alternativas pautadas no conceito de proteção ambiental. Também estimula a organização de agricultores familiares na produção, no processamento e na comercialização dos produtos ecológicos.

Os SAFs são práticas de uso da terra que têm como objetivo integrar árvores e arbustos em sistemas de cultivo e/ou pecuária. De acordo com Wilson e Lovell (2016), existem cinco grandes categorias de SAF que sequestram mais carbono do que a agricultura tradicional. A silvopastura, por exemplo, integra árvores em pastagens com gado e pode armazenar 45% mais biomassa acima do solo (BAS) do que pastagens perenes (UDAWATTA E JOSE, 2012).

Já as fileiras de árvores e/ou arbustos são integradas com culturas agrônômicas ou hortícolas, permitindo a vegetação perene adjacente aos corpos d'água. A agricultura florestal, que é a forma mais complexa de SAF, inclui uma mistura diversificada de espécies perenes modeladas para imitar florestas naturais, além de outros elementos como aléias, quebra-ventos e cinturões de abrigo, que são plantados adjacentes a cultivos ou áreas de pastagem de forma linear para proteção contra o vento (GARRETT e BUCK, 1997). Os cultivos de sub-bosque multicamadas, a biomassa lenhosa e o carbono do solo no SAF podem sequestrar cerca de 0,29 a 15,21 Mg.ha.ano⁻¹ de AGB (NAIR et al., 2010), o que torna essa prática uma das soluções climáticas naturais mais promissoras (GRISCOM et al., 2017).

Para estimular que o uso dos SAFs seja uma solução efetiva para as mudanças climáticas, é necessário monitorar a biomassa e carbono e seus impactos econômico. A medição da quantidade de biomassa acima do solo, pode ser realizada através do sensoriamento remoto,

através de sensores acoplados em RPAs. O sensoriamento remoto é uma técnica que utiliza a radiação refletida e emitida à distância para avaliar as características físicas da cobertura do solo (WANG et al., 2019).

Porém a medição realizada diretamente no local de interesse, que é realizada por meio de observações de campo junto a utilização de equações matemáticas, é ainda considerada mais precisa do que o método de sensoriamento remoto, que depende de instrumentos remotos, sendo mais dispendiosa e apresentando limitações de cobertura espacial. Contudo, muitos trabalhos têm sido elaborados em busca da quantificação de Carbono e Biomassa acima do solo através do sensoriamento remoto em conjunto com a inteligência artificial, mostrando-se promissoras a complementar ou até mesmo substituir as medições a campo ou possibilitando a quantificações em áreas remotas, com difícil acesso.

2.1.1 ATUAÇÃO DO CENTRO ECOLOGICO NOS SAFs DO LITORAL NORTE DO RS

O Centro Ecológico é uma Organização Não Governamental (ONG) com sede na cidade de Dom Pedro de Alcântara no Rio Grande do Sul, Brasil, onde desempenha um papel fundamental na promoção e assistência aos sistemas agroflorestais na região. Fundada com o propósito de fomentar práticas agrícolas sustentáveis, o Centro Ecológico concentra seus esforços na promoção da agroecologia e na difusão de conhecimentos relacionados à integração de árvores e cultivos em sistemas agrícolas. A organização oferece uma ampla gama de serviços, incluindo capacitação técnica para agricultores, disseminação de boas práticas agrícolas, desenvolvimento de modelos de sistemas agroflorestais adaptados à região e suporte na implementação de projetos agroecológicos.

Além disso, o Centro Ecológico também desempenha um papel crucial na promoção da conservação ambiental, trabalhando para restaurar ecossistemas degradados e mitigar os impactos ambientais negativos da agricultura convencional. Sua atuação tem contribuído significativamente para o fortalecimento da agricultura sustentável e a preservação da biodiversidade na região sul do Brasil.

O Centro Ecológico está desenvolvendo o projeto que se intitula como “Combinação de renda e proteção florestal no Sul do Brasil”, este projeto tem como objetivo avaliar e valorizar os serviços ambientais associados às suas áreas gerenciadas e fragmentos florestais. Espera-se um avanço substancial na demonstração da viabilidade técnica e financeira de sistemas agroflorestais complexos, como um modelo de uso da terra mais adequado aos desafios climáticos. Além disso, o projeto servirá de modelo para empreendimentos semelhantes

localizados no domínio da Mata Atlântica e em outros lugares. Uma das métricas que o projeto busca estimar é o CO_{2eq} estocado na vegetação acima do solo, sendo proposta uma estimativa de 4 mil Mg de CO_{2eq} em SAFs na região do litoral norte do Rio Grande do Sul.

Para isso, foi estabelecida entre a Universidade Federal de Santa Maria (UFSM) e o Centro Ecológico uma parceria para atender à demanda do projeto "Combinação de renda e proteção florestal no Sul do Brasil". Um dos objetivos deste projeto é a avaliação das emissões de dióxido de carbono equivalente (CO_{2eq}) nos Sistemas Agroflorestais (SAFs) da região de estudo. Deste modo busca-se através de dados de sensoriamento remoto estabelecer modelo para estimar CO_{2eq} com precisão e baixo custo. A expertise da UFSM em sensoriamento remoto e análise de dados geoespaciais com a experiência prática do Centro Ecológico na gestão e promoção de práticas agroflorestais sustentáveis, estabelece uma sinergia com o potencial de fornecer informações críticas para a avaliação do impacto ambiental, contribuindo para o avanço do conhecimento científico e para a tomada de decisões nos SAFs na região do Sul do Brasil.

2.2 SENSORIAMENTO REMOTO


O sensoriamento remoto é uma disciplina científica que se concentra na aquisição de informações sobre a Terra e seus objetos a partir de sensores localizados em plataformas espaciais, aéreas ou terrestres, sem a necessidade de contato físico direto. Esse campo envolve a captação e análise de dados de diversos tipos, como imagens de satélites, fotografia aérea, dados de sensores infravermelhos, radar e lidar. Os princípios subjacentes ao sensoriamento remoto são baseados na interação da radiação eletromagnética com a superfície da Terra, permitindo a obtenção de informações valiosas sobre características geográficas, ambientais e atmosféricas. O sensoriamento remoto desempenha um papel fundamental em várias áreas científicas, como a geologia, a ecologia, a climatologia e a gestão de recursos naturais, fornecendo uma visão abrangente e não invasiva do planeta. (PONZONI et al., 2004).

Com o avanço das tecnologias espaciais, através de dados de satélite ou imagens obtidas por RPAs e com o aprimoramento dos algoritmos de classificação de imagem, a utilização do sensoriamento remoto para mapeamento de uso e cobertura da terra, tem se tornado cada vez mais difundida (CAON et al., 2019). A classificação de imagens para a produção de mapas temáticos é uma das aplicações mais comuns do sensoriamento remoto, e estudos voltados para o mapeamento da sucessão da vegetação têm se intensificado nos últimos anos (LU et al., 2014). No entanto, a classificação de imagens de alta resolução, como aquelas com 10 cm de resolução, ainda é um grande desafio.

A radiação eletromagnética emitida pelo sol e captada pelos sensores, quando atinge a vegetação, ela é refletida, transmitida, absorvida ou dispersa pela vegetação, dependendo das características dos tecidos vegetais, como pigmentos, estrutura celular e densidade (PONZONI et al., 2009). O comportamento da reflectância da vegetação é o que permite realizar a leitura do estado da vegetação, como vigor ou estresse provocado por algum fator climático ou por alguma doença e também permitindo realizar a classificação dos diferentes objetos da natureza.

A reflectância varia nas diferentes bandas espectrais do espectro eletromagnético. No espectro do visível (400-700 nm), a vegetação apresenta alta reflectância na região da banda verde (550 nm), devido à reflexão da luz pelas células vegetais e pela superfície das folhas, e alta absorção na banda do vermelho (680 nm) devido à absorção da radiação pela clorofila e outros pigmentos nas folhas. Já na banda do infravermelho próximo (*Near infrared* – NIR) (700-1300 nm), a reflectância da vegetação é mais alta quando as plantas estão saudáveis, resultante da defesa das mesmas a comprimentos de onda que são deletérios às células e à fisiologia (PONZONI et al., 2015). Na região do NIR também é possível distinguir a vegetação de outras superfícies, como solo e água, devido à diferença em suas assinaturas espectrais. A Figura 1 ilustra o espectro de reflectância da vegetação.

Figura 1 - Comportamento espectral da vegetação.



Fonte: Moreira (2007).

A interação da radiação eletromagnética com a vegetação é complexa e depende de diversos fatores, como a espécie vegetal, a idade da planta, a densidade foliar, a umidade do solo, entre outros. O entendimento dessas interações é fundamental para o uso correto das

técnicas de sensoriamento remoto na análise e monitoramento da vegetação. (PONZONI, 2009).

2.2.1 AERONAVE REMOTAMENTE PILOTADA

A utilização crescente de RPA para diferentes usos, se justifica principalmente pela capacidade de voo a baixa altitude e pela coleta de imagens de alta resolução, que proporcionam informações cruciais sobre as culturas e o solo. Dentre as tecnologias predominantes em RPA, destacam-se os sensores RGB (Red, Green, Blue) e multiespectrais (ZHANG et al., 2019).

O modo de operação de uma RPA consiste na elaboração de um plano de voo da área a ser mapeada, onde serão definidos de acordo com o operador e à necessidade de detalhamento das imagens, a altura de voo, a sobreposição lateral e longitudinal das imagens (MORGAN; FALKNER, 2002) e o GSD (*Ground Sample Distance*), responsável pela definição do mapa e podendo variar de acordo com a finalidade à qual o mapeamento está sendo feito.

A aeronave segue rigorosamente o plano de voo, aderindo estritamente às especificações preestabelecidas de altitude e sobreposição. Este processo se desenvolve em múltiplas passagens até que a totalidade da área seja integralmente mapeada. Durante essas operações, os sensores RGB e/ou multiespectrais capturam imagens que incorporam informações de coordenadas geográficas em seu registro, ângulos de rotação de cada imagem nos eixos x,y e z (Parâmetros de Orientação Externa da Imagem), distância focal, coeficientes de distorções, coordenada principal e dimensões da placa geradora de imagens (Parâmetros de Orientação Interna da Imagem), as quais serão posteriormente empregadas para a realização do alinhamento das fotografias, geração de nuvens de pontos homólogos e a subsequente geração de modelo numérico de superfície e/ou do terreno (MDS/MNT) ortomosaico e cálculo dos índices de vegetação (AHMAD et al., 2020).

2.2.2 PLATAFORMAS ORBITAIS E SENSORES

Atualmente, a utilização de satélites para a aquisição de dados de sensoriamento remoto tem se tornado uma ferramenta fundamental em diversas áreas de pesquisa. A disponibilidade de uma variedade de satélites equipados com sensores de diferentes resoluções espaciais e espectrais oferece uma riqueza de informações para cientistas e pesquisadores. Essas imagens de satélite, com resoluções que variam desde metros até centímetros por pixel, permitem a condução de estudos abrangentes em campos como a monitoramento ambiental, agricultura de

precisão, estudos climáticos, detecção de mudanças na cobertura terrestre, gestão de recursos naturais e mapeamento urbano. Esses avanços na tecnologia de sensoriamento remoto desempenham um papel crucial na compreensão e abordagem de questões críticas relacionadas ao meio ambiente e ao desenvolvimento sustentável, oferecendo valiosos insights para uma ampla gama de pesquisas interdisciplinares (PRUDKIN, 2019).

O satélite CBERS-4A, objeto da cooperação entre Brasil e China, é reconhecido por sua capacidade de fornecer imagens gratuitas de sensoriamento remoto de alta resolução espacial, beneficiando pesquisas ambientais e agrícolas. Da mesma forma, o satélite Sentinel-2A, pertencente ao programa Copernicus da União Europeia, oferece dados gratuitos de alta qualidade, permitindo análises precisas de uso da terra, cobertura vegetal e monitoramento da qualidade da água. Ambos desempenham papéis essenciais na pesquisa científica, proporcionando disponibilidade acessível a informações valiosas para uma variedade de estudos (INPE, 2020).

O Programa CBERS foi concebido a partir de uma colaboração pioneira no campo da tecnologia e ciência espacial entre o Brasil e a China. Isso possibilitou a entrada do Brasil em um grupo exclusivo de nações que detêm a capacidade de gerar dados primários por meio de sensoriamento remoto. O CBERS- 4A é um satélite de sensoriamento remoto de média resolução equipado com uma carga útil óptica operando no espectro visível com faixa de resolução de 2 a 60 metros. Suas imagens são utilizadas para diversas finalidades no monitoramento ambiental, entre as quais pode se destacar o controle de desmatamento, queimadas, monitoramento de recursos hídricos, ocupação do solo, entre outros (INPE, 2020).

O CBERS 4A possui três sensores diferentes, o primeiro sensor é a câmera Multiespectral (MUX), que possui três bandas no visível e uma banda no infravermelho com resolução espacial de 16 m. Já o outro sensor é a câmera de Campo Largo (WFI) que também possui três bandas no visível e uma banda infravermelha, espacialmente resolvido, a faixa é de 55 m. Por último, o terceiro sensor, a Wide Scan Multispectral and Panchromatic Camera (WPM), com três bandas do visível e uma do infravermelho, cada uma com resolução espacial de 8 m e banda pancromática de 2 m (INPE, 2020). A câmera imageadora utilizada nesta pesquisa foi a multiespectral Pancromática de Ampla Varredura (WPM) com bandas Blue, Green, Red e Nir de 8m de resolução espacial e uma banda pancromática de 2m de resolução, a revisita do satélite é de 31 dias.

O satélite Sentinel-2A, parte do programa Copernicus da União Europeia, destaca-se por suas notáveis propriedades que o tornam uma ferramenta de valor inestimável para pesquisas em diversas áreas. Equipado com um sistema ótico multiespectral de alta resolução,

o Sentinel-2A oferece imagens entre 10 a 60 metros de resolução espacial em 13 bandas espectrais, proporcionando uma visão abrangente da superfície terrestre. Essa combinação de alta resolução espacial e espectral possibilita a detecção precisa de mudanças na cobertura vegetal, tornando-o particularmente adequado para estudos de florestas e sistemas agroflorestais. (SENTINEL hub, 2023).

O Sentinel-2A tem sido amplamente utilizado em pesquisas relacionadas ao monitoramento de florestas e sistemas agroflorestais. Suas imagens de alta qualidade permitem a identificação de mudanças na cobertura florestal, o mapeamento de áreas desmatadas, a avaliação da saúde das florestas e a detecção de incêndios florestais entre outras. Além disso, sua capacidade de monitorar a vegetação em múltiplas bandas espectrais é fundamental para o estudo da produtividade agrícola, a identificação de pragas e doenças e a otimização de práticas de manejo em sistemas agroflorestais. Dessa forma, o Sentinel-2A desempenha um papel crucial no avanço do conhecimento e na promoção de práticas sustentáveis em ecossistemas florestais e agrícolas em todo o mundo. (BORGES, 2017).

Estudo conduzido em sistema agroflorestal nos Andes Colombianos, conduzido por BOLIVAR et al. (2021) utilizando variáveis espectrais derivadas de imagens do Sentinel 2 para prever a biomassa acima do solo, índice de área foliar (IAF) e fechamento do dossel (CC), usando modelos de regressão Random Forest, conseguiram bons ajustes para AGB com R^2 0,92 e RMSE relativo de 34, com isso mostrando a capacidade de estimar biomassa acima do solo, utilizando dados de sensoriamento remoto, permitindo mapear estas importantes variáveis ecossistêmicas à escala de paisagem.

2.2.3 ÍNDICES DE VEGETAÇÃO

Um índice de vegetação é obtido por meio do processo de fusão da medida da radiação eletromagnética refletida pela cobertura vegetal em faixas espectrais específicas do espectro eletromagnético. Essas faixas espectrais estão intrinsecamente relacionadas com a quantidade e a condição da vegetação (COURA, 2007).

A composição espectral do fluxo radiante que emana da superfície da Terra fornece informações sobre as propriedades físicas do solo, da água e da vegetação características em ambientes terrestres. Técnicas, modelos e índices de sensoriamento remoto são projetados para converter esta informação espectral em um formato que seja facilmente interpretável. No entanto, as interações fundamentais da energia radiante com a superfície da Terra devem ser

compreendidas para que o sensoriamento remoto seja aplicado de forma eficiente (HUETE, 1989)

A quantificação de índices de vegetação a partir de imagens obtidas por RPA e satélites desempenha um papel fundamental na avaliação de sistemas agroflorestais. Autores como Rizzi e Rudorff (2007) destacam que diferentes índices de vegetação, fornecem uma medida objetiva da saúde vegetal e da distribuição espacial da cobertura vegetal, podendo ser utilizados em diferentes parâmetros biofísicos, como a biomassa aérea.

Em pesquisas de quantificação de biomassa em florestas, índices de vegetação obtidos das bandas espectrais do visível e multiespectral, sendo as bandas Blue (azul), Green (verde), Red (vermelho), RedEdge (Borda do vermelho) e NIR (Infravermelho próximo) desempenham um papel significativo. O NDVI (índice de vegetação por diferença normalizada da banda verde), calculado a partir das bandas Red e NIR, é frequentemente utilizado para avaliar a saúde e densidade da vegetação, além disso, o GNDVI (Índice de Vegetação Green Normalizado) incorpora a banda Green para proporcionar uma visão mais equilibrada da cobertura vegetal, melhorando a estimativa de biomassa (BARBOSA et al. 2017).

O uso de índices de vegetação, calculados por bandas espectrais do visível e multiespectrais tem se destacado como uma ferramenta eficaz para o monitoramento em florestas. Os índices de vegetação desempenham um papel crucial na avaliação da saúde das florestas, permitindo a detecção de mudanças em parâmetros-chave, como a densidade da vegetação e a qualidade das folhas, com base em dados espectrais de satélites e sensores (PONZONI et al., 2009). Essas técnicas têm sido amplamente utilizadas para estudar as dinâmicas florestais, identificar áreas de degradação e auxiliar na gestão sustentável desses ecossistemas.

Esses dados são cruciais para compreender a relação entre a biomassa, o carbono e as concentrações de dióxido de carbono ($\text{CO}_{2\text{eq}}$) em sistemas agroflorestais. Pesquisas recentes, como as de Bolfe et al. (2012), Fonseca (2020) e Sousa et al. (2021) demonstram que os índices de vegetação são indicadores valiosos para estimar o estoque de carbono e suas mudanças ao longo do tempo em SAFs.

