

RODRIGO HEMERSON LIMA E SILVA

MONITORAMENTO DO EFLUXO DE CO₂, UMIDADE E TEMPERATURA EM SOLOS
DE AGROECOSSISTEMAS NO SEMIÁRIDO COM AUXÍLIO DE VEÍCULO AÉREO
NÃO TRIPULADO

Serra Talhada-PE

2025

S
I
L
V
A

R
H
L

M
O
N
I
T
O
R
A
M
E
N
T
O

E
F
L
U
X
O

D
E

C

.
. .
2
0
2
5

RODRIGO HEMERSON LIMA E SILVA

MONITORAMENTO DO EFLUXO DE CO₂, UMIDADE E TEMPERATURA EM SOLOS
DE AGROECOSSISTEMAS NO SEMIÁRIDO COM AUXÍLIO DE VEÍCULO AÉREO
NÃO TRIPULADO

Dissertação apresentada à Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, como parte das exigências do Programa de Pós-Graduação em Produção Vegetal, para obtenção do título de Mestre em Produção Vegetal.

Orientador: Prof. Dr. Eduardo Soares de Souza
Co-orientador: Alan Cezar Bezerra

Serra Talhada-PE

2025

FICHA CATALOGRÁFICA

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário(a): Auxiliadora Cunha – CRB-4 1134

S586m Silva, Rodrigo Hemerson Lima e.
Monitoramento do efluxo de CO₂, umidade e temperatura em solos de agroecossistemas no semiárido com auxílio de veículo aéreo não tripulado / Rodrigo Hemerson Lima e Silva. – Serra Talhada, 2025.

53 f.; il.

Orientador(a): Eduardo Soares de Souza.

Co-orientador(a): Alan Cezar Bezerra.

Dissertação (Mestrado) – Universidade Federal Rural de Pernambuco, Unidade Acadêmica Serra Talhada - UAST, Programa de Pós-Graduação em Produção Vegetal , Serra Talhada, BR-PE, 2025.

Inclui referências.

1. Ar do solo - Regiões áridas . 2. Fotografia aérea em levantamentos do solo - Regiões áridas . 3. Aprendizado computacional. 4. Solos - Temperatura - Regiões áridas I. Souza, Eduardo Soares de, orient. II. Bezerra, Alan Cezar, coorient. III. Título

CDD 581.15

RODRIGO HEMERSON LIMA E SILVA

MONITORAMENTO DO EFLUXO DE CO₂, UMIDADE E TEMPERATURA EM SOLOS
DE AGROECOSSISTEMAS NO SEMIÁRIDO COM AUXÍLIO DE VEÍCULO AÉREO
NÃO TRIPULADO

Dissertação apresentada à Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, como parte das exigências do Programa de Pós-Graduação em Produção Vegetal, para obtenção do título de Mestre em Produção Vegetal.

APROVADO em 26 / 02 / 2025.

Banca Examinadora

Documento assinado digitalmente
 **EDUARDO SOARES DE SOUZA**
Data: 28/02/2025 09:32:32-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Eduardo Soares de Souza – UAST/UFRPE
Presidente da banca - Orientador

Documento assinado digitalmente
 **ALDO TORRES SALES**
Data: 28/02/2025 11:41:25-0300
Verifique em <https://validar.iti.gov.br>

Dr. Aldo Torres Sales – DEN/UFPE
Examinador Externo

Documento assinado digitalmente
 **ELISIANE ALBA**
Data: 28/02/2025 19:27:33-0300
Verifique em <https://validar.iti.gov.br>

Dra. Elisiane Alba – UAST/UFRPE
Examinador Externo ao programa

Ao meu pai, Edivaldo Benedito da Silva e minha mãe, Maria Aurení de Lima Silva, que nunca mediram esforços para me dar a melhor educação possível e por eles eu dedico a minha vida integralmente. Aos meus irmãos, Guilherme Heverton e Lara Rosa, que em todos os momentos estiveram comigo, compartilhando a vida e tornando-a boa de ser vivida. Às minhas irmãs de pós-graduação, Bianca Porfírio, Jheiny Carvalho e Nerissa Cumbana, que diariamente me ajudaram a suportar o processo e com um simples abraço em grupo me davam toda energia necessária pra seguir em frente. À todos aqueles que já se sentiram incapazes algum dia, mas que ainda assim não deixaram de tentar, com todo amor.

Dedico

AGRADECIMENTOS

A Deus, que em sua infinita graça me fez chegar até aqui e sempre será a minha motivação para seguir em frente, especialmente nos dias mais difíceis.

A toda minha família, em nome dos meus pais, Maria Aurení de Lima Silva e Edivaldo Benedito da Silva, que sempre me encheram de amor e foram meu refúgio seguro sempre que precisei desviar das minhas maiores preocupações.

A todos os meus amigos, em especial àqueles que o mestrado me presenteou, que tantas vezes me fizeram gargalhar, dividir as preocupações e me ajudaram durante todo esse processo.

A toda equipe de docentes, técnicos e pesquisadores, em nome do Dr. José Ralison Inácio Silva e do Dr. Denizard Oresca, que fizeram parte desse trabalho e foram força motora essencial para que essa pesquisa pudesse ser realizada.

Ao meu comitê de orientação, Prof. Dr. Eduardo Soares de Souza, Prof. Dr. Alan Cezar Bezerra e Prof.^a Dra. Elisiane Alba, que incansavelmente me orientaram e foram essenciais para o meu amadurecimento como pesquisador.

À Universidade Federal Rural de Pernambuco – Unidade Acadêmica de Serra Talhada, em especial ao Programa de Pós-Graduação em Produção Vegetal, que forneceu a infraestrutura necessária para a execução deste mestrado acadêmico.

Com todo amor, agradeço.

Algo só é impossível até que alguém duvide e acabe provando o contrário.

(Albert Einstein)

RESUMO

Apesar dos benefícios ambientais dos sistemas agroflorestais, a quantificação da dinâmica espaço-temporal do carbono e da água em solos recém-implantados no semiárido é limitada pela escassez de estudos e pela complexidade imposta pela variabilidade edáfica, sazonalidade hídrica e interações ecológicas, que desafiam a padronização metodológica. A coleta contínua de dados e o sensoriamento remoto, incluindo VANTs, permitem a quantificação do efluxo de CO₂ do solo (R_s), umidade (θ) e temperatura (T_s) do solo, apoiando práticas de manejo sustentável com estimativas precisas. Este estudo objetiva investigar a dinâmica espaço-temporal de R_s, θ e T_s em solos sob diferentes usos do solo (Caatinga, pastagem e sistema agroflorestal). A coleta de dados foi realizada em parcelas de solos do semiárido, com monitoramento *in situ* (IRGA - Infrared gas analyser) e uso de veículos aéreos não tripulados (VANTs) equipado com sensor RGN (Bandas Espectrais Red, Green e Near Infrared) para mapear uma área (≈ 0,4 ha) de SAF dividida em SAF1 (parte alta) e SAF2 (parte baixa). O experimento, conduzido por 11 meses, mediu variações sazonais e espaciais do efluxo de CO₂ do solo (R_s), umidade (θ), temperatura (T_s) e indicadores físico-hídricos em solos do semiárido. Realizou-se uma leitura por mês com o IRGA, enquanto o VANT coletou imagens apenas em dois momentos. Os resultados mostraram que o efluxo de CO₂ variou significativamente entre os sistemas, com valores médios de 1,0 a 4,3 μmol m⁻² s⁻¹, sendo o sistema agroflorestal SAF2 o maior emissor. A umidade apresentou uma relação inversa com a temperatura, mantendo padrões sazonais estáveis. As propriedades físico-hídricas do solo mostraram estabilidade à variação temporal. Modelos preditivos desenvolvidos a partir de imagens de alta resolução espacial apresentaram alta precisão (R² > 0,70), com destaque para respiração do solo, a qual se destacou com mais eficiência em função do modelo. Conclui-se que o monitoramento com o IRGA ao longo de 11 meses, conseguiu caracterizar o comportamento de uma agrofloresta recém implantada, além disso, o uso integrado de monitoramento *in situ* com o sensoriamento remoto é eficaz para compreender a dinâmica espaço-temporal de emissões de CO₂, umidade e temperatura do solo. Este estudo destaca o potencial de sistemas agroflorestais na mitigação de gases do efeito estufa (GEE) e a importância de práticas de manejo sustentável baseadas em dados precisos.