2.2.4 OBTENÇÃO DE ÍNDICES DE VEGETAÇÃO COM SENSORES EMBARCADOS EM RPA E SATÉLITES PARA QUANTIFICAÇÃO DE CO_{2eq} NA VEGETAÇÃO ESTOCADO ACIMA DO SOLO

A utilização de imagens obtidas por RPA e satélites, como o CBERS 4A e o Sentinel-2 entre outros, tem se mostrado de grande relevância na quantificação de índices de vegetação, sendo utilizados para diversas análises, como respostas na produtividade, ataque por pragas, doenças e relações com a quantificação de biomassa e carbono aéreo, entre outros (BORGES et al., 2017; BOLIVAR-SANTAMARIA et al., 2021)

O sensoriamento remoto óptico de alta resolução espacial tem apresentado em diversos estudos a capacidade de proporcionar informações precisas, para prever atributos estruturais de compartimentos florestais como a biomassa e sua mudança ao longo do tempo, permitindo extrapolações para escalas maiores (KERSHAW et al., 2017).

Com a intensificação das mudanças climáticas, os governos que assinaram o protocolo de Kyoto têm buscado alternativas e acordos para a redução de gases do efeito estufa (GEE), um dos principais elementos químicos responsáveis pelo efeito estufa é o dióxido de carbono (CO_{2eq}). Por ser o único GEE a ser capturado e estocado pelas plantas em sua biomassa pelo processo da fotossíntese (PACHECO; HELENE, 1990), tem se buscado realizar alternativas mais sustentáveis na agricultura, que apresentam manejo sustentável com o menor impacto, deste modo armazenando um maior valor de carbono estocado, exemplo disso são os sistemas agroflorestais e produção ecológica que apresenta a interação de diferentes culturas agronômicas e árvores.

Neste contexto, o mercado de carbono, também conhecido como comércio de emissões de carbono, emergiu como um instrumento destinado a facilitar a implementação das políticas de mitigação das emissões de GEE. Sua instauração teve início inicialmente através do Protocolo de Quioto, que viabilizou o estabelecimento de um mercado de âmbito global envolvendo os signatários do tratado (SOUZA et al., 2010).

Buscando encontrar formas de quantificação de biomassa e carbono em larga escala, pois a obtenção a campo em muitos casos é onerosa e requer maiores recursos financeiros, o Sensoriamento remoto é uma alternativa promissora, com diversos estudos nos últimos anos, trazendo cada vez mais aprimoramento das metodologias utilizadas.

A obtenção dos índices de vegetação (IVs) é fundamental para entender a dinâmica da vegetação em SAFs, uma vez que estão diretamente relacionados com a saúde e a produção vegetal. Esses índices, quando correlacionados com valores de biomassa, carbono e CO_{2eq},

possibilitam a avaliação da capacidade de sequestro de carbono e mitigação das emissões de CO_{2eq} em SAFs, contribuindo para práticas agrícolas mais sustentáveis. Pesquisas como as conduzidas por (BOLFE, 2012) têm demonstrado como essa abordagem integrada pode fornecer insights valiosos para o manejo eficaz de SAFs e proporcionar oportunidades financeiras com o mercado do carbono.

No entanto, é importante destacar que a aplicação dessas técnicas requer considerações específicas em relação às características dos SAFs e à seleção adequada de índices de vegetação para a região em estudo. A validação e calibração dos resultados com medições em campo são etapas cruciais, conforme ressaltado por (BROWN, 1997; KUMAR; NAIR, 2011), para garantir a precisão das estimativas de BAS, C e CO_{2eq} a partir de imagens de sensoriamento remoto. Em conjunto, esses estudos reforçam a relevância das imagens de RPA e dos diferentes satélites disponíveis para avaliação, monitoramento e permitindo estimar o carbono em busca de valorizar os SAFs, com implicações significativas para a gestão sustentável da vegetação e recursos naturais no Brasil.

2.3 ANÁLISE MULTIVARIADA FATORIAL PARA CORRELAÇÃO DE VARIÁVEIS

No geral, a análise multivariada refere-se à aplicação de métodos estatísticos que simultaneamente examinam múltiplas medidas em relação a cada indivíduo ou objeto sob investigação. Qualquer abordagem que leve em consideração simultaneamente mais de duas variáveis podem ser classificadas como análise multivariada (HAIR JÚNIOR et al., 2005). A necessidade de compreender as interações entre várias variáveis aleatórias confere à análise multivariada um considerável potencial de aplicação na área de recursos naturais (JOHNSON; WICHERN, 1988).

Conforme Lourenço e Matias (2001), as técnicas estatísticas multivariadas demonstram uma complexidade superior àquelas empregadas na estatística univariada. Apesar da notável complexidade teórica embasada na matemática, as técnicas multivariadas capacitam o pesquisador a lidar com múltiplas variáveis simultaneamente, proporcionando, assim, um conjunto de dados substancialmente robusto para a análise das informações da pesquisa. Buscando compreender as correlações dos valores de BAS e C e CO_{2eq} estocado na vegetação acima do solo com os valores de índices de vegetação quantificados através de imagens obtidas por RPA e satélites CBERS 4A e Sentinel-2 é importante escolher métodos estatísticos capazes de explicar essas interações.

A análise multivariada representa um conjunto de metodologias estatísticas que viabiliza a avaliação e interpretação de conjuntos de dados de natureza quantitativa, caracterizados por uma elevada quantidade de variáveis, de maneira simplificada (NEISSE; HONGYU, 2016). A emergência das técnicas multivariadas está intrinsecamente associada aos avanços tecnológicos e à utilização de computadores para a condução de análises estatísticas.

Para aplicar a análise fatorial é necessário testar se os dados estão suficientemente ligados para se proceder à análise. Para tal podem ser utilizados o teste de Kaiser-Meyer-Olkin Measure of Sampling Adequacy (KMO) e o teste de Bartlett, que mede a adequação dos dados, sendo um teste de significância para as correlações, pois desta forma tem se a certeza se a correlação é significativa ou não (VICINI, 2005). Possibilitando mostrar se os estudos não devem ser feitos de forma isolada, mas sim de maneira conjunta, com a utilização de uma técnica adequada, podendo ser a utilização da análise de componentes principais (ACP).

É relevante destacar que a análise fatorial (AF) se distingue de abordagens dependentes, como a regressão múltipla, onde uma variável é designada como a variável dependente (ou resposta), enquanto as demais são tratadas como variáveis independentes (ou explicativas). A análise fatorial, por sua vez, constitui-se como um método de natureza interdependente, em que todas as variáveis em análise são consideradas simultaneamente. Nesse contexto, cada variável é prevista com base em todas as outras variáveis, evidenciando uma interligação intrínseca entre elas. Assim, enquanto as técnicas dependentes são orientadas para a previsão e explicação de fenômenos, as técnicas interdependentes têm como objetivo primordial a identificação de estruturas subjacentes (HAIR et al., 2009).

A AF desempenha o papel de elucidar a estrutura das covariâncias existentes entre as variáveis mediante a utilização de um modelo estatístico causativo. Este método pressupõe a presença de p variáveis não observadas, subjacentes aos dados observados. Os fatores, nesta abordagem, representam o que existe de comum nas variáveis originais, (REIS, 1997). Portanto, a análise multivariada fatorial desempenha um papel fundamental na decomposição e na explicação das estruturas subjacentes que influenciam as relações entre as variáveis, fornecendo valiosas informações em diversas áreas da pesquisa, para tomadas de decisões.

2.4 ANÁLISE DE REDES NEURAIS ARTIFICIAIS PARA MODELAGEM DE EQUAÇÕES

Outra abordagem que vem sendo muito utilizada para resolver problemas complexos, como correlacionar e interpretar banco de dados com inúmeras variáveis é o uso de Redes Neurais Artificiais (RNA). Sendo muito utilizada para correlacionar e interpretar resultados

obtidos com outras técnicas de estatísticas, possibilitando um *insight* mais claro em diversas áreas, incluindo pesquisa de mercado, marketing de banco de dados, análise financeira, análise de variáveis ambientais entre outras.

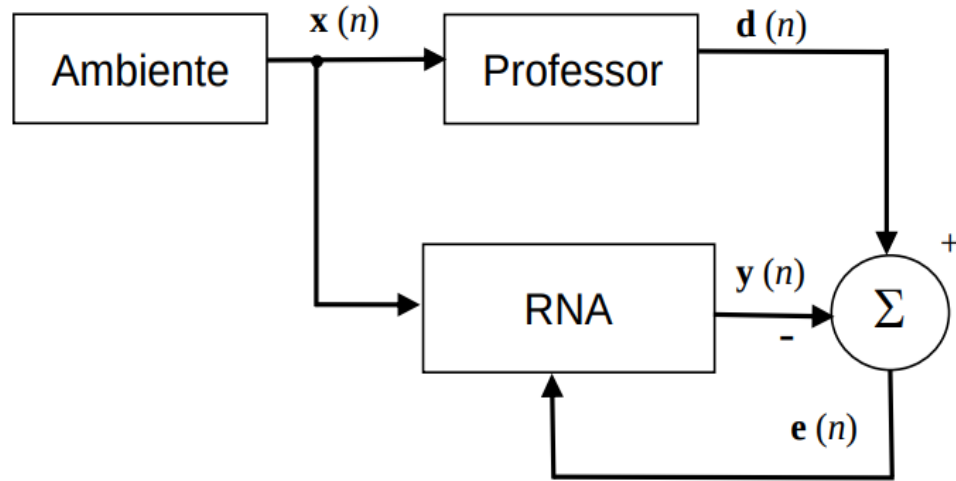
A arquitetura de uma Rede Neural Artificial (RNA) se refere à organização e estrutura da rede, incluindo a disposição dos neurônios e suas conexões sinápticas, destacando-se os seguintes tipos (SILVA; SPATTI; FLAUZINO, 2012):

- **FeedForward de Camada Simples:** consiste em uma única camada de entrada associada a um ou mais neurônios, responsáveis por gerar a resposta de saída desejada. O fluxo de dados ocorre em uma direção, em direção à camada de saída. Essa arquitetura é principalmente aplicada em problemas de classificação de padrões e filtragem.
 - **FeedForward de Camadas Múltiplas:** esta arquitetura envolve múltiplas camadas, em que as informações passam de uma camada para a próxima, permitindo uma maior complexidade na modelagem de problemas. É frequentemente usada em tarefas que exigem aprendizado profundo e extração de recursos complexos.
 - **FeedForward de Camadas Múltiplas:** neste tipo de arquitetura existem camadas entrada e saída. Essa arquitetura é predominantemente empregada em problemas que envolvem a aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos.
 - **Recorrente ou Realimentada:** as saídas dessa arquitetura são reintroduzidas como entradas em uma nova camada de neurônios, criando um ciclo de retroalimentação. As
- Parte superior do formulário

O processo de aprendizado de uma RNA ocorre mediante uma sequência de etapas. Inicialmente, a RNA é submetida a estímulos provenientes do ambiente circundante. Posteriormente, seus parâmetros são sujeitos a modificações em resposta a essa estimulação. Por fim, a RNA demonstra uma capacidade de resposta diferenciada devido às alterações ocorridas em sua estrutura interna. Os três principais tipos de aprendizado em RNAs são descritos por (BRAGA; CARVALHO; LUDERMIR (2007).

Aprendizado Supervisionado: Nessa modalidade de aprendizado, é empregado o conceito de um instrutor externo. O conhecimento prévio do ambiente está disponível, ou seja, as saídas desejadas são conhecidas e representadas como um conjunto de pares $(x(n), d(n))$. A rede neural busca emular o comportamento do instrutor, conforme ilustrado no diagrama de fluxo da Figura 1.6.


Figura 2 - Aprendizado Supervisionado para Redes Neurais Artificiais.



Fonte: Barreto (2002).

Aprendizado Não-Supervisionado: Nessa modalidade de aprendizado, a presença de um instrutor externo é ausente. Não há disponibilidade de informações acerca das saídas desejadas nem da qualidade da solução do problema. Em vez disso, realiza-se a extração de características pertinentes a partir de conjuntos de exemplos, conforme ilustrado na Figura 3.

Figura 3 - Aprendizado Não-Supervisionado para Redes Neurais Artificiais.



Fonte: Barreto (2002).

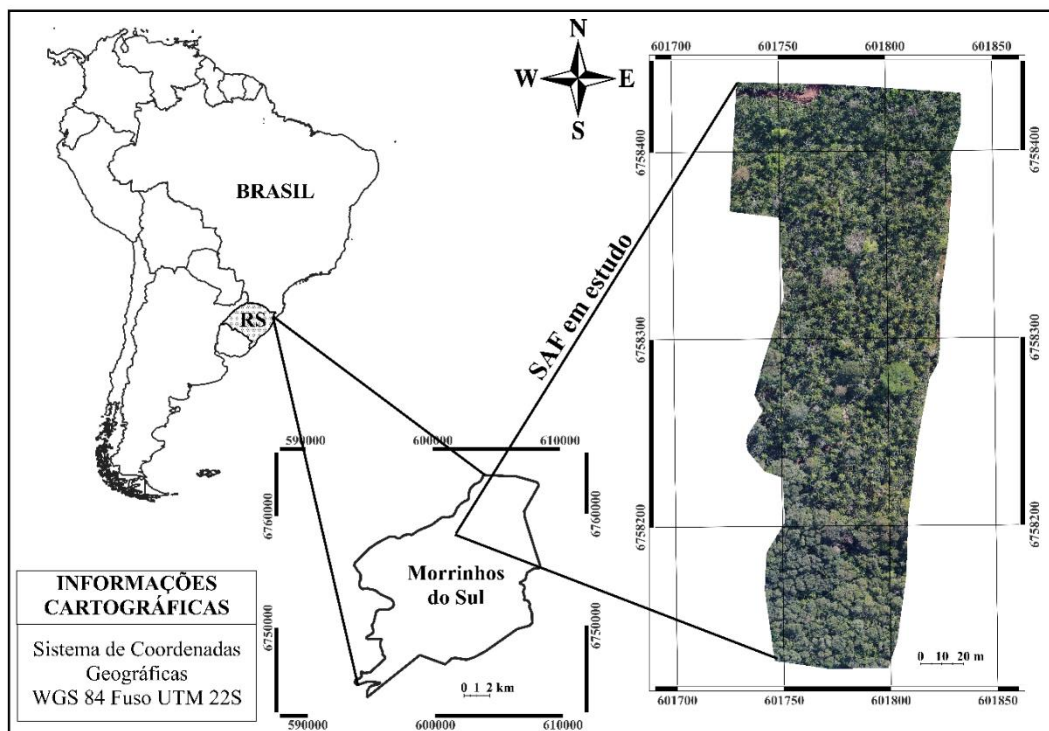
Uma das plataformas da RNA que vem sendo muito utilizada é o IBM SPSS *Statistics*, onde oferece análise estatísticas avançadas, possuindo uma vasta biblioteca de algoritmos de aprendizado de máquina. Portanto neste estudo será utilizado em conjunto a análise multivariada fatorial com a RNA buscando uma maior precisão na relação das variáveis do CO_2 equivalente com os IVs e dados de reflectancia em bandas de diferentes sensores remotos, podendo possibilitar a identificação de quais variáveis espectrais apresentam maior correlação com CO_2 equivalente.

3. MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo é um sistema agroflorestal silvibananeiro, com altitude variando entre 80 a 140 m do nível do mar (área de encosta), localizado entre as coordenadas geográficas 29°17'59.39" de latitude Sul e 49°57'7.08" longitude Oeste (Datum WGS84), no município de Morrinhos do Sul, no Litoral Norte do Estado do Rio Grande do Sul (Figura 4). O SAF possui área de 2,37 hectares, faz parte de uma propriedade rural pertencente ao agricultor familiar Valdeci Evaldt Steffen, sendo manejado pelos conceitos da agricultura orgânica da região, sendo assistido pelo Centro Ecológico.

Figura 4 - Localização do sistema agroflorestal em estudo em Morrinhos do Sul, Litoral Norte do Rio Grande do Sul.



Fonte: Autor (2023).

A vegetação pertencente ao tipo fitogeográfico da Floresta Ombrófila Densa Submontana, com características do Bioma Mata Atlântica (IBGE, 2012). O clima é do tipo Cfa, subtropical úmido com verão quente, segundo a classificação de Köppen (ALVARES et al., 2013), com temperatura média de 19°C, e médias mensais variando entre 15,1 e 24,7°C e a precipitação média anual fica em torno de 1700 mm. As classes de solos predominantes na

paisagem da região onde o SAF está localizado são predominantemente argilosos (podzólico), originados do basalto. O relevo é fortemente ondulado, com boa drenagem e afloramento de rochas em vários pontos (VIVAN, 2002).

Desde 1990, o Centro de Ecológico (CE) implementou sistemas agroflorestais (SAFs) na região, realizando a transição de bananais convencionais para SAFs, e em alguns casos, incorporando práticas de agricultura orgânica, com áreas certificadas para produção orgânica. No desenvolvimento das pesquisas, com o objetivo de compreender o impacto das mudanças climáticas nos sistemas produtivos, foram estabelecidas duas linhas de trabalho nas áreas em que o CE oferece consultoria.

Uma dessas linhas visa preservar a diversidade das espécies arbóreas da Mata Atlântica, enquanto a outra busca minimizar os efeitos do efeito estufa. Para avançar nesse contexto, foram adotadas metodologias simplificadas, evitando abordagens diretas. Nesse sentido, o CE empregou equações alométricas previamente estabelecidas em outras regiões, especialmente aquelas que envolviam SAFs com consórcio de juçara e bananais, e que apresentavam características semelhantes à região do estudo.

O propósito subjacente é que as pesquisas, em colaboração com o CE, resultem em trabalhos passíveis de publicação, contribuindo para a construção de uma base de conhecimento sobre o comportamento da biomassa, carbono e $\text{CO}_{2\text{eq}}$ nos SAFs da região. Esses estudos visam destacar a importância desses sistemas na mitigação do aquecimento global, potencialmente fomentando o surgimento de novos projetos nesta área.

3.2 AQUISIÇÃO DE IMAGENS E COLETA DE DADOS NO SAF

3.2.1 Aquisição das imagens com sensores embarcados em RPA e satélites

Em agosto de 2022 foi realizado no SAF em estudo um voo programado com uma RPA *Phantom 4 Advanced Plus*[®] (DJI) do tipo multirrotor ou asa rotativa (CASTRO JORGE; INAMASU, 2014), que possui autonomia para até 20 minutos de voo em condições de campo, contendo sensor RGB e ventos inferiores a 13 m/s, tendo altura máxima de voo de até 500 m

Os vôos com RPA foram planejados no aplicativo *Precision Flight*, com parâmetros para obter um *pixel* de tamanho projetado no terreno (*ground sample distance* - GSD) menor que 10 cm, recobrimento longitudinal de 75% e lateral de 70%. A altura do voo foi de 150 m, com duração de 15 minutos em operação e com velocidade de 10 m s⁻¹, produzindo 265 imagens.

Para complementar os dados de SR foram adquiridas imagens multiespectrais gratuitas, livres de cobertura de nuvens no local do SAF em estudo, dos sensores WPM CBERS 4A e sensores MSI Sentinel 2A. Devido a presença de nuvens em algumas datas disponíveis, foram utilizadas imagens de janeiro de 2023, tanto do CBERS 04A quanto do SENTINEL-2A.

As imagens do sensor WPM do satélite CBERS 04A foram obtidas no catálogo de imagens do INPE, disponível no link <http://www.dgi.inpe.br/catalogo/explore>. O sensor WPM fornece imagens em cinco bandas, sendo uma banda panorâmica com resolução espacial de 2m, três bandas do visível (RGB) e a banda NRI, todas com resolução espacial de 8m, de forma simultânea na mesma órbita.

Esse sensor apresenta 92 km de largura da faixa imageadora e tem uma revisita de 31 dias. As imagens do sensor MSI Nível-2A presente no Sentinel-2A foram obtidas gratuitamente por meio do portal *Copernicus Open Access Hub*, da Agência Espacial Europeia (*European Space Agency - ESA*), disponível no link <https://scihub.copernicus.eu/dhus/#/home>. Este sensor apresenta 13 bandas espectrais, variando de 10 a 60 m de resolução espacial, onde as bandas com 10 m são Blue, Green, Red e Nir. Neste estudo para os cálculos de IVs foi utilizado também a banda Red Edge de 20 m de resolução espacial. O satélite Sentinel possui uma revisita de 10 dias, com a constelação de dois satélites gêmeos, sendo Sentinel 2A e 2B. As imagens referentes as bandas espectrais de cada sensor utilizado, podem ser visualizados em apêndice (A) a esse trabalho.

3.2.2 Inventário Florestal para determinação indireta de biomassa, carbono e estimativa de CO₂ equivalente

Em fevereiro de 2023 foi realizado o inventário florestal, sendo instaladas 32 unidades amostrais (ua) pelo método de Prodan – área variável (BRITO et al., 2007) (Figura 5), pelo fato desta metodologia permitir dispor com mais facilidade unidades amostrais sobre a população de forma a contemplar todas as regiões do SAF em comparação a métodos que utilizam unidades de maior área e/ou área fixa. Nestas ua foram identificadas as espécies arbóreas e palmeiras, mensurados em todos os indivíduos a circunferência à altura do peito CAP (cm) a partir de 15 cm com uso de fita métrica, para posterior cálculo de diâmetro à altura do peito (DAP), e altura total (m) com uso de clinômetro HaglöfHec. Todas as espécies foram identificadas por Engenheiros Florestais e Técnicos do Centro Ecológico, unidade do Litoral Norte, baseados no sistema *Angiosperm Phylogeny Group - APG III* (2009), com auxílio dos

agricultores. Também nas bananeiras observadas dentro das uas foi mensurado o CAP (cm), para posterior transformação para DAP.

Figura 5 - Inventário Florestal pelo método da sexta árvore de Prodan em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil - 2023.




Fonte: Autor (2022).

As UA foram georreferenciadas com receptor GNSS de navegação Garmin® 66 CSX, com erro de posição horizontal entre 5-15 m, coordenadas em projeção cartográfica do tipo Universal Transverse de Mercator (UTM), relativa ao Fuso 22S, Meridiano Central 51° W e Datum horizontal WGS 84, obtendo assim as coordenadas métricas E (m) e N (m) de todas as UA. Os dados foram descarregados do receptor para o computador com uso do programa TrackMaker Profissional®, sendo as coordenadas exportadas em arquivos de texto, para posterior tabulação em planilhas eletrônicas, e importação para o sistema de informação geográfica (SIG) QGIS® versão 3.28.3. A área amostral de cada UA foi obtida pela distância horizontal, mensurada com trena de fibra de vidro de 50 m, do ponto de referência até a sexta árvore, acrescido da metade do diâmetro da mesma (Equação 1), gerados por buffer de distância variável no SIG QGIS (Figura 6), dada por (BRITO et al., 2007; AMARAL et al., 2021):

$$A = \left(\left(\frac{d}{2} \right) + D \right)^2 \cdot \pi \quad (1)$$

Em que: A = área da unidade amostral (m^2); d = diâmetro da sexta árvore (m); D = distância horizontal medida do centro da ua até a sexta árvore (m); π = número Pi (3,141592654).

Figura 6 - Distribuição das 32 unidades amostrais pelo método da sexta árvore de Prodan em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil - 2023.



Fonte: Autor (2023).

3.3 PROCESSAMENTO DE DADOS

3.3.1 Processamento das imagens da RPA

O processamento de imagens obtidas com o sensor RGB da RPA *Phantom 4* foi realizado, visando à extração dos valores médios, máximos e mínimos das bandas espectrais e IVs de cada sensor. As imagens resultantes do processo de Sensoriamento Remoto por RPA foram submetidas ao processamento utilizando o software Agisoft Metashape® versão 2.0.1. Esta aplicação foi acessada mediante uma licença gratuita destinada a estudantes, com validade de 31 dias.

A utilização de imagens georreferenciadas, em conjunto com os parâmetros de orientação externa e interna das imagens no momento de sua aquisição, possibilita a correção de distorções presentes nas imagens, conferindo-lhes qualidade geométrica e utilidade em variadas aplicações científicas. O processamento das imagens no software Metashape passaram pela geração de uma nuvem de pontos espersa, geração do modelo digital de superfície, seguida

pela geração do mosaico ortorretificado, com uso de qualidade média de processamento, procedimento adequado para a geração de índices de vegetação (ALBUQUERQUE et al., 2021).

Dessa forma, foram gerados os ortofotomosaicos, exportados em arquivos de extensão geotiff, para cada uma das bandas espectrais capturadas pelo sensor RGB, e posteriormente foram obtidos os IVs, utilizando a ferramenta de transformação de raster, sendo também exportados os ortomosaicos da mesma forma, selecionando a opção de exportar os valor do IVs. Esses arquivos foram importados para o SIG QGIS, onde foi realizado o recorte das imagens pelo limite do SAF, armazenado em arquivo vetorial shapefile de feição poligonal, para facilitar o tempo de processamento das imagens.

Os IV gerados com os dados do sensor RGB da RPA Phantom 4 foram EXG - Excess Leaf Index; GCC - Green Cromatic Coordinate; GLI - Green Leaf Index; I - Intensity; IO - Simple Ratio Red/Blue Iron Oxide; MPRI - Modified Photochemical Reflectance Index; NCPI - Chlorophyll Ration Index e RGBVI - Red Green Blue Vegetation Index, cujas equações serão apresentadas na seção 3.3.2.

3.3.2 Processamento das imagens de satélite

Após a aquisição das imagens do sensor WPM do satélite CBERS 04A, foi realizado o recorte das imagens para reduzir o tempo de processamento das mesmas, no processo de fusão de imagens. Para este procedimento foi utilizado o plugin *Orfeo Toolbox* (OTB), complemento instalado no Qgis na versão 3.28.3. O propósito primordial deste procedimento reside na modificação da resolução das bandas espectrais, uma vez que as bandas Blue, Green, Red e Nir possuem uma resolução espacial de oito metros. A fim de alcançar uma resolução espacial de dois metros nas mencionadas bandas, utilizou-se a banda pancromática com 2 metros de resolução espacial como referência (FONSECA et. al., 2000).

O processo de fusão de imagens compreende duas etapas executadas por meio da função de Geometry do OTB. A função Geometry apresenta duas subfunções para esse processo, sendo a primeira a Superimpose, seguida pela aplicação da Pansharpening. Em ambos os casos, a banda pancromática desempenhou o papel de referência no processo de fusão das imagens, possibilitando a otimização da resolução espacial das bandas espectrais de oito metros para dois metros, permitindo melhor diferenciação dos diferentes objetos da imagem. Para a realização de correção da atmosfera para as imagens do sensor WPM CBERS 04A, ainda não se tem disponível pelo INPE os fatores de correção atmosférica (FONSECA, 2000).

Para as imagens do Sentinel-2A foi realizado a correção da atmosfera através do plugin Semi-automatic classification instalado no Qgis na versão 3.28.3, pois esse plugins apresenta a função para a correção da atmosfera de diferentes satélites, tendo a função específica para o Sentinel-2 (SANTORI, 2022). Para a realização da correção foi necessário selecionar a pasta onde estão as imagens e buscar o metadado MTD_MSIL 1C que vem disponibilizado junto às imagens. A banda espectral Red Edge com 20m de resolução ao aplicar as correções atmosféricas, o plugin também realiza a fusão, passando para 10m a resolução da banda, ficando com a mesma resolução das bandas RGB e NIR.

3.3.3 Índices de vegetação

A escolha dos índices de vegetação (IVs) que possam demonstrar interação com os valores de CO₂ equivalente encontrados para as 32 ua na vegetação acima do solo no SAF em estudo, foi através da realização de uma revisão de literatura de diferentes trabalhos (FONSECA, 2020; MORAES, 2021; VERLY, 2021; THAPA et al., 2023) entre outros.

Com base nas faixas espectrais disponíveis dos sensores utilizados neste estudo, foram usados os seguintes IVs (Tabela 1): CIGREEN - Chlorophyll Index Green ;CVI - Chlorophyll Vegetation Index; EXG - Excess Leaf Index; GCC - Green Chromatic Coordinate; GDVI - Green-normalized difference vegetation index ; GLI - Green Leaf Index; I - Intensity; IO - Simple Ratio Red/Blue Iron Oxide; MCARI - Modified Chlorophyll Absorption in Reflectance Index; MPRI - Modified Photochemical Reflectance Index; MVI - Moisture Vegetation Index; NCPI - Chlorophyll Ration Index; NDRE - Normalized Difference Red Edge; NDVI - Normalized Difference Vegetation; NDWI - Normalized Difference Water; Norm NIR - Norm NIR ; Norm RED – Norm RED; RGBVI - Red Green Blue Vegetation Index; SAVI - Soil Adjusted Vegetation Index; SIPI - Structure Insensitive Pigment Index; SR - Simple Ratio ; TCARI - Transformed Chlorophyll Absorption in Reflectance Index.

Para realização dos cálculos dos IVs, para o RPA foram realizados no programa Metashape 2.0.1. e para as imagens dos satélites foi utilizado a ferramenta calculadora raster no Qgis versão 3.28.3.

Tabela 1 - Índices de vegetação calculados conforme as bandas espectrais dos sensores utilizados no imageamento sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continua)

Sigla	Fórmula	Autor
CIGREEN	$\left(\frac{R_{NIR}}{R_{GREEN}}\right) - 1$	GITELSON et al. (2005)
CVI	$\frac{R_{NIR} * R_{RED}}{R_{GREEN}^2}$	HABOUDANE et al. (2002)
EXG	$\frac{2 * R_{GREEN}}{R_{RED} * R_{BLUE}}$	WOEBBECKE et al., (1995)
GCC	$\frac{R_{GREEN}}{R_{RED} + R_{GREEN} + R_{BLUE}}$	GILLESPIE et al. (1987)
GDVI	$(R_{NIR} - R_{GREEN})$	TUMBO et al. (2000)
GLI	$\frac{2 * R_{GREEN} - R_{RED} - R_{BLUE}}{2 * R_{GREEN} + R_{RED} + R_{BLUE}}$	LOUHAICHI et al. (2001)
I	$\frac{1}{30,5 * R_{RED} R_{GREEN} R_{BLUE}}$	ESCAFADAL et al. (1994)
IO	$\frac{R_{RED}}{R_{BLUE}}$	HEWSON et al. (2001)
MCARI	$(R_{REDEGE} - R_{RED}) - 0,2(R_{REDEGE} - R_{GREEN}) * \left(\frac{R_{REDEGE}}{R_{RED}}\right)$	DAUGHTRY et al. (2000)
MPRI	$\frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED}}$	YANG et al. (2008)
MVI	$\left(\frac{R_{NIR}}{R_{REDEGE}}\right)$	GAO (1996)
NCPI	$\frac{R_{RED} - R_{BLUE}}{R_{RED} + R_{BLUE}}$	PEÑUELAS et al. (1993)
NDRE	$\frac{R_{NIR} - R_{REDEGE}}{R_{NIR} + R_{REDEGE}}$	BARNES et al., (2000)
NDVI	$\frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	ROUSE-JUNIOR et al. (1973)
NDWI	$\frac{R_{GREEN} - R_{NIR}}{R_{GREEN} + R_{NIR}}$	MCFEETERS (1996)
NormNIR	$\left(\frac{R_{NIR}}{R_{NIR} + R_{RED} + R_{GREEN}}\right)$	Portal index database

Tabela 1 - Índices de vegetação calculados conforme as bandas espectrais dos sensores utilizados no imageamento sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(conclusão)

Norm RED	$\left(\frac{R_{RED}}{R_{NIR+RED} + R_{GREEN}} \right)$	Portal index database
RGBVI	$\frac{R_{RED} * R_{BLUE}}{(R_{GREEN} * R_{GREEN}) + (R_{GREEN} * R_{BLUE})}$	BENDIG et al. (2015)
SAVI	$\frac{1,5(R_{NIR} - R_{RED})}{R_{NIR} + R_{RED} + 0,5}$	HUETE (1989)
SIPI	$\frac{R_{NIR} - R_{BLUE}}{R_{NIR} + R_{RED}}$	PENUELAS et al. (1995)
SR	$\left(\frac{R_{NIR}}{R_{RED}} \right)$	GNYP et al. (2015)
TCARI	$3 * (R_{REDEEDGE} - R_{RED}) - 0,2(R_{REDEEDGE} - R_{GREEN}) * \left(\frac{R_{REDEEDGE}}{R_{RED}} \right)$	HABOUDANE et al. (2002)

Legenda: R_{BLUE} é a banda espectral do azul, R_{GREEN} banda espectral do verde, R_{RED} banda espectral do vermelho, R_{NIR} banda espectral do infravermelho próximo e $R_{REDEEDGE}$ banda espectral da borda do vermelho

Fonte: Autor (2023).

3.3.4 Obtenção de dados nos mosaicos das Bandas e IVs, utilizando a ferramenta estatística zonal no SIG Qgis.

Para realizar a quantificação das estatísticas das bandas espectrais e os Índices de Vegetação (IVs) dos diferentes sensores considerados, foi utilizado os limites das 32 ua gerados a partir do raio característico de cada ua, o qual foi previamente inserido na interface do QGIS, através de tabela eletrônica contendo as coordenadas centrais e o valor do raio, para o cálculo da área amostral de cada ua. Após empregou-se a ferramenta estatística zonal (EZ) do software QGIS versão 3.28.3, para a aquisição dos valores médios, máximos e mínimos e posteriormente exportados em arquivo de texto, o qual foi importado em planilha eletrônica, na qual foram organizados todos os dados obtidos por ua, juntamente com os dados de CO_{2eq} obtido para a vegetação acima do solo, sendo extrapolados da área de cada ua para o hectare (10000 m²).

3.3.5 Estimativa da biomassa, carbono e CO₂ equivalente estocados na vegetação do SAF acima do solo

Os dados de DAP (cm) e juntamente com a altura (m) foram utilizados para calcular biomassa acima do solo, com uso de equações alométricas específicas para os grupos palmeiros, bananeiras e espécies arbóreas. Este procedimento foi necessário, pois não havia dados de biomassa obtidos por métodos diretos de determinação, pois esta foi a forma de trabalho escolhida pelo Centro Ecológico em vários projetos e trabalhos envolvendo determinação de biomassa e carbono desde 2010.

Na determinação da biomassa para estimar CO_{2eq} nas 32 ua, foram utilizadas diferentes equações alométricas encontradas em trabalhos científicos, que realizaram estudos em sistemas agroflorestais, que apresentaram semelhanças nas estruturas e espécies. Neste trabalho foi utilizado o método indireto (não destrutivo), que é uma alternativa de baixo custo e rápida, diferente do método destrutivo, que apesar dos resultados serem mais fidedignos, exige o abatimento de alguns indivíduos, de um maior tempo para execução, exigindo maiores recursos (ARANCIBIA, 2021).

O método não destrutivo consistiu na utilização de equações alométricas já consagradas na literatura para estimar a biomassa na vegetação acima do solo. Nessas equações as dimensões das árvores DAP (cm) e altura (m) são algumas das variáveis medidas e a biomassa estocada é a variável a ser estimada. Para o cálculo da biomassa das espécies *Musa* sp. (Bananeira) e *Euterpe edulis* (Juçara) em cada ua, foram utilizadas as equações desenvolvidas por (STEENBOCK et al., 2013), respectivamente, em agroflorestas de Barra do Turvo/SP e Adrianópolis/PR (Tabela 2).

Tabela 2 - Equações alométricas utilizadas para o cálculo da biomassa das espécies *Musa* sp. (Bananeira) e *Euterpe edulis* (Juçara) no sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Espécie	Equações	Parâmetros			
		A	B	R ² aj	S _{xy} %
Bananeira	$\ln \text{BAS} = a + b \cdot \ln \text{dap}$	-3,98414	2,20132	0,91719	16,174
Juçara	$\ln \text{BAS} = a + b \cdot \ln (\text{dap}^2 \cdot h)$	-2,34626	0,79482	0,91574	30,145

Legenda: BAS = Biomassa acima do solo; dap = diâmetro à altura do peito (cm); h = altura (m).

Fonte: Adaptado de STEENBOCK (2013).

Para o cálculo de biomassa das espécies arbóreas da Mata Atlântica, foi utilizado a equação desenvolvida por Tanizaki (2000) (Tabela 3), que é adequada a algumas formações da Mata Atlântica, como a Floresta Ombrófila Densa, formação vegetal que ocorre na área de

estudo. Em cada ua a biomassa das três categorias foi somada para obter a biomassa total por ua, sendo extrapolada para o hectare.

Tabela 3 - Equação utilizada para o cálculo de biomassa para as espécies arbóreas nativas presentes no sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Espécies	Equações	Parâmetros		
		A	B	C
Demais espécies	$BAS = 2,718^{(a+b*LN(dap)+c*LN(h))}$	-2,5202	2,14	0,4644

Legenda: BAS = Biomassa acima do solo; dap = diâmetro à altura do peito (cm); h = altura(m).

Fonte: Adaptado de Tanizaki (2000).