Palavras-chave: respiração do solo, VANTs, aprendizado de máquina, agrofloresta, semiárido, IRGA.

ABSTRACT

Despite the environmental benefits of agroforestry systems, the quantification of the spatiotemporal dynamics of carbon and water in newly established soils in the semiarid region is limited by the scarcity of studies and the complexity imposed by soil variability, water seasonality, and ecological interactions, which challenge methodological standardization. Continuous data collection and remote sensing, including UAVs, allow the quantification of soil CO₂ efflux (R_s), soil moisture (θ), and soil temperature (T_s), supporting sustainable management practices with accurate estimates. This study investigates the spatiotemporal dynamics of R_s , θ , and T_s in soils under different land uses (Caatinga, pasture, and agroforestry system). Data collection was carried out in semiarid soil plots, with in situ monitoring (IRGA - Infrared gas analyzer) and the use of unmanned aerial vehicles (UAVs) equipped with RGN sensors (Red, Green, and Near Infrared Spectral Bands) to map an area (≈ 0.4 ha) of SAF divided into SAF1 (upper part) and SAF2 (lower part). The experiment, conducted for 11 months, measured seasonal and spatial variations of soil CO₂ efflux (R_s), moisture (θ), temperature (T_s), and physical-hydric indicators in semiarid soils. One reading was taken monthly with the IRGA, while the UAV collected images only in two moments. The results showed that CO₂ efflux varied significantly among the systems, with average values ranging from 1.0 to 4.3 $\mu\text{mol m}^{-2} \text{s}^{-1}$, with the SAF2 agroforestry system being the largest emitter. Moisture showed an inverse relationship with temperature, maintaining stable seasonal patterns. The soil's physical-hydric properties showed stability to temporal variation. Predictive models developed from high spatial resolution images showed high accuracy ($R^2 > 0.70$), emphasizing soil respiration, which was more efficient due to the model. It is concluded that monitoring with IRGA over 11 months characterized the behavior of a newly implemented agroforestry. In addition, the integrated use of in situ monitoring with remote sensing effectively understands the spatiotemporal dynamics of CO₂ emissions, soil moisture, and temperature. This study highlights the potential of agroforestry systems in mitigating greenhouse gases (GHG) and the importance of sustainable management practices based on accurate data.

Keywords: soil respiration, UAVs, machine learning, agroforestry, semi-arid, IRGA.

LISTA DE FIGURAS

Figura 1. Comportamento da pluviosidade durante o ano experimental, consoante a normal climatológica regional (1992 – 2022).19

Figura 2. Localização do Sítio Brabo, em Custódia-PE, destacando as áreas experimentais de pastagem (PA), sistema agroflorestal (SAF1 e SAF2) e Caatinga (CA).20

Figura 3 Médias e intervalos de confiança, IC (baseado no erro padrão e na distribuição t de Student) da respiração (R_s , $\mu\text{mol m}^{-2}\text{s}^{-1}$) (A e B), umidade (θ , $\text{m}^3 \text{m}^{-3}$) (C e D) e temperatura do solo (T_s , $^{\circ}\text{C}$) (E e F), calculados por método não paramétrico de bootstrap para os diferentes sistemas de uso do solo (CA – Caatinga, PA – Pastagem, SAF1 e SAF2 – Sistemas agroflorestais). Variação mensal (dezembro de 2023 a outubro de 2024) e por períodos (seco:chuvoso, chuvoso, chuvoso:seco e seco).29

Figura 4. Médias e intervalos de confiança, IC (baseado no erro padrão e na distribuição t de Student) dos parâmetros de referência e seus limites críticos (Reynolds et al., 2007, 2009), calculados por método não paramétrico de bootstrap para os diferentes sistemas de uso da terra (CA – Caatinga, PA – Pastagem, SAF1 – Agrofloresta parte alta, SAF2 – Agrofloresta parte baixa), durante os períodos chuvoso e seco. Onde: P_{mac} - Macroporosidade ($\text{m}^3 \text{m}^{-3}$) – A, CA_e - Capacidade de aeração ($\text{m}^3 \text{m}^{-3}$) – B, $CADP$ - Capacidade de água disponível (m^3m^{-3}) – C, CCR - Capacidade de campo relativa (adimensional) – D, K_s - Condutividade hidráulica (mm h^{-1}) – E e D_s – densidade do solo (g cm^{-3}) – F.32