A quantificação do carbono ($Mg\ ha^{-1}$) de cada ua, se deu pela multiplicação do valor de biomassa ($Mg\ ha^{-1}$) pelo coeficiente igual a 0,5, seguindo as recomendações do IPCC (Intergovernmental Painel on Climate Change), sendo necessária para a obtenção da estimativa de CO_{2eq} . Pois a quantificação do dióxido de carbono (CO_{2eq}) se dá em relação ao carbono, onde uma tonelada de carbono equivale a 3,67 toneladas de CO_{2eq} obtido em razão dos pesos moleculares do carbono e do CO_2 de ($44,01/12,01\ g\ mol^{-1}$). Os cálculos foram realizados em planilha Excel.

3.3.6 Análise de Multivariada fatorial e Modelagem por redes neurais artificiais

Para a realização da análise multivariada fatorial (AF), os dados mensurados de CO_2 equivalente e os valores médios, máximos e mínimos dos IVs e das bandas espectrais (refletância), que totalizaram 180 variáveis descritoras obtidas em 32 ua (cases), foram importados para o programa Statistica versão 12, onde foram padronizados utilizando a razão entre a diferença do valor de cada observação de uma determinada variável e sua média, pelo respectivo desvio padrão. A rotação Varimax Normalized foi adotada, pois facilita a interpretação dos fatores, tornando os independentes e reduzindo o acúmulo de contribuições de variáveis no primeiro fator. Foram estabelecidos critérios para encontrar os fatores mais representativos, sendo considerados os autovalores maiores que um, que explicam acumuladamente mais de 70% da variabilidade dos dados, ou os fatores com variáveis de interesse específicas para a análise. As contribuições das variáveis acima de 70% foram

consideradas significantes na composição dos fatores (VICINI et al., 2018; MANLY e ALBERTO, 2019).

Para estabelecer modelos, através de dados SR, para a estimação de CO_{2eq} , foram utilizadas as redes neurais artificiais (RNAs), disponíveis no software IBM SPSS Statistics versão 29.0.1.1 (trial educacional). As RNAs treinadas foram do tipo Multilayer Perceptron (MLP), implementadas com o algoritmo backpropagation e a otimização Levenberg-Marquadt. Os dados foram divididos em 75% para treinamento e 25% para teste, porém o software SPSS estabeleceu em 87,5% para treinamento e 12,5% para teste, sendo treinadas três redes com três camadas: Neurônio de Entrada (NE), Neurônio Intermediário (NI) ou Camada Oculta e Neurônio de Saída (NS). Foi obtido um modelo para estimar CO_{2eq} completo, utilizando 100% das variáveis (180 variáveis) na camada de entrada e treinadas por 20 vezes até obter o melhor valor possível de R^2 (SOARES, 2005).

Para estabelecer um modelo mais simples e prático, foram selecionadas as covariáveis com Nível de Importância da Variável (NIV) de aproximadamente 70%, resultado obtido como o modelo completo, sendo então as variáveis STCARI_Med, SB3_Max, SGLI_Med, SSR_Med, SI_Max, VIO_Max, CB1_Min, SCVI_Med, CRGBVI_Med, SNCPI_Med, VEXG_Med e CI_Max, reduzindo o número de variáveis para alimentar a camada de entrada e possibilitar a obtenção de um modelo mais simples.

Os valores finais de CO_{2eq} obtidos com equações alométricas, através de mensurações obtidas a campo (DAP - cm e altura - m), foram utilizados como valor de saída para treinar e validar as RNAs, enquanto os dados de SR foram utilizadas como covariáveis de entrada. As covariáveis independentes foram padronizadas para a modelagem das RNAs, subtraindo a média do valor observado e dividindo a diferença pelo desvio padrão. As amostras de teste e treinamento foram estimadas e otimizadas diretamente pelo software SPSS, sem intervenção do pesquisador na seleção. A arquitetura da rede e a quantidade de camadas ocultas também foram selecionadas automaticamente pelo software.

Para avaliar a qualidade dos resultados obtidos pelas RNAs em comparação ao mensurado pelo método indireto (equações alométricas), foram adotados os seguintes indicadores estatísticos, a Raiz do Erro Quadrático Médio, do inglês *Root Mean Squared Error* – *RMSE* (Equação 2), o RMSE relativo em percentagem (Equação 3), o Bias (Equação 4) e o BIAS relativo em percentagem (Equação 5). Estes parâmetros são métodos amplamente empregados para verificação do desempenho estatístico de métodos paramétricos e não-paramétricos empregados na estimativa de biomassa/carbono florestal (SOARES, 2005).

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2)$$

$$\text{RMSE (\%)} = \frac{\sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}}{\bar{y}} * 100 \quad (3)$$

$$\text{Bias} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{y}_i) \quad (4)$$

$$\text{Bias (\%)} = \frac{\text{Bias}}{\bar{y}} * 100 \quad (5)$$

Em que: y_i = valores de $\text{CO}_{2\text{eq}}$ obtidos pelas equações alométricas de estimativa de biomassa com dados de DAP e altura; \hat{y}_i = valores $\text{CO}_{2\text{eq}}$ estimados nas ua (i) pelo modelo obtido na modelagem das RNAs, e n = número total de ua.

Também na planilha eletrônica, foram gerados gráficos de valores de $\text{CO}_{2\text{eq}}$ obtidos pelas equações alométricas versus valores $\text{CO}_{2\text{eq}}$ estimados pelas RNAs para ambos os modelos (completo e reduzido), técnica chamada de validação cruzada, com ajuste de equação da reta, como uma ferramenta auxiliar para a determinação da qualidade do ajuste dos modelos (STONE, 1974).

A metodologia empregada para avaliar as correlações entre as $\text{CO}_{2\text{eq}}$ e as variáveis de SR que foram utilizadas para a construção do modelo reduzido desenvolvido por RNA, foi baseada na análise de correlação de Spearman, utilizando o software SigmaPlot. O coeficiente de correlação de Spearman foi aplicado para estabelecer relações estatísticas não lineares entre as variáveis, permitindo a identificação de padrões nas relações entre as concentrações de $\text{CO}_{2\text{eq}}$ e as variáveis de SR. Para os pares de variáveis com coeficientes de correlação positivos e valores de p-valor abaixo de 0,050 tendem a aumentar em conjunto, para os pares com coeficientes de correlação negativos e valores de p-valor abaixo de 0,050, uma variável tende a diminuir enquanto a outra aumenta e para os pares com valores de p-valor superiores a 0,050, não há relação monotônica significativa entre as duas variáveis (SIEGEL, 1975).

4 RESULTADOS E DISCUSSÃO

O inventário no SAF silvibananeiro nas 32 ua com área média de 118,6 m², apresentou o equivalente a 1177 indivíduos (3101 ind ha⁻¹), distribuídos em 13 espécies e 11 famílias botânicas. A espécie *Musa* sp. representou 83,7% dos indivíduos observados, *Euterpe edulis* 14,6% e as demais espécies apenas 1,7%. Em estudo conduzido por Amaral *et al* (2021), onde analisou a variabilidade espacial em um SAF silvibananeiro próximo a região deste estudo, localizado no município de Três Cachoeiras, no Litoral Norte do Rio Grande do Sul, encontrou 776 indivíduos por hectare, distribuídos em 22 espécies, um gênero e 17 famílias botânicas. Neste estudo não foi contabilizado a espécie *Musa* sp., diferentemente da presente pesquisa, em que contabilizou-se a espécie *Musa* sp. Essa diferença metodológica pode explicar a diferença observada em número de indivíduos por hectare.

A análise por estatística descritiva para biomassa, carbono e CO_{2eq} equivalente, determinados por equações alométricas (Tabela 4), com uso dos dados de campo (DAP e altura), apresentaram alta variabilidade, com base no coeficiente de variação maior que 100, e nas demais estatísticas que sugerem o não atendimento a normalidade, pela discrepância entre os valores de média (M), mediana (Md) e moda (Mo) (RIBEIRO JUNIOR, 2004). A biomassa apresentou média de 90,59 Mg ha⁻¹, carbono média de 45,3 Mg ha⁻¹ e o CO_{2eq} média de 166,23 Mg ha⁻¹, ambos com CV% de 142,7. A média de biomassa 90,59 Mg ha⁻¹ apresentou a contribuição de 19,08 Mg ha⁻¹ da espécie *Musa* sp., 33,64 Mg ha⁻¹ da *Euterpe edulis* e 37,88 Mg ha⁻¹ das demais espécies arbóreas.

Tabela 4 - Estatística descritiva para biomassa, carbono e CO₂ equivalente determinados por equações alométricas em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Var. (Mg ha ⁻¹)	M	EP	Md	Mo	S ²	S	CV%	K	As	V _{min}	V _{máx}	NC
Biomassa	90,6	22,9	49,4	Amd	16711,50	129,27	142,7	18,23	4,09	26,35	710,59	46,61
Carbono	45,3	11,4	24,7	Amd	4177,87	64,64	142,7	18,23	4,09	13,17	355,29	23,30
CO _{2eq}	166,2	41,9	90,6	Amd	56271,37	237,22	142,7	18,23	4,09	48,34	1303,93	85,53

Legenda: Var. = Variáveis; M = Média, EP = Erro padrão da média; Md = Mediana; Mo = moda; Amd = Amodal; S² = Variância; S = Desvio Padrão; CV = Coeficiente de variação; K = Número de classes; As = Assimetria; V_{min} = variação mínima; V_{máx} = Variação máxima; NC = Nível de confiança para média de 95%;

Fonte: Autor (2023)

O coeficiente de assimetria (As) foi positivo, ou seja, distribuição de dados inclinada à direita da média, com mais valores por ua menores que a mesma. Formação de cauda na região

dos valores maiores que a média, que não se localiza no centro de distribuição dos dados, sendo maior que a mediana, que por sua vez, foi maior que a moda. Já o coeficiente de curtose (K) foi positivo, sendo a curva de distribuição dos dados leptocúrtica, que concentra dados em torno da média (RIBEIRO JUNIOR, 2004).

Os valores obtidos nesta pesquisa demonstram uma maior acumulação de biomassa, carbono e CO_{2eq} na vegetação acima do solo em relação a um estudo prévio conduzido no mesmo local entre 2010 e 2013 pelo Centro Ecológico Amaral *et al* (2021). Nesse estudo anterior, as médias correspondentes foram de 70,3 Mg ha⁻¹, 35,2 Mg ha⁻¹ e 129,18 Mg ha⁻¹, respectivamente para BAS, C e CO_{2eq}.

Porém, essas diferenças podem estar atribuídas a diferentes aspectos, onde dentro deste período de aproximadamente 10 anos entre esses estudos, o manejo adotado no SAF foi sendo intensificado, aumentando a intensidade de podas e remoções de árvores de grande porte do sistema, para aumentar a produtividade das bananeiras, que é prejudicada quando está sobre excessivo sombreamento (VIVAN, 2002). Sobre esse aspecto podemos notar as diferenças no número de indivíduos de *Euterpe edulis* e demais espécies nativas por hectare, em que em 2013 apresentavam 4.400 ind ha⁻¹ e em 2023 foi de 506 ind ha⁻¹. Em contrapartida os métodos para a realização do inventário foram diferentes, em 2013 foi contabilizado todos os indivíduos arbóreos que apresentaram circunferência acima de 15 cm dentro de uma parcela de 700 m² e em 2023 foram contabilizados somente as seis árvores nas 32 unidades amostral (mensurados cap e altura), seguindo o método de Prodan.

Todas as ua apresentaram diferença em suas áreas, totalizando 3795,46 m² e além das seis árvores, foram medidos o CAP de todos os indivíduos de *Musa sp.* dentro de cada ua, já mencionado anteriormente. Para comparação dos números de indivíduos por hectare entre os dois estudos, foram descartados o número de bananeiras contabilizados em 2023, pois o estudo em 2013 não mensurou as bananeiras, sendo outro fator que contribui para as diferenças de biomassa encontrada nas diferentes datas. Outro aspecto importante que está contribuindo para as diferenças de biomassa, carbono e CO_{2eq} entre 2013 e 2023 foi a utilização de diferentes equações alométricas dos estudos, para a quantificação da biomassa.

Estudo conduzido por Danelli *et al.* (2016) para a quantificação de biomassa florestal em áreas com consórcio de bananeiras e juçara manejado pela população caiçara e quilombola na região do Litoral Norte no Estado de São Paulo, dentro dos limites do Núcleo Picinguaba, obtiveram valores de 61,2 e 59,3 Mg ha⁻¹, de biomassa na vegetação acima do solo, sendo esses valores obtidos em áreas denominadas de Ubatumirim e Camburi, que, respectivamente, apresentaram 1,840 ind ha⁻¹ e 940 ind ha⁻¹. Esses valores foram mensurados utilizando equações

alométricas para florestas secundárias da Mata Atlântica, onde utilizou as variáveis dendrométricas de DAP e altura dos indivíduos que apresentaram DAP igual ou superior a 4,58 cm em uma parcela com área de 1000 m². Foi utilizado o coeficiente de 0,5 para converter biomassa em carbono e o valor de 3,67 para obter CO_{2eq}, mesmo fator de conversão empregado neste estudo. Os valores obtidos para as duas áreas foram de 30,6 Mg ha⁻¹ e 29,65 Mg ha⁻¹ para carbono e de 112,3 Mg ha⁻¹ e 108,8 Mg ha⁻¹ de CO_{2eq}.

A comparação dos resultados obtidos em estudos realizados em diferentes anos e regiões, com metodologias e abordagens distintas, revela variações significativas nas estimativas de biomassa, carbono e CO_{2eq} em sistemas agroflorestais (SAF) com consórcio de banana e juçara, bem como outras espécies nativas. Essas variações encontradas enfatizam a influência das espécies utilizadas, as práticas de manejo, as diferenças metodológicas e as condições locais na quantificação da biomassa, carbono e CO_{2eq} em SAF, destacando a complexidade desses sistemas e a necessidade de abordagens específicas para a avaliação precisa de seu potencial de mitigação de carbono.

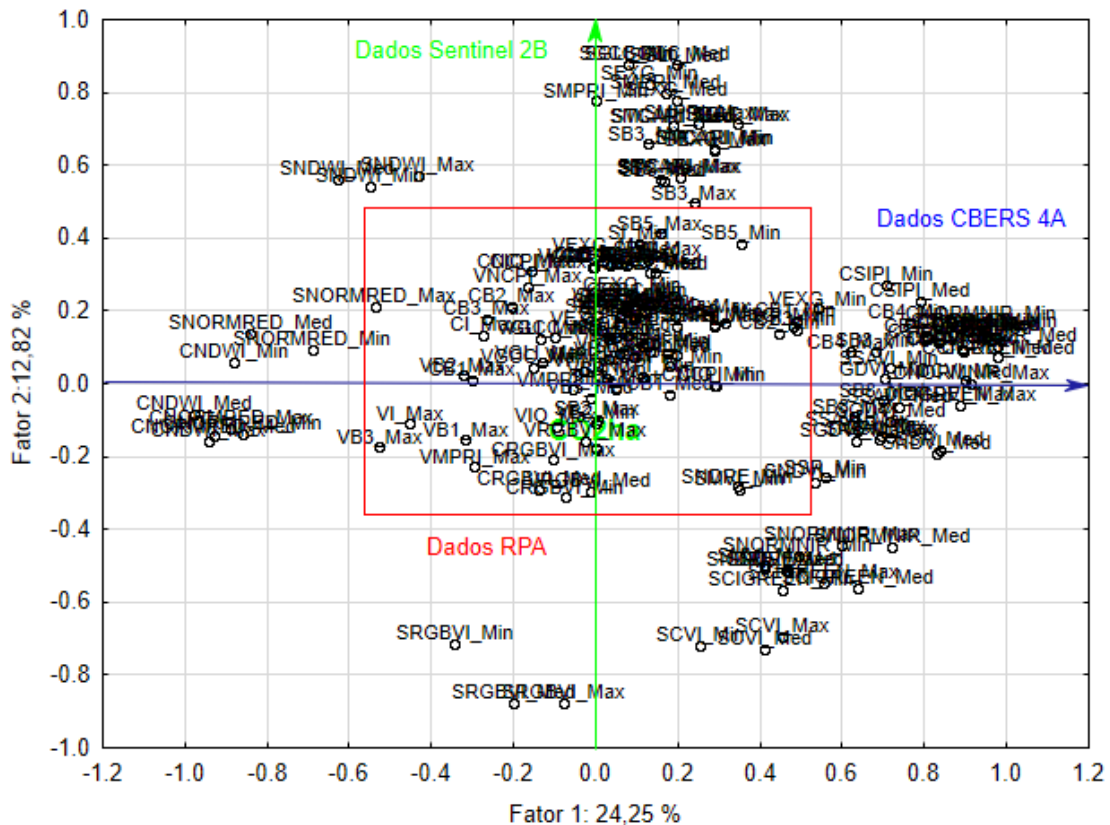
Foram obtidas 180 variáveis a partir do imageamento do SAF em estudo, dentre a refletância de bandas e índices de vegetação, com seus valores médios, mínimos e máximos obtidos pela estatística zonal, oriundos dos três sensores utilizados, o sensor RGB da RPA Phantom 4, e os sensores multiespectrais WPM do CBRES 04A e MSI Nível-2A do Sentinel 2-A. A análise multivariada fatorial, com a rotação varimax normalized, foi utilizada para estabelecer o relacionamento entre CO_{2eq} e as 180 variáveis obtidas pelo sensoriamento remoto (VICINI et al., 2018)

Nesta análise, a partir das variáveis de entrada, foram obtidos 31 autovalores, dos quais 18 apresentaram valores maiores que um, sendo que os cinco primeiros autovalores acumularam 71,47% da variabilidade do conjunto de dados, valor absoluto de 129,36. Os autovalores 1 (48,84; variância explicada 26,98%) e 2 (38,73; variância explicada 21,40%) foram os mais importantes acumulando uma explicação da variabilidade de 48,38%, sendo utilizados para gerar a dispersão das variáveis em análise. Os autovalores são relativos aos fatores obtidos, mantendo a ordem, sendo o autovalor 1 relacionado ao fator 1, e assim sucessivamente (VICINI et al., 2018; MANLY e ALBERTO, 2019). Após a rotação Varimax normalized dos eixos, definindo as variáveis que realmente contribuem na formação de cada fator, o fator 1 explicou 24,25% (valor absoluto 43,88) da variabilidade do conjunto dos dados, e o fator 2 12,82% (23,20 valor absoluto).

No gráfico de dispersão das variáveis, segundo os fatores 1 e 2 (Figura 7), foi observado que os dados obtidos pelo satélite Sentinel-2A tiveram maior contribuição ao fator 1 e os dados

obtidos pelo satélite CBERS 04A tiveram maior contribuição ao fator 2. As variáveis que ocupam as posições nas extremidades dos eixos que representam os fatores 1 e 2 foram as mais importantes para os mesmos, por contribuírem mais para a sua formação. Os dados oriundos do sensor RGB da RPA ficaram dispersos na região central do gráfico, juntamente com o CO_{2eq} (destacado em verde), mostrando haver pequena contribuição destas variáveis para a formação dos fatores. Houve também relações de baixa a média significância entre CO_{2eq} com a maioria das variáveis de sensoriamento remoto. Este comportamento sugere dificuldade de modelar os dados por certos métodos, a exemplo de regressão linear, o que justifica o uso de modelagens com emprego de inteligência artificial, a exemplo das redes neurais artificiais.

Figura 7 -Dispersão das variáveis CO_{2eq} e dados de sensoriamento remoto (180 variáveis), segundo a Análise Fatorial, em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.



Fonte: Autor (2023).

Ao realizar a modelagem dos dados com as redes neurais artificiais foi estabelecida a geração de dois modelos para a estimativa de CO_{2eq} , sendo um completo com todas as variáveis de entrada (180 - covariáveis), e um modelo reduzido, contendo as covariáveis que apresentaram importância normalizada de aproximadamente 70%, obtidas a partir dos

resultados do modelo completo. A seguir serão descritos os aprendizados das RNAs para estes dois modelos.

O aprendizado das RNAs para estimar o $\text{CO}_{2\text{eq}}$ com todas as variáveis de sensoriamento para a vegetação acima do solo no SAF em estudo, foi inicialmente configurado para utilizar 75% (24) das ua para treinamento e 25% (8) das ua para teste. Porém, o próprio método se autoajusta, e utilizou 87,5% (28) das ua para treinamento e 12,5% (4) para teste, por entender ser necessário mais dados para realizar o aprendizado de redes. O processo de aprendizado foi estruturado por 180 neurônios ou camadas de entrada (variáveis de SR), 16 neurônios ou camadas ocultas e 1 neurônio ou camada de saída ($\text{CO}_{2\text{eq}}$). O esquema de aprendizado desta rede está em apêndice (B) à dissertação, devido ao seu tamanho em função do número de variáveis de entrada.

No treinamento a soma dos erros quadráticos foi 0,101 e o erro relativo 0,7% (0,007). Já no teste, a soma dos erros quadráticos foi 0,031 e o erro relativo 17,3% (0,173). Para ambas as situações os valores são aceitáveis e indicam baixos erros, mesmo no caso do teste, onde foram utilizadas apenas quatro de 32 ua, o que influencia na medida dos erros, sendo adotadas também outras formas de analisá-los.

A medida de viés pelo BIAS absoluto foi de $-2,11 \text{ Mg ha}^{-1}$, sendo o BIAS relativo de $-1,27\%$, e a raiz do erro quadrático médio (RMSE) absoluto foi de $22,92 \text{ Mg ha}^{-1}$, entre valores de $\text{CO}_{2\text{eq}}$ de referência e estimados pelo modelo completo obtido pela RNA, e o RMSE relativo foi de $4,36\%$. Estes parâmetros indicam que um modelo satisfatório foi obtido, mesmo com a inclusão de três ua com valores de $\text{CO}_{2\text{eq}}$ muito elevados, discrepantes em relação as demais ua, devido a presença de árvores de maiores dimensões em certas regiões dos SAFs, sendo um comportamento natural devido a forma de manejo da vegetação (podas drásticas de espécies usadas para incrementar matéria orgânica no solo e regular 40% de sombreamento das bananeiras, e condução de espécies madeiráveis para atingir portes maiores).

Nesta modelagem, foi possível também observar que a importância das variáveis apresentou valores individuais baixos (Tabela 5). Dentre estas, foram selecionadas as variáveis para gerar o modelo reduzido (70% da importância normalizada), sendo as 12 variáveis destacadas em negrito. A tabela com todos os as variáveis e suas contribuições de importâncias do modelo completo estão em apêndice (C) a esse trabalho.

Tabela 5 - Importância das variáveis de entrada no modelo completo para estimar CO₂ equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Importância da variável independente (entrada)				
Número	Variáveis	Importância	Importância Relativa (%)	Importância normalizada
1	STCARI_Med	0.012	1.2049	100.0%
2	SB3_Max	0.012	1.1829	98.2%
3	SGLI_Med	0.011	1.1354	94.2%
4	SSR_Med	0.011	1.1295	93.7%
5	SI_Max	0.010	1.0286	85.4%
6	VIO_Max	0.010	1.0228	84.9%
7	CB1_Min	0.010	0.9561	79.3%
8	SCVI_Med	0.009	0.9343	77.5%
9	CRGBVI_Med	0.009	0.8756	72.7%
10	SNCPI_Med	0.009	0.8607	71.4%
11	VEXG_Med	0.008	0.8476	70.3%
12	CI_Max	0.008	0.8424	69.9%
13	SB2_Min	0.008	0.8266	68.6%
14	SRGBVI_Min	0.008	0.7956	66.0%
15	SSAVI_Med	0.008	0.7643	63.4%
16	VEXG_Min	0.008	0.7552	62.7%
17	SNDWI_Min	0.007	0.7497	62.2%
18	CRS_Min	0.007	0.7385	61.3%
19	VIO_Med	0.007	0.7282	60.4%
20	CB4_Max	0.007	0.7097	58.9%
21	SSIPI_Med	0.007	0.7045	58.5%
⋮	⋮	⋮	⋮	⋮
180	VNCPI_Min	0.003	0.2521	20.9%

Legenda (Letras no início do nome das variáveis): V – sensor RGB embarcado na RPA Phantom 4; C – sensor WPM embarcado no satélite CBERS 04A; S – sensor MSI Nível-2A do Sentinel 2-A.

Fonte: Autor (2023).

Dentre estas 12 variáveis, 58% foram constituídos por dados do satélite Sentinel-2A, 25% do satélite CBERS 4A e 17% dados da RPA. Na tabela 6 é possível observar os valores de *p-valor* para o teste de normalidade de Shapiro-Wilk, correlação de Spearman dos dados destas variáveis em relação ao CO_{2eq} de referência.

Tabela 6 - Valores de importância, normalidade e correlação de spearman das covariáveis utilizadas para compor o modelo reduzido em RNA..

Covariáveis do modelo reduzido	Importância %	Normalidade Shapiro-Wilk p-valor	Correlação Spearman	p-valor
–	–	CO2eq (0,0051)	–	–
SI_Max	22,559	0,5501	-0,03780	0,836
CI_Max	19,021	0,0453	-0,18200	0,316
VIO_Max	11,368	0,8923	-0,05720	0,754
SSR_Med	10,654	0,2124	0,04290	0,814
CB1_Min	9,594	0,0252	-0,19300	0,288
VEXG_Med	8,730	0,009	0,23600	0,192
CRGBVI_Med	5,228	0,5729	0,04580	0,801
STCARI_Med	5,011	0,2851	0,14100	0,439
SGLI_Med	3,098	0,7524	0,07180	0,694
SCVI_Med	2,432	0,9345	0,17200	0,344
SNCPI_Med	1,828	0,5511	-0,00073	0,996
SB3_Max	0,476	0,0495	-0,36600	0,0395

Fonte: Autor (2023).

A análise da correlação de Spearman entre os dados de SR com o valor de CO_{2eq} estimado por equações alométricas, sendo utilizados para gerar o modelo reduzido para estimar o CO_{2eq} através de dados de SR, indica que as relações entre essas variáveis são predominantemente de baixa magnitude bem como boa parte das covariáveis não apresentaram relação monotônica significativa p-valores superiores a 0,050 (ATAIDES, 2019) . Os coeficientes de correlação variam entre -0,366 e 0,236. Valores próximos de zero, como o índice de vegetação SNCPI_Med (-0,00073), revelam uma correlação extremamente fraca ou praticamente inexistente entre os valores de SR e as concentrações de CO_{2eq}. A correlação de Spearman pode ser considerada moderada quando se aproxima de 0,2, como no caso do índice de vegetação VEXG_Med (0,236), porem este IV não apresentou relação significativa (p-valor > 0,05). No entanto, valores negativos, como o apresentado na banda espectral do Green do satélite Sentinel-2A (-0,366), indicam uma correlação inversa entre essas variáveis.

Portanto, a correlação de Spearman sugere que as relações entre os valores de sensoriamento remoto e as concentrações de CO_{2eq} são predominantemente fracas, com algumas exceções que apresentam correlações moderadas, mas, em geral, a relação não é forte. Isso indica que outras variáveis ou fatores podem ter um papel mais significativo na determinação das concentrações de CO_{2eq}.

O aprendizado das RNAs para estimar o CO_{2eq} com o modelo reduzido, utilizando apenas as variáveis com importância normalizada de aproximadamente 70%, também foi

configurado para utilizar 75% (24) das ua para treinamento e 25% (8) das ua para teste. A RNA utilizou 84,4% (27) das ua para treinamento e 15,6% (5) para teste, por entender ser necessário mais dados para realizar o aprendizado de redes. O processo de aprendizado foi estruturado por 12 neurônios ou camadas de entrada, 3 neurônios ou camadas ocultas e 1 neurônio ou camada de saída.

No treinamento, a soma dos erros quadráticos foi 0,586 e o erro relativo 4,5% (0,045). Já no teste, a soma dos erros quadráticos foi 0,033 e o erro relativo 159,2% (1,592). Para o treinamento os valores foram aceitáveis mesmo apresentando um erro relativo mais elevado, sendo aceitável para a utilização de RNA. Já no teste, em função do uso de apenas cinco de 32 ua, o que influenciou na medida dos erros.

A medida de viés pelo BIAS absoluto foi de $-1,85 \text{ Mg ha}^{-1}$, sendo o BIAS relativo de $-1,12\%$, e a raiz do erro quadrático médio (RMSE) absoluto foi de $50,20 \text{ Mg ha}^{-1}$, entre valores de $\text{CO}_{2\text{eq}}$ de referência e estimados pelo modelo completo obtido pela RNA, e o RMSE relativo foi de $1,99\%$. Estes parâmetros também indicam que um modelo satisfatório foi obtido, desta vez com apenas 12 de 180 variáveis de entrada simplificando o modelo obtido, mesmo com a inclusão de três ua com valores de $\text{CO}_{2\text{eq}}$ muito elevados, discrepantes em relação as demais ua, devido a presença de árvores de maiores dimensões em certas regiões dos SAFs, sendo isto um comportamento natural, pelos motivos já descritos anteriormente.

Os índices de vegetação SI_Max, CI_Max, ligados ao neurônio 1, e VIO_Max, ligado ao neurônio 3, foram as variáveis mais importantes, respectivamente, com 100, 84,3 e 50,4% de importância normalizada (Tabela 7). Essas variáveis não eram as mais importantes no modelo completo, destacando o aprendizado diferenciado das redes neurais obtidas no trabalho. Nesta modelagem, foi possível demonstrar a estrutura de aprendizado da rede neural artificial para gerar o modelo reduzido (Figura 8).

Tabela 7 - Importância das 12 variáveis de entrada no modelo reduzido para estimar $\text{CO}_{2\text{eq}}$ por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continua)

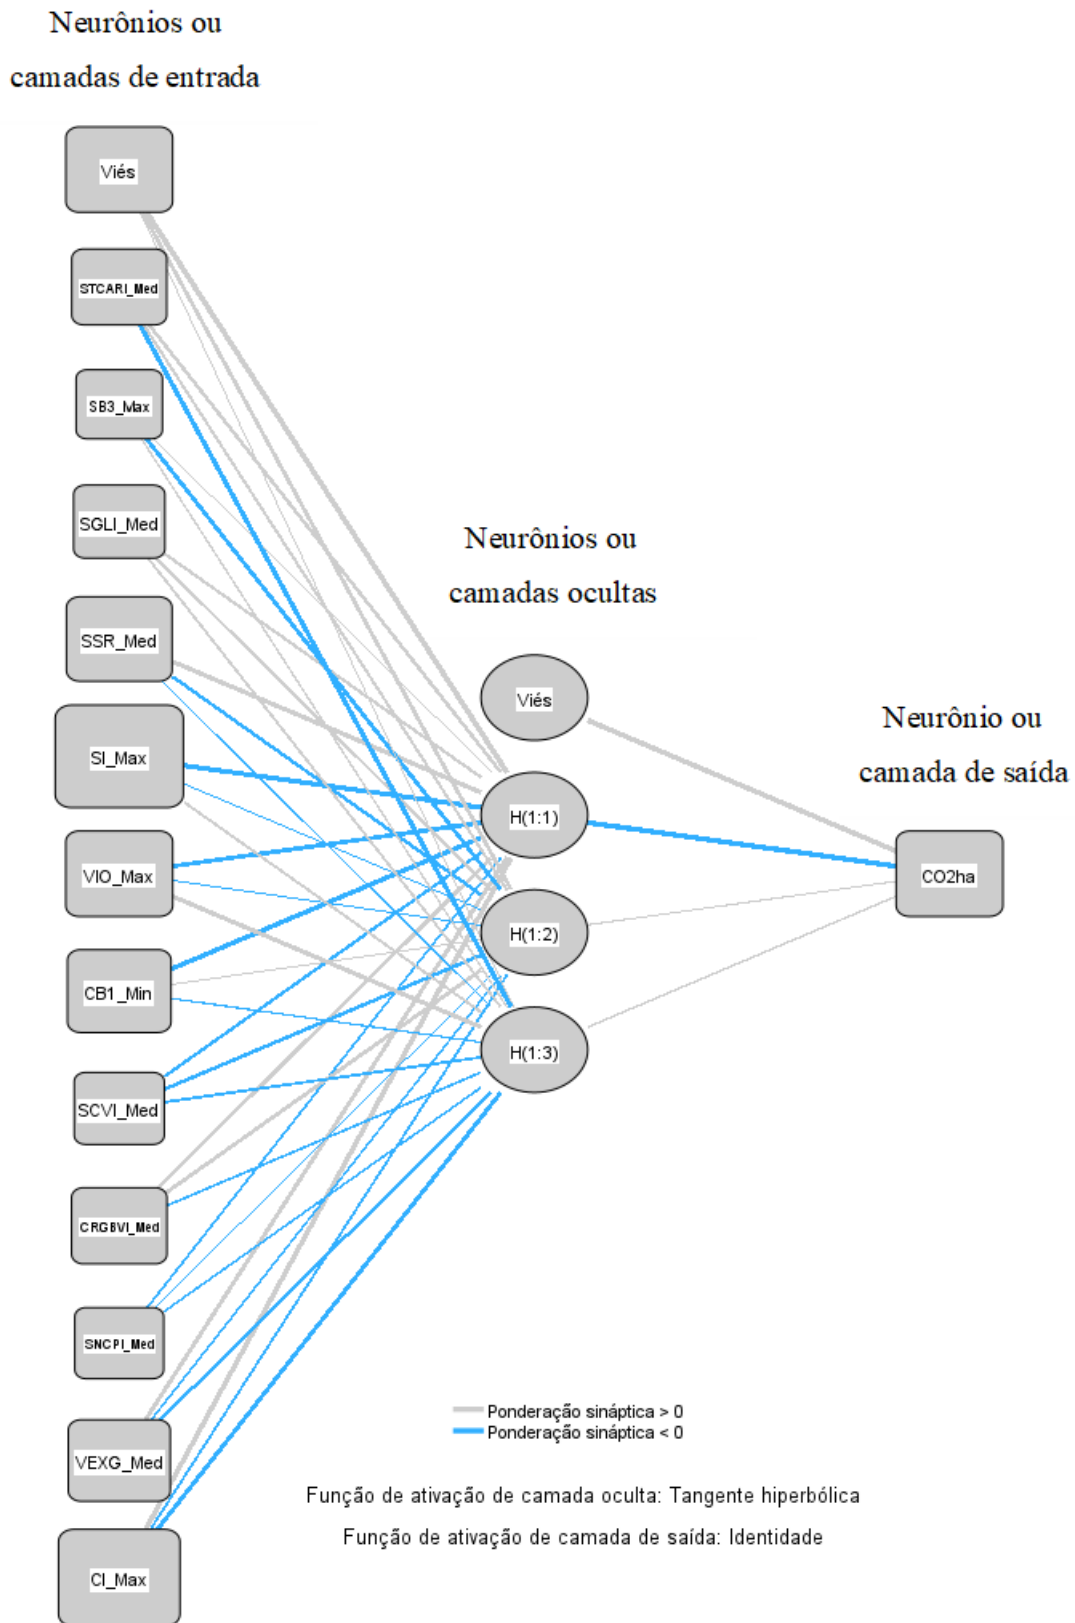
Importância da variável independente				
Número	Variáveis	Importância	Importância Relativa (%)	Importância normalizada
1	SI_Max	0.226	22.56	100.0%
2	CI_Max	0.190	19.02	84.3%
3	VIO_Max	0.114	11.37	50.4%
4	SSR_Med	0.107	10.65	47.2%
5	CB1_Min	0.096	9.59	42.5%
6	VEXG_Med	0.087	8.73	38.7%

Tabela 7 - Importância das 12 variáveis de entrada no modelo reduzido para estimar CO₂eq por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

					(Conclusão)
7	CRGBVI_Med	0.052	5.23	23.2%	
8	STCARI_Med	0.050	5.01	22.2%	
9	SGLI_Med	0.031	3.10	13.7%	
10	SCVI_Med	0.024	2.43	10.8%	
11	SNCPI_Med	0.018	1.83	8.1%	
12	SB3_Max	0.005	0.48	2.1%	

Fonte:Autor, (2023).

Figura 8 - Estrutura de aprendizado da RNA para estimar CO2 equivalente pelo modelo reduzido com dados de sensoriamento remoto (12 variáveis) em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.



Fonte: Autor (2023).

comparação dos parâmetros referentes aos dados de CO_{2eq} estimados pelos dois modelos obtidos pelas RNAs, foi apresentada a tabela 9.