Figura 5. Representação gráfica dos testes de Tukey ($p < 0,05$) para dados paramétricos e de Dunn para dados não paramétricos, comparando os diferentes sistemas de uso da terra (CA – Caatinga, PA – Pastagem, SAF1 – Agrofloresta parte alta, SAF2 – Agrofloresta parte baixa) nos períodos chuvoso e seco. Os parâmetros analisados incluem: θ_0 - Umidade inicial ($\text{m}^3 \text{m}^{-3}$) – A, ϕ_t - Porosidade total ($\text{m}^3 \text{m}^{-3}$) – B, e S - Sorvidade ($\text{cm s}^{-1/2}$) – C, no município de Custódia-PE.34

Figura 6. Ortomosaico da área de estudo (agrofloresta parte alta e baixa), gerado a partir da coleta de imagens pelo sensor RGN. Onde A) janeiro e B) junho, Custódia-PE.35

Figura 7. Matriz de correlação de Pearson entre os parâmetros coletados no solo (R_s – Respiração do solo ($\mu\text{mol m}^{-2}\text{s}^{-1}$), θ – Umidade do solo (m^3m^{-3}) e T_s – Temperatura do solo ($^{\circ}\text{C}$)), e reflectância das bandas espectrais (Red – Banda Vermelho, Green – Banda Verde e NIR – Banda Infravermelho Próximo) e índices de vegetação (NDVI, EVI, SAVI e GNDVI) obtidos pelo valor médio dos pixels na imagem selecionados no interior do tubo de coleta dos dados in situ. Custódia-PE.36

Figura 8. Representação gráfica do modelo de predição e resíduo, respectivamente, obtido para cada parâmetro mensurado no solo (R_s – Respiração do solo ($\mu\text{mol m}^{-2}\text{s}^{-1}$) - A e B, θ_s – Umidade do solo ($\text{m}^3 \text{m}^{-3}$) - C e D e T_s – Temperatura do solo ($^{\circ}\text{C}$) - E e F).38

Figura 9 Comportamento dos valores de Respiração do solo (R_s , $\mu\text{mol m}^{-2} \text{s}^{-1}$) - (A), Umidade do solo (θ , m^3m^3) - (B) e Temperatura do solo (T_s , $^{\circ}\text{C}$) - (C), mensuradas em campo com o IRGA e preditas pelo modelo.39

Figura 10. Mapas de espacialização das variáveis preditas pelo modelo obtido para o sistema agroflorestal. A e B - Respiração do solo (R_s , $\mu\text{mol m}^{-2} \text{s}^{-1}$), C e D - umidade do solo (θ , m^3m^3) e E e F - temperatura do solo (T_s , $^{\circ}\text{C}$), para os meses de janeiro e junho respectivamente.40

LISTA DE TABELAS

Tabela 1. Análise textural e carbono orgânico do solo (COS) da superfície (0 - 20cm) dos solos sítios experimentais.21

Tabela 2. Indicadores de qualidade físico-hídrica do solo (IQFHS) e seus níveis críticos: Macroporosidade (P_{mac}), capacidade de aeração (CA_{er}), capacidade de água disponível para as Plantas (CADP), capacidade de campo relativa (CCR), condutividade hidráulica saturada.25

Tabela 3. Índices de vegetação empregados no sistema agroflorestal.27

Tabela 4. Valores médios e desvio padrão dos parâmetros das curvas de retenção, $\theta(h)$, e condutividade hidráulica, $K(\theta)$, dos solos das áreas de Caatinga (CA), pastagem (PA) e sistemas agroflorestais (SAF1 e SFA2), obtidos com a metodologia Beerkan (BEST-steady).31

Tabela 5. Erro quadrático médio (RMSE), coeficiente de determinação (R^2) e erro médio absoluto (MAE) após a validação cruzada para a respiração do solo (R_s), umidade do solo (θ) e temperatura do solo (T_s) em relação às bandas espectrais e índices de vegetação.37

Tabela 6 Distribuição do quantitativo espacial para cada classe das variáveis preditas pelo modelo, na agrofloresta, para os meses de janeiro e junho de 2023.41

SUMÁRIO

| | |
|--|----|
| 1 INTRODUÇÃO