Tabela 8 - Estatística descritiva para CO₂ equivalente determinados por equações alométricas e estimados por modelagem de redes neurais artificiais em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Var. (Mg ha ⁻¹)	M	EP	Md	Mo	S ²	S	CV%	K	As	V _{min}	V _{máx}	NC
CO _{2eq}	166,2	41,9	90,6	Amd	56271,37	237,22	142,7	18,23	4,09	48,34	1303,93	85,53
CO _{2eq} RNA _C	168,3	40,4	104,5	Amd	52160,67	228,39	135,7	17,17	3,95	31,93	1248,84	82,34
CO _{2eq} RNA _R	168,1	40,8	112,6	Amd	53266,68	230,80	137,3	19,28	4,26	54,07	1287,13	83,21

Legenda: Var. = Variáveis; CO_{2eq} RNA_C = CO₂ equivalente estimados pelo modelo completo obtido com redes neurais artificiais; CO_{2eq} RNA_R = CO₂ equivalente estimados pelo modelo reduzido obtido com redes neurais artificiais;; M = Média, EP = Erro padrão da média; Md = Mediana; Amd = Amodal; Mo = Moda; S² = Variância; S = Desvio Padrão; CV = Coeficiente de variação; K = Número de classes; As = Assimetria; V_{min} = variação mínima; V_{máx} = Variação máxima; NC = Nível de confiança para média de 95%;

Fonte: Autor (2023)

Tabela 9 - Parâmetros estatísticos para os modelos obtidos por RNAs para a estimativa de CO_{2eq} em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

Modelos RNA	Arquitetura		E.R. (treino)	E.R. (teste)	RMSE	RMSE %	DP	CV %	Bias	Bias %
	NE -> NI -> NS									
CO _{2eq} RNA _C	180 - 16 - 1		0.75	17.29	22.92	4.36	240.76	142.83	- 2.11	-1.27
CO _{2eq} RNA _R	12 - 3 - 1		4.51	159.25	50.20	1.99	230.79	137.31	- 1.85	-1.12

Legenda: NE = Neurônio de Entrada; NI = Neurônio Intermediário; NS = Neurônio de Saída; E.R. (trein) = Erro relativo do treinamento em RNA; E.R. (teste) = Erro relativo do teste em RNA; RMSE = Raiz do erro do quadrático médio; RMSE % = Raiz do erro quadrático médio relativo em percentagem; DP = Desvio padrão; CV % = Coeficiente de variação; Bias = Desvio sistemático do valor real apresentado por um valor estimado via modelagem para este valor observado ou de referência.

Fonte: Autor (2023)

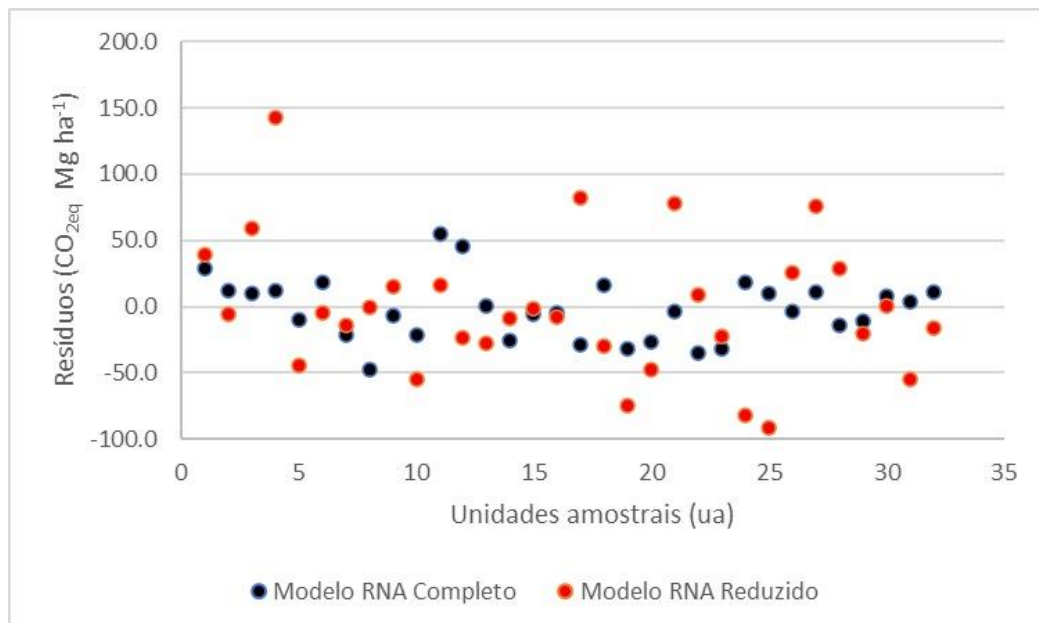
O modelo completo e reduzido gerados pela RNA para estimar o CO_{2eq} em relação aos valores obtidos pelos dados de campo demonstraram um desempenho satisfatório (Tabela 10). A diferença entre os valores estimados e os valores de campo foi de apenas 2,1 Mg ha⁻¹ (1,26% superestimado) e 1,19 Mg ha⁻¹ (1,14% superestimado), indicando resultados promissores para a estimativa de CO_{2eq} com o uso de dados de sensoriamento remoto de diferentes sensores. Esses resultados foram alcançados ao calcular a discrepância entre as estimativas de CO_{2eq} obtidas por meio de equações alométricas e as estimativas geradas do modelo completo e reduzido por RNA. Em seguida, a diferença entre essas estimativas foi expressa como uma

porcentagem, considerando que o valor calculado com base nas equações alométricas, que é considerado o valor de referência, corresponde a 100%.

Observou-se também que o modelo reduzido exibiu uma maior dispersão dos resíduos enquanto o modelo completo apresentou menos dispersão nos resíduos e um comportamento com maior estabilidade (Figura 10). Essa disparidade em alguns valores nos resíduos entre os modelos pode ser associada aos erros relativos apresentados na RNA, mas talvez principalmente pela redução das variáveis da camada de entrada para obter o modelo reduzido.

Além disso, os modelos completos e reduzidos exibiram valores distintos na raiz do erro quadrático médio, com 22,92 Mg CO_{2eq} ha⁻¹ para o completo e 50,20 Mg CO_{2eq} ha⁻¹ para o reduzido e quanto os valores de Bias que é o erro sistemático presente nos modelos, foi apresentado um valor de -2,11 Mg CO_{2eq} ha⁻¹ para o modelo completo, enquanto o modelo reduzido registrou -1,85 Mg CO_{2eq} ha⁻¹, apresentando valores considerados bons para os dois modelos. Apesar das estimativas do modelo reduzido terem apresentado maior dispersão nos resíduos do que no modelo completo, que por também ser apresentado precisão na estimativa do CO_{2eq} e por possuir menos variáveis, se torna um modelo mais prático para a utilização.

Figura 10 - Gráfico de Dispersão de Resíduos da Estimativa de CO_{2eq} equivalente, comparando os modelos completo RNAC e reduzido RNAR obtidos por redes neurais artificiais na vegetação acima do solo em sistema agroflorestral silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

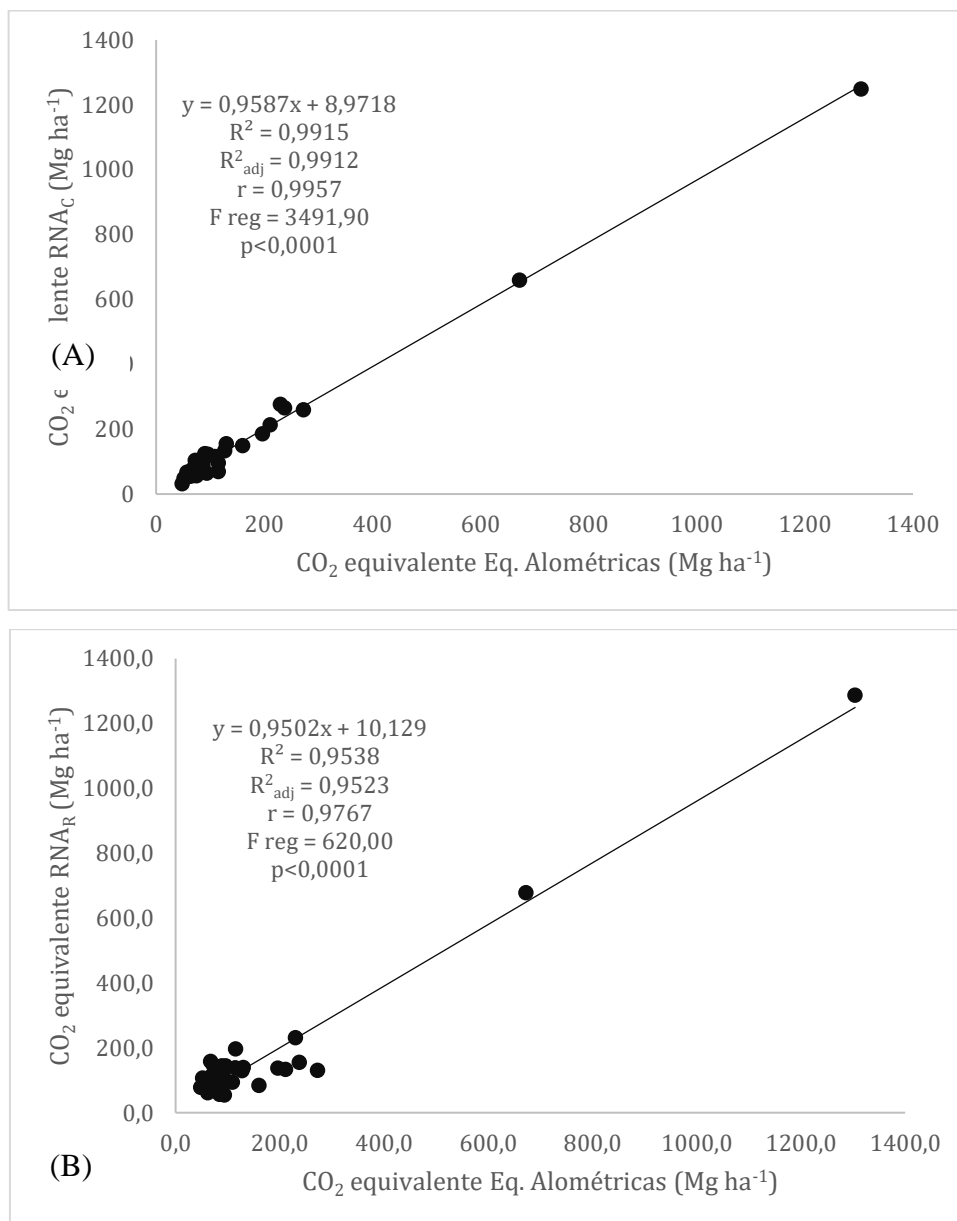


Fonte: Autor (2023).

No contexto da avaliação da qualidade dos modelos, o modelo completo demonstrou um desempenho superior em relação ao modelo reduzido, uma vez que apresenta um erro

relativo de teste significativamente menor (17.29% contra 159.25%) e um coeficiente de determinação na validação cruzada mais alto (0,99 contra 0,95), (Figura 11). Além disso, o desvio padrão do modelo completo é ligeiramente maior, o que pode indicar uma maior dispersão dos dados, mas esse modelo ainda supera o modelo reduzido em termos de precisão global.

Figura 11 - Validação Cruzada para os valores de CO₂ equivalente determinado por equações alométricas com dados de DAP (cm) e altura (m), e estimado pelos modelos completo (RNAC - A) e reduzido (RNAR - B) obtidos por redes neurais artificiais na vegetação acima do solo em Sistema Agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul – 2023.



Fonte: Autor (2023).

No entanto, vale ressaltar que os dados obtidos por ambos os modelos apresentaram um coeficiente de variação considerável, o que pode indicar alguma variação nos resultados, ao reproduzir o comportamento dos dados de referência. Portanto, em termos estatísticos o modelo completo é preferível ao modelo reduzido, mas é importante notar que o modelo reduzido, que utiliza menos variáveis de entrada, apresentou uma diferença mínima entre o valor de CO_2 equivalente estimado e o valor determinado por dados de campo e equações alométricas. Deste modo, a simplificação do modelo reduzido pode ser benéfica em situações em que a disponibilidade de dados ou a complexidade das análises é uma preocupação, facilitando a implementação prática e eficiente. Portanto, embora o modelo completo seja estatisticamente superior, o modelo reduzido pode ser mais apropriado em contextos onde a simplicidade e a aplicabilidade prática são prioridades.

Verly et al. (2021) utilizaram dados de sensoriamento remoto para estimar o estoque de carbono em fragmentos florestais da Mata Atlântica e obtiveram resultados satisfatórios, com alta correlação entre valores observados e previstos, baixos RMSE e Bias próximos de zero, demonstrando a capacidade das RNAs em modelar a variabilidade do estoque de carbono e CO_{2eq} . Pesquisas com diferentes modelos alométricos (incluindo lineares, não lineares e RNA) inferiram a considerável superioridade da RNA sobre os demais, para estabelecer a relação dos dados de SR com CO_{2eq} na vegetação acima do solo medido em campo (SCHOENINGER, 2008). Vários estudos já foram realizados sobre a aplicabilidade de RNA na previsão de parâmetros biofísicos de florestas, considerando variáveis dendrométricas medidas em campo como entradas (ENGLHART et al., 2011; VAHEDI, 2016). No entanto, o uso de dados de SR como variáveis de entrada no modelo RNA para prever CO_{2eq} na vegetação acima do solo medido em campo é uma abordagem bastante nova.

Os resultados obtidos no presente estudo apresentaram evidências substanciais de que a utilização de RNA se destacou como uma abordagem eficaz para elaborar modelos que possam estimar CO_{2eq} na vegetação acima do solo em SAFs com precisão. Os resultados obtidos indicam que as RNAs conseguiram capturar de maneira precisa as complexas relações entre variável de CO_{2eq} estimada por equação alométrica com dados de SR em SAF silvibananeiro, proporcionando estimativa de CO_{2eq} com um elevado grau de exatidão. Essa precisão superior se deve à capacidade das RNA de modelar relações não lineares, que são frequentemente encontradas em sistemas agroflorestais devido à coexistência de diferentes espécies vegetais, indivíduos de diferentes portes e distribuições, bem como suas interações, que por vezes podem ser diferentes as de ocorrência em florestas nativas.

Contudo, existem algumas incertezas em nosso procedimento de estimativa de $\text{CO}_{2\text{eq}}$ na vegetação acima do solo. Primeiro, não tivemos acesso a valores reais de biomassa, determinados de forma direta na área do estudo, onde permitiria obter um valor mais próximo do real de biomassa e conseqüentemente de $\text{CO}_{2\text{eq}}$ da região do estudo. Portanto, utilizamos equações alométricas obtidas em outras regiões, resultando em valores estimados, que possivelmente proporcionaram erros ao valor real. Além disso, os erros de posição do GPS afetam consideravelmente os resultados obtidos em estudos de detecção remota (RONOUD et al., 2021), enquanto todos os algoritmos de aprendizagem automática são específicos do local, no sentido de que os seus resultados podem variar consoante a área de estudo (MORADI et al., 2022). Como tal, a generalização dos nossos resultados deve ser feita com cautela e baseada na validação da especificidade do local.

No entanto, esses resultados representam um avanço significativo na estimativa de $\text{CO}_{2\text{eq}}$ em SAFs na região do estudo, reduzindo custos e tempo e possibilitando um planejamento mais eficiente para propriedades que adotaram a produção por meio de SAFs. Isso contribui para a valorização dessas propriedades na região e para atender a um dos objetivos do projeto do Centro Ecológico, do qual uma das metas é a mensuração/comprovação do estoque de 4 mil Mg de $\text{CO}_{2\text{eq}}$ em áreas de SAF.

5 CONSIDERAÇÕES FINAIS

A utilização de dados (índices de vegetação e refletância em bandas específicas) obtidos por sensores embarcados nos satélites CBERS 4A e Sentinel-2A, bem como com o sensor RGB embarcado na RPA Phantom 4, demonstraram ser abordagens eficazes para a coleta de informações essenciais para o desenvolvimento de modelos por Redes Neurais Artificiais (RNAs) para estimar o $\text{CO}_{2\text{eq}}$. Porém, a análise multivariada fatorial e a análise de correlação de Spearman mostraram que as variáveis de sensoriamento remoto apresentaram baixas correlações com dados de $\text{CO}_{2\text{eq}}$, demandando o uso de RNAs para realizar a modelagem dos dados.

As RNAs com a utilização dos dados de SR, se mostrou eficaz na obtenção de estimativas de $\text{CO}_{2\text{eq}}$ na vegetação acima do solo no SAF em questão, fornecendo uma abordagem alternativa e complementar ao uso de mensurações por métodos diretos.

Os dois modelos desenvolvidos por RNA, completo e reduzido, mostraram-se eficazes para a estimativa de $\text{CO}_{2\text{eq}}$ estocado acima do solo por meio de dados de sensoriamento remoto, em termos de precisão quando comparados ao valor de referência. No entanto, o modelo reduzido, oferece uma ferramenta eficaz e prática por utilizar um menor número de variáveis.

Recomenda-se conduzir novas pesquisas considerando de outras áreas de SAFs silvibananeiro, para que os modelos possam representar melhor as áreas de SAFs na região do estudo, obtendo também diferentes variáveis independentes. Deve-se explorar outros Índices de Vegetação, além de examinar a utilidade de sensores orbitais mais avançados, que ofereçam uma melhor resolução temporal, espacial, espectral e radiométrica. Além disso, é aconselhável testar diversas configurações de redes neurais, visando otimizar a correlação entre os dados dendrométricos e as informações digitais, ou outros métodos de inteligência artificial, resultando assim em estimativas mais precisas das variáveis de interesse nos Sistemas Agroflorestais.

Recomenda-se, adicionalmente, a aplicação do método destrutivo para a quantificação da biomassa acima do solo, o que viabiliza o desenvolvimento de equações alométricas e também modelos por RNAs para estimar com maior precisão o $\text{CO}_{2\text{eq}}$ na vegetação acima do solo nos SAFs silvibananeiros na região do Litoral Norte do Rio Grande do Sul.

REFERÊNCIAS

- AHMAD, Ali et al. **Remotely piloted aircraft (RPA) in agriculture: A pursuit of sustainability.** *Agronomy*, v. 11, n. 1, p. 7, 2020.
- ALABARCE, Fernanda da Silva. **Caracterização ecofisiológica do estabelecimento inicial de *Euterpe edulis* MARTIUS em agroflorestal,** 2016.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ALBUQUERQUE, Rafael Walter et al. Forest restoration monitoring protocol with a low-cost remotely piloted aircraft: Lessons learned from a case study in the brazilian atlantic forest. **Remote Sensing**, v. 13, n. 12, p. 2401, 2021.
- ARANCIBIA, Ivã Andreas Lima. **Carbono estocado acima do solo por um sistema agroflorestal sucessional na mata atlântica.** 2021. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.
- ATAIDES, Rafael Peixoto. Informações de imagens do satélite Pleiades estimam com precisão estoques de biomassa e o volume de madeira em área de cerrado sensu stricto?. 2019.
- BARBOSA, Verilma et al. Biomassa, carbono e nitrogênio na serapilheira acumulada de florestas plantadas e nativa. **Floresta e Ambiente**, v. 24, p. e20150243, 2017.
- BARNES, E. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the fifth International Conference on Precision Agriculture**, 2000.
- BENDIG, J. et al. Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. **Remote Sensing**, v. 6, n. 11, p. 10395-10412, 2014.
- BOLFE, Édson Luis; BATISTELLA, Mateus; FERREIRA, Marcos César. Correlação de variáveis espectrais e estoque de carbono da biomassa aérea de sistemas agroflorestais. **Pesquisa Agropecuária Brasileira**, v. 47, p. 1261-1269, 2012.
- BOLIVAR-SANTAMARIA, Sérgio; REU, Bjorn. Detecção e caracterização de sistemas agroflorestais nos Andes colombianos utilizando imagens sentinel-2. **Sistemas Agroflorestais**, v. 95, p. 499-514, 2021.
- BONINI, Isabelle et al. Collapse of ecosystem carbon stocks due to forest conversion to soybean plantations at the Amazon-Cerrado transition. **Forest Ecology and Management**, v. 414, p. 64-73, 2018.
- BORGES, Mariley Gonçalves; RODRIGUES, Héric Lyncon Antunes; LEITE, Marcos Esdras. Mapeamento de fitofisionomias do Cerrado na microrregião de Grão Mogol através de imagens de satélite Landsat 8 e Sentinel-2A. **Revista Tocantinense de Geografia**, v. 6, n. 11, p. 19-30, 2017.

BORGES, Marcelo Gules; CARVALHO, Isabel Cristina de Moura; STEIL, Carlos Alberto. A juçara vai à escola: aprendizagem entre pessoas, coisas e instituições. **Horizontes Antropológicos**, v. 21, p. 309-329, 2015.

BRAGA, A. P.; CARVALHO, C. P. L. F.; LUDERMIR, T. B. [S.l.]: LTC, 2007. 248 p. ISBN 8521615647.

BRITO, A. et al. Comparação entre métodos de Quadrantes e Prodan para análise florística, fitossociológica e volumétrica. **Revista Cerne**, v. 13, n. 4, p. 399-405, 2007.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. **FAO Forestry Paper**, v. 134, Roma, 1997. Disponível em: <<http://www.fao.org/3/W4095E/w4095e00.htm#Contents>>.

CAON, I. L., Becker, W. R., Ganascini, D., Cattani, C. E. V., De Souza Mendes, I., Hugo, V., Prudente, R., Oldoni, L. V., Antunes, J. F. G., & Mercante, E. (2019). **Comparativo entre os classificadores RF e MAXVER, para a classificação de uso e cobertura da terra, em diferentes densidades temporais.**

COURA, S. M. da C. Mapeamento da vegetação do Estado de Minas Gerais utilizando dados Modis. 2007. 147 f. Dissertação (Mestrado em Sensoriamento Remoto) – **Instituto Nacional de Pesquisas Espaciais**, São José dos Campos, 2007.

DA ROCHA FERREIRA, Lucas; DAL SOGLIO, Fabio Kessler. Sistemas Agroflorestais para a agricultura familiar: formação de redes rurais no rio grande do sul. **Revista Brasileira de Agroecologia**, v. 16, n. 2, p. 13-13, 2021.

DAUGHTRY, C. S. T. et al. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance Remote Sensing of Environment. v. 74. 2000.

DE LIMA, Gabriella Santos Arruda et al. Carbon estimation in an integrated crop-livestock system with imaging sensors aboard unmanned aerial platforms. *Remote Sensing Applications: Society and Environment*, v. 28, p. 100867, 2022.

DE PAULA AMARAL, Lúcio et al. Variabilidade espacial em sistema agroflorestal silvibananeiro, no litoral do Rio Grande do Sul, com gvSIG. **Nativa**, v. 9, n. 1, p. 44-53, 2021.

ENGLHART, Sandra; KEUCK, Vanessa; SIEGERT, Florian. Modeling aboveground biomass in tropical forests using multi-frequency SAR data—A comparison of methods. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 5, n. 1, p. 298-306, 2011.

FLORESTAL, Novo Código. Lei 12.651 de 25 de maio de 2012. Presidência da República. Casa Civil. Subchefia para Assuntos Jurídicos, 2017.

FLORESTAL, BRASIL—CÓDIGO. Lei nº 4.771 de 15 de setembro de 1965. **Institui o novo Código Florestal. Brasília, DF**, 1965.

FONSECA, Cássia Kellen Lopes. **Uso de drone para estimativa de biomassa em áreas de caatinga do estado de Pernambuco**. 2020. Dissertação de Mestrado. Universidade Federal de Pernambuco.

Fonseca, L. G. M. et al. Apostila de processamento digital de imagens. São José dos Campos: INPE, jun. 2000.

FORNACE, Kimberly M. et al. Mapping infectious disease landscapes: unmanned aerial vehicles and epidemiology. **Trends in parasitology**, v. 30, n. 11, p. 514-519, 2014.

GARRETT HG, Buck L (1997) Prática e política agroflorestal nos Estados Unidos da América. Para **Ecol Manage** 91:5–15. [https://doi.org/10.1016/S0378-1127\(96\)03884-4](https://doi.org/10.1016/S0378-1127(96)03884-4)

GAO, Bo-Cai. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote sensing of environment**, v. 58, n. 3, p. 257-266, 1996.

GILLESPIE, A. R.; KAHLE, A. B.; WALKER, R. E. Color enhancement of highly correlated images. II Channel ratio and “chromaticity” transformation techniques. **Remote Sensing of Environment**, v. 22, pp. 343 – 365, 1987.

GITELSON, Anatoly A. et al. Remote estimation of canopy chlorophyll content in crops. **Geophysical research letters**, v. 32, n. 8, 2005.

GLIESSMAN, S. R. **Agroecologia: Processos ecológicos em Agricultura Sustentável**. 4a Edição. Porto Alegre: Editora da UFRGS, 2009.

GNYP, M.L., PANITZKI, M., REUSCH, S., 2015. Proximal nitrogen sensing by off-nadir and nadir measurements in winter wheat canopy. In: Stafford, J.V. (Ed.) **Proceedings of the European Conference on Precision Agriculture 2015**, Tel Aviv. Pp. 43-50.

GRISCOM BW, Adams J, Ellis PW et al (2017) **Soluções climáticas naturais**. Proc Natl Acad Sci USA 114:11645–11650. <https://doi.org/10.1073/pnas.1710465114>

GOETZ, Scott J. et al. Mapping and monitoring carbon stocks with satellite observations: a comparison of methods. **Carbon balance and management**, v. 4, n. 1, p. 1-7, 2009.

GUERRA, SCS. O novo código florestal brasileiro e os sistemas agroflorestais: implicações e considerações sobre as áreas de preservação permanente e reservas legais. **II Congresso Brasileiro de Reflorestamento Ambiental**. Universidade Federal do Espírito Santo, 2012.

GOETZ, Scott J. et al. Mapping and monitoring carbon stocks with satellite observations: a comparison of methods. **Carbon balance and management**, v. 4, n. 1, p. 1-7, 2009.

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, n. 2–3, p. 416-426, 2002. Doi.org/10.1016/S00344257(02)00018-4.

HAGGAR, J. et al. Contribution of agroforestry systems to sustaining biodiversity in fragmented forest landscapes. **Agriculture, Ecosystems and Environment**, v. 283, n. June, p. 106567, 2019.

HAIR JR., J.F.; WILLIAM, B.; BABIN, B.; ANDERSON, R.E. **Análise multivariada de dados**. 6.ed. Porto Alegre: Bookman, 2009.

HAIR JÚNIOR, J. F; ANDERSON, R. E; TATHAN, R. L; BLACK, W. C. **Análise Multivariada de Dados**. 5. ed. Porto Alegre: Bookman, 2005. 593p.

HENDERSON, Andrew et al. O gênero Euterpe no Brasil. **Selowia** , n. 49/52, pág. 1-22, 2000.

HUETE, Alfredo R. Soil influences in remotely sensed vegetation-canopy spectra. Theory and applications of optical remote sensing, 1989.

IBGE. **Manual técnico da vegetação brasileira**. 2. ed. Rio de Janeiro: IBGE, 2012, 92p.

INPE. Bernardo F. T. Rudorff. Brasil (Org.) PRODUTOS DE SENSORIAMENTO REMOTO. Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: 02 outubro 2023.

Instituto Nacional De Pesquisas Espaciais (INPE). Lançamento CBERS 04A. **Instituto Nacional de Pesquisas Espaciais**, São José dos Campos, 2020.

JOHNSON, R. A.; WICHERN. D. W. Applied multivariate statistical analysis. **Englewood Cliffs: Prentice-Hall**, 1988. 607p.

KERSHAW Jr., J. A.; DUCEY, M. J.; BEERS, T. W.; HUSCH, B. (2017). **Forest mensuration**. Chichester; Hoboken: John Wiley & Sons, 5a ed., 632 p.

KUMAR, B.M.; NAIR, P.K.R. (eds.) Carbon Sequestration Potential of Agroforestry Systems: Opportunities and Challenges, *Advances in Agroforestry*. v.8, DOI 10.1007/978-94-007-1630-8_1, **Springer Science+Business Media B.V.**, 2011.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D.E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, v. 16, p. 65-70. 2001.

LOURENÇO, Alexandre; MATIAS, Rui P. Estatística multivariada. Porto: **Instituto Superior de Engenharia do Porto**, 2001.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297–1328, 2006. Taylor and Francis Ltd. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01431160500486732>>. Acesso em: 21 out. 2023.

LU, Dengsheng; BATISTELLA, Mateus; MORAN, Emilio. Satellite estimation of aboveground biomass and impacts of forest stand structure. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 8, p. 967-974, 2005.

LU, Ning et al. Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. **Plant Methods**, v. 15, n. 1, p. 1-16, 2019.

LU, X.; GUO, Q.; LI, W.; FLANAGAN, J. A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 94, p. 1–12, 2014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271614000860>>. Acesso em: 05 out.. 2023.

MACEDO, Fabrício Lopes de. Modelagem da biomassa acima do solo (BAS), por meio de imagens de alta resolução espacial e índices de vegetação. 2014.

MANLY, B. J.; ALBERTO, J. A. Métodos estatísticos multivariados: uma introdução. 4. ed. Porto Alegre: Bookman, 254 p. 2019.

MANSANI, G. C.; SILVA, L. C.; PEREZ-CASSARINO, J.; FARIA, K. K.; LEANDRINI, J. A. **Sistemas agroflorestais na floresta ombrófila mista e sua contribuição para a agroecologia**. v. 17 n. 3 (2022): Anais da Reunião Técnica sobre Agroecologia - Agroecologia, Resiliência e Bem Viver - Pelotas, RS, 2022.

MCFEETERS, S. K. The use of the normalized difference water index (ndwi) in the delineation of open water features. **International Journal of Remote Sensing, Taylor & Francis**, v. 17, n. 7, p. 1425-1432, 1996.

MORADI, Fardin et al. Above-ground biomass estimation in a Mediterranean sparse coppice oak forest using Sentinel-2 data. **Annals of Forest Research**, v. 65, n. 1, p. 165-182, 2022.

MORGAN, D.; FALKNER, E. **Geometry Of Aerial Photographs**. v. 1, p. 39–44, 2002.

Nair PKR, Nair VD, Mohan Kumar B, Showalter JM (2010) Sequestro de carbono em sistemas agroflorestais. In: Avanços em agronomia. Elsevier, pp 237–307

NEISSE, A. C.; HONGYU, K. Aplicação de componentes principais e análise fatorial a dados criminais de 26 estados dos EUA. **E&S Engineering and Science**, v.6, n.2, 2016.

Oliveira, N.L.; Jacq, C.; Dolci, M.; Delahaye, F. (2010) Desenvolvimento sustentável e sistemas agroflorestais na Amazônia matogrossense, *Confins*, 10, 2010.

PACHECO, M. R. P. S.; HELENE, M. E. M. Atmosfera, fluxos de carbono e fertilização por CO₂. *Estud. av.*, São Paulo, v. 4, n. 9, p. 204-220, aug. 1990. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S010340141990000200010&lng=en&nrm=iso>.

PEÑUELAS J, BARET F, FILELLAI. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, v. 31, n. 2, p. 221–230, 1995.

PEÑUELAS, J.; BARET, F.; FIRELELLA, I. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. **Photosynthetica**, v.31, n.2, p.221-230, 1993.

PONZONI, Flávio Jorge; SHIMABUKURO, Yosio Edemir; KUPLICH, Tatiana Mora. **Sensoriamento remoto da vegetação**. Oficina de textos, 2015.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos - São Paulo: Parêntese, 2009

PONZONI, F.J.; REZENDE, A.C.P. Caracterização espectral de estágios sucessionais de vegetação secundária arbórea em Altamira (PA), através de dados orbitais. **Revista Árvore**, v.28, p.535-545, 2004.

Portal index database. <https://www.indexdatabase.de/db/i-single.php?id=51>. Acesso em set 2023.

PRUDKIN, Gonzalo. Drones: su origen y aplicación en el periodismo contemporáneo para generación de contenidos en 3D. **DRONES E CIÊNCIA**, p. 9, 2019.

REIS, E. Estatística multivariada aplicada. **Lisboa**, 1997.

REZENDE, Alba Valéria et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, v. 71, n. 2, p. 65-73, 2006.

RIBEIRO JÚNIOR, J. I. Análises estatísticas no Excel. Guia prático. Viçosa: Editora UFV, 2004. 251p.

RIZZI, R.; RUDORFF, B.F.T. Imagens do sensor MODIS associadas a um modelo agrônomo para estimar a produtividade de soja. **Pesquisa Agropecuária Brasileira**, v.42, p.73-80, 2007.

RONOUD, Ghasem et al. Multi-sensor aboveground biomass estimation in the broadleaved Hyrcanian forest of Iran. **Canadian journal of remote sensing**, v. 47, n. 6, p. 818-834, 2021.

ROUSE, J. W. **Monitoring Vegetation Systems in the Great Plains with ERTS**. US Government Printing Office, 1973.

SANTORI, Alisson R. Amostragem de componentes puros (vegetação, solo, água/sombra) em imagens de satélite Sentinel-2 como subsídios à interpretação do NDVI na Bacia Hidrográfica do Ribeirão das Cruzes, Selvíria/MS. **Boletim Paulista de Geografia**, v. 1, n. 107, p. 76-95, 2022.

SAKAMOTO, Toshihiro et al. An alternative method using digital cameras for continuous monitoring of crop status. **Agricultural and Forest Meteorology**, v. 154, p. 113-126, 2012.

SCHOENINGER, Emerson Roberto et al. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa Artificial neural networks in the biomass and organic carbon mapping of the arboreal component of a dense ombrophile forest. **Ambiência**, v. 4, n. 2, p. 179-195, 2008.

SCHUH, Mateus Sabadi et al. **Estimativa da biomassa acima do solo em floresta de terra firme na Amazônia com dados LiDAR aerotransportado e upscaling com imagens orbitais**. 2023. Tese de Doutorado. Universidade Federal de Santa Maria.

Sentinel Hub. Disponível em: <https://www.sentinel-hub.com/>. Acesso em: 15/10/2023.

SHI, Lei; LIU, Shirong. Methods of estimating forest biomass: **A review**. Biomass Volume Estimation and Valorization for Energy, v. 10, p. 65733, 2017.

SIEGEL S. Estatística não-paramétrico para as ciências do comportamento. São Paulo: McGraw-Hill do Brasil; 1975.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas. 2012.

SOARES, T. M. **Utilização da teoria da resposta ao item na produção de indicadores sócio-econômicos**. Pesquisa Operacional, Sociedade Brasileira de Pesquisa Operacional, v. 25, n. 1, p. 83112, 2005.

SOUSA, Larissa Melo de. **Sistemas agroflorestais: uma abordagem sobre mudanças de uso e cobertura da terra e estimativa de carbono**, no município de Tomé-Açu, Pará. 2021. Tese de Doutorado. Ufra/Campus Belém

SOUZA, A. L. R. et al. (2010, agosto). Protocolo de kyoto e mercado de carbono: estudo exploratório das abordagens contábeis aplicadas aos créditos de carbono e o perfil de projetos de MDL no Brasil. **VI Congresso Nacional de Excelência em Gestão**, Niterói, 10p. Acesso em: 18/05/2021.

STEENBOCK, Walter et al. Avaliação da dinâmica do carbono em agroflorestas desenvolvidas por agricultores associados à Cooperafloresta. Agrofloresta, **ecologia e sociedade**, p. 345-362, 2013.

STONE, Mervyn. Cross-validatory choice and assessment of statistical predictions. **Journal of the royal statistical society: Series B (Methodological)**, v. 36, n. 2, p. 111-133, 1974.

TANIZAKI, K. F. **Impactos do uso do solo no estoque e fluxo de carbono no domínio da Mata Atlântica: estudo de caso no estado do Rio de Janeiro**. Tese (Doutorado) - Departamento de Geografia Ambiental, Universidade Federal Fluminense, Rio de Janeiro, 2000.

THAPA, Bhuwan; LOVELL, Sarah; WILSON, Jeffrey. Remote sensing and machine learning applications for aboveground biomass estimation in agroforestry systems: a review. **Agroforestry Systems**, p. 1-15, 2023.

TEMESGEN, Hailemariam et al. A review of the challenges and opportunities in estimating above ground forest biomass using tree-level models. **Scandinavian Journal of Forest Research**, v. 30, n. 4, p. 326-335, 2015.

TORRES-SÁNCHEZ, Jorge et al. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. **Computers and Electronics in Agriculture**, v. 103, p. 104-113, 2014.

Tumbo, D.S.; Wagner, D.G.; Heinenmann, P.H. Real-world hyperspectral characteristics of corn plants under different chlorophyll levels. In: 2000 ASAE Annual International Meeting. Proceedings... Mineapolis: ASAE. 2000. **ASAE Paper No.** 001093

Udawatta RP, Jose S (2012) Estratégias agroflorestais para sequestrar carbono na América do Norte temperada. **Agrofor Syst** 86:225–242. <https://doi.org/10.1605/01.301-0020846221.2012>

VAHEDI, Ali Asghar. Artificial neural network application in comparison with modeling allometric equations for predicting above-ground biomass in the Hyrcanian mixed-beech forests of Iran. **Biomass and Bioenergy**, v. 88, p. 66-76, 2016.

VERLY, Otávio Miranda. Sensoriamento remoto na estimativa do estoque de carbono em fragmentos florestais da Mata Atlântica. 2021.

VICINI, L. et al. Técnicas Multivariadas Exploratórias: Teoria e Aplicações no Software Statistica. Santa Maria: **Editora UFSM**, 240 p. 2018.

VICINI, Lorena. Análise multivariada: da teoria à prática. 2005.

VIEIRA, Marcelo Nunes. As novidades na produção do Açaí Juçara nos municípios de Três Cachoeiras e Morrinhos do Sul/RS. 2022.

VIVAN, Jorge Luiz. Bananicultura em sistemas agroflorestais no Litoral Norte do RS. **Agroecologia e Desenvolvimento Rural Sustentável**, v. 3, n. 2, p. 1-20, 2002.

WANG Y, Pyörälä J, Liang X et al (2019) Estimativa de biomassa in situ em níveis de árvore e parcela: o que os dados registraram e o que os algoritmos derivaram de nuvens de pontos terrestres e aéreas na floresta boreal. **Remote Sens Environ** 232:111309. <https://doi.org/10.1016/j.rse.2019.111309>

WATZLAWICK, Luciano Farinha; KIRCHNER, Flávio Felipe; SANQUETTA, Carlos Roberto. Carbon and biomass estimate in araucarian forest using satellite images from Ikonos II. **Ciência Florestal**, v. 19, n. 2, p. 169-181, 2009.

Wilson M, Lovell S (2016) Agrofloresta – o próximo passo na agricultura sustentável e resiliente. **Sustentabilidade** 8:574. <https://doi.org/10.3390/su8060574>

WOEBBECKE, D. M. et al. Shape features for identifying young weeds using image analysis. Transactions of the ASAE (**American Society of Agricultural Engineers**), v. 38, n. 1, p. 271–281, 1995.

YANG, Zhengwei; WILLIS, Patrick; MUELLER, Rick. **Impact of band-ratio enhanced AWIFS image to crop classification accuracy**. In: Proc. Pecora. 2008. p. 1-11.

YOUNG, Iris Marion. The logic of masculinist protection: Reflections on the current security state. Signs: **journal of women in culture and society**, v. 29, n. 1, p. 1-25, 2003.

ZHANG, Q. et al. Application of uav-based remote sensing technology in agriculture: A review. **Remote Sensing, Multidisciplinary Digital Publishing Institute**, v. 11, n. 14, p. 1697, 2019.

APÊNDICE A – IMAGENS DAS BANDAS ESPECTRAIS DOS SENSORES UTILIZADOS NA PESQUISA.

Figura 12- Imagens das bandas espectrais dos sensores da câmera RGB do RPA, do sensor CBERS4A e o sensor Sentinel-2A, utilizadas para a obtenção dos índices de vegetação.

(continua)

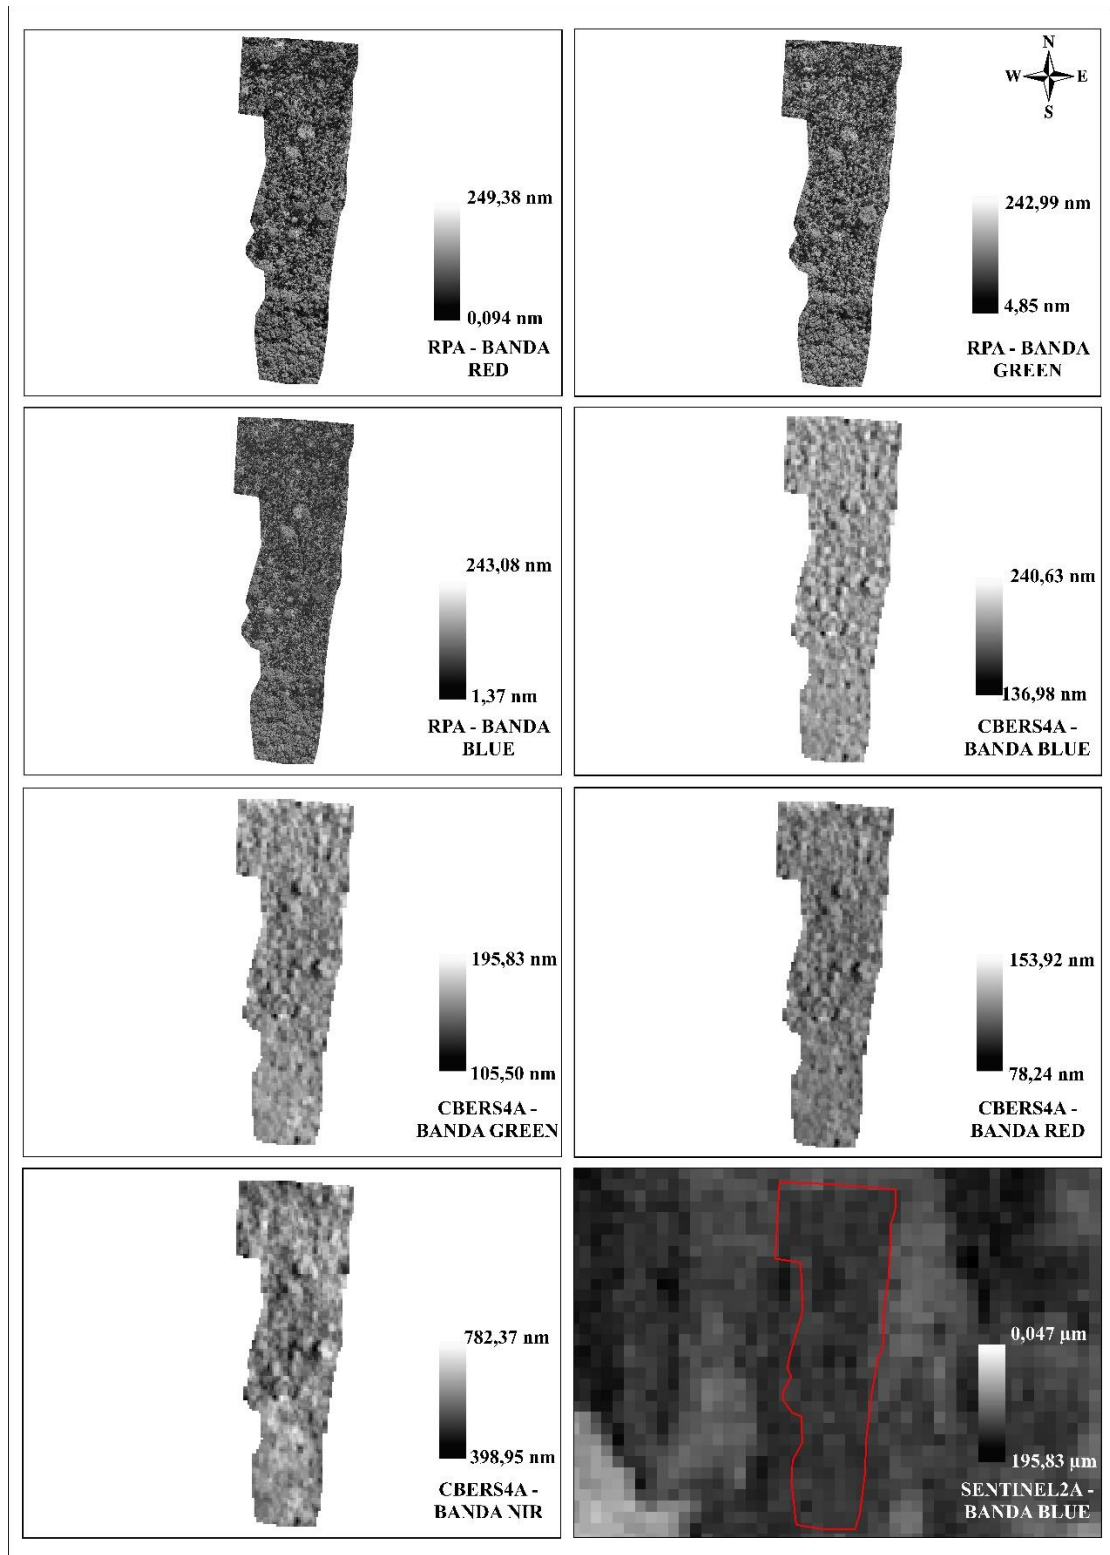



Figura 12- Imagens das bandas espectrais dos sensores da câmera RGB do RPA, do sensor CBERS4A e o sensor Sentinel-2A, utilizadas para a obtenção dos índices de vegetação.

(conclusão)



Fonte: Autor (2023)

APÊNDICE C – IMPORTÂNCIA DAS VARIÁVEIS DE ENTRADA DO MODELO COMPLETO, PARA ESTIMAR CO₂eq EQUIVALENTE POR REDE NEURAL ARTIFICIAL.

Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO₂ equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continua)

Importância da variável independente (entrada)				
Número	Variáveis	Importância	Importância Relativa (%)	Importância normalizada
1	STCARI_Med	0,012	1,205	100,0%
2	SB3_Max	0,012	1,183	98,2%
3	SGLI_Med	0,011	1,135	94,2%
4	SSR_Med	0,011	1,130	93,7%
5	SI_Max	0,010	1,029	85,4%
6	VIO_Max	0,010	1,023	84,9%
7	CB1_Min	0,010	0,956	79,3%
8	SCVI_Med	0,009	0,934	77,5%
9	CRGBVI_Med	0,009	0,876	72,7%
10	SNCPI_Med	0,009	0,861	71,4%
11	VEXG_Med	0,008	0,848	70,3%
12	CI_Max	0,008	0,842	69,9%
13	SB2_Min	0,008	0,827	68,6%
14	SRGBVI_Min	0,008	0,796	66,0%
15	SSAVI_Med	0,008	0,764	63,4%
16	VEXG_Min	0,008	0,755	62,7%
17	SNDWI_Min	0,007	0,750	62,2%
18	CRS_Min	0,007	0,738	61,3%
19	VIO_Med	0,007	0,728	60,4%
20	CB4_Max	0,007	0,710	58,9%
21	SSIPI_Med	0,007	0,705	58,5%
22	CNDWI_Min	0,007	0,701	58,2%
23	SCVI_Min	0,007	0,696	57,7%
24	SB2_Max	0,007	0,694	57,6%
25	SNDRE_Min	0,007	0,693	57,6%
26	CGCC_Med	0,007	0,692	57,4%
27	SCIGREEN_Med	0,007	0,692	57,4%
28	SEXG_Min	0,007	0,688	57,1%
29	SIO_Min	0,007	0,683	56,6%
30	CIO_Min	0,007	0,679	56,4%
31	CNDVI_Max	0,007	0,678	56,2%
32	SI_Med	0,007	0,677	56,2%
33	VB3_Min	0,007	0,676	56,1%
34	CNORMRED_Min	0,007	0,676	56,1%
35	SB2_Med	0,007	0,665	55,2%

Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO2 equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continuação)

36	VNCPI_Max	0,007	0,664	55,1%
37	CGLI_Med	0,007	0,658	54,6%
38	CNCPI_Med	0,007	0,655	54,3%
39	CI_Min	0,007	0,653	54,2%
40	VEXG_Max	0,006	0,645	53,5%
41	STCARI_Min	0,006	0,644	53,4%
42	CNCPI_Min	0,006	0,639	53,0%
43	SIO_Med	0,006	0,636	52,8%
44	CB2_Max	0,006	0,635	52,7%
45	CIO_Max	0,006	0,634	52,7%
46	SMPRI_Min	0,006	0,632	52,5%
47	SNORMRED_Max	0,006	0,632	52,5%
48	SNCPI_Min	0,006	0,631	52,4%
49	CEXG_Med	0,006	0,631	52,4%
50	SNORMNIR_Med	0,006	0,627	52,1%
51	CCVI_Med	0,006	0,627	52,0%
52	SNDRE_Med	0,006	0,627	52,0%
53	CNORMRED_Med	0,006	0,623	51,7%
54	SSR_Min	0,006	0,620	51,5%
55	CNDWI_Max	0,006	0,619	51,3%
56	VMPRI_Med	0,006	0,611	50,7%
57	SB3_Med	0,006	0,611	50,7%
58	SB4_Med	0,006	0,611	50,7%
59	SMCARI_Min	0,006	0,602	50,0%
60	CCIGREEN_Max	0,006	0,600	49,8%
61	VI_Max	0,006	0,595	49,4%
62	CB1_Max	0,006	0,593	49,2%
63	SIO_Max	0,006	0,589	48,9%
64	VRGBVI_Max	0,006	0,589	48,9%
65	SMVI_Min	0,006	0,588	48,8%
66	SB3_Min	0,006	0,582	48,3%
67	CB1_Med	0,006	0,582	48,3%
68	CMPRI_Max	0,006	0,581	48,3%
69	SNDWI_Med	0,006	0,580	48,1%
70	VGLI_Med	0,006	0,579	48,1%
71	SMPRI_Max	0,006	0,576	47,8%
72	CB3_Min	0,006	0,576	47,8%
73	CSIPL_Med	0,006	0,571	47,4%
74	CI_Med	0,006	0,571	47,4%
75	SCIGREEN_Max	0,006	0,570	47,3%
76	VB3_Med	0,006	0,570	47,3%

Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO2 equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continuação)

77	SGCC_Min	0,006	0,569	47,3%
78	SMCARI_Med	0,006	0,569	47,2%
79	SGCC_Max	0,006	0,568	47,2%
80	SB8_Max	0,006	0,565	46,9%
81	SMVI_Med	0,006	0,559	46,4%
82	SSIPI_Max	0,006	0,556	46,2%
83	SCVI_Max	0,005	0,548	45,5%
84	SI_Min	0,005	0,548	45,5%
85	CNDWI_Med	0,005	0,546	45,3%
86	CSAVI_Max	0,005	0,545	45,2%
87	SNORMNIR_Max	0,005	0,541	44,9%
88	VGLI_Max	0,005	0,540	44,8%
89	CSIPI_Max	0,005	0,540	44,8%
90	VGCC_Med	0,005	0,537	44,6%
91	CGLI_Min	0,005	0,536	44,5%
92	SNCPI_Max	0,005	0,535	44,4%
93	SEXG_Med	0,005	0,532	44,2%
94	SGLI_Max	0,005	0,531	44,1%
95	VB3_Max	0,005	0,529	43,9%
96	VNCPI_Med	0,005	0,528	43,8%
97	SNDVI_Med	0,005	0,521	43,3%
98	SMVI_Max	0,005	0,518	43,0%
99	VGCC_Max	0,005	0,515	42,8%
100	CGLI_Max	0,005	0,515	42,7%
101	SNDWI_Max	0,005	0,514	42,7%
102	CNORMRED_Max	0,005	0,512	42,5%
103	CGCC_Min	0,005	0,509	42,2%
104	CNDVI_Med	0,005	0,503	41,8%
105	VB2_Med	0,005	0,502	41,7%
106	SNDVI_Max	0,005	0,501	41,6%
107	CRS_Max	0,005	0,500	41,5%
108	SB4_Max	0,005	0,498	41,3%
109	SGLI_Min	0,005	0,495	41,1%
110	VRGBVI_Min	0,005	0,494	41,0%
111	CSR_Med	0,005	0,487	40,4%
112	CEXG_Min	0,005	0,485	40,3%
113	VRGBVI_Med	0,005	0,485	40,2%
114	SNDVI_Min	0,005	0,484	40,1%
115	SB5_Med	0,005	0,483	40,0%
116	CCIGREEN_Min	0,005	0,482	40,0%
117	CCIGREEN_Med	0,005	0,480	39,8%

Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO2 equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

(continuação)				
118	CMPRI_Med	0,005	0,479	39,8%
119	SMCARI_Max	0,005	0,479	39,7%
120	CCVI_Min	0,005	0,478	39,6%
121	SMPRI_Med	0,005	0,476	39,5%
122	VB1_Med	0,005	0,472	39,1%
123	VI_Med	0,005	0,471	39,1%
124	VGLI_Min	0,005	0,465	38,6%
125	CIO_Med	0,005	0,464	38,5%
126	VI_Min	0,005	0,451	37,4%
127	SNORMNIR_Min	0,004	0,449	37,2%
128	SNDRE_Max	0,004	0,447	37,1%
129	SCIGREEN_Min	0,004	0,444	36,9%
130	CCVI_Max	0,004	0,443	36,8%
131	CB3_Max	0,004	0,443	36,8%
132	CB4_Med	0,004	0,442	36,7%
133	CNORMNIR_Med	0,004	0,440	36,6%
134	CB3_Med	0,004	0,440	36,5%
135	CSIPI_Min	0,004	0,438	36,3%
136	SGCC_Med	0,004	0,438	36,3%
137	CGDVI_Med	0,004	0,437	36,3%
138	CNDVI_Min	0,004	0,435	36,1%
139	SRGBVI_Med	0,004	0,431	35,8%
140	SB5_Max	0,004	0,426	35,3%
141	CB4_Min	0,004	0,423	35,1%
142	CGCC_Max	0,004	0,422	35,0%
143	CNORMNIR_Max	0,004	0,422	35,0%
144	SGDVI_Med	0,004	0,414	34,4%
145	SB4_Min	0,004	0,412	34,2%
146	SB8_Min	0,004	0,411	34,1%
147	CNORMNIR_Min	0,004	0,407	33,8%
148	CGDVI_Min	0,004	0,405	33,6%
149	SB8_Med	0,004	0,404	33,5%
150	SB5_Min	0,004	0,404	33,5%
151	CEXG_Max	0,004	0,402	33,3%
152	VGCC_Min	0,004	0,401	33,3%
153	CMPRI_Min	0,004	0,401	33,2%
154	CSAVI_Min	0,004	0,400	33,2%
155	SNORMRED_Min	0,004	0,397	32,9%
156	STCARI_Max	0,004	0,395	32,8%
157	SSAVI_Max	0,004	0,393	32,6%
158	VIO_Min	0,004	0,389	32,3%
159	CNCPI_Max	0,004	0,387	32,1%

Tabela 10 - Importância das variáveis de entrada no modelo completo para estimar CO2 equivalente por rede neural artificial em sistema agroflorestal silvibananeiro, Morrinhos do Sul, Litoral Norte do Rio Grande do Sul, Brasil – 2023.

				(conclusão)
160	VB2_Max	0,004	0,387	32,1%
161	SGDVI_Max	0,004	0,385	31,9%
162	CRGBVI_Max	0,004	0,380	31,6%
163	SSIPI_Min	0,004	0,380	31,5%
164	SNORMRED_Med	0,004	0,372	30,9%
165	VB1_Min	0,004	0,370	30,7%
166	SRGBVI_Max	0,004	0,370	30,7%
167	CGDVI_Max	0,004	0,367	30,4%
168	CRGBVI_Min	0,004	0,359	29,8%
169	CB2_Min	0,004	0,350	29,1%
170	GDVI_Min	0,003	0,347	28,8%
171	VB2_Min	0,003	0,338	28,0%
172	CB2_Med	0,003	0,336	27,8%
173	SEXG_Max	0,003	0,326	27,1%
174	SSAVI_Min	0,003	0,325	27,0%
175	VB1_Max	0,003	0,310	25,8%
176	SSR_Max	0,003	0,305	25,3%
177	VMPRI_Min	0,003	0,273	22,6%
178	VMPRI_Max	0,003	0,271	22,5%
179	CSAVI_Med	0,003	0,271	22,5%
180	VNCPI_Min	0,003	0,252	20,9%

Fonte: Autor (2023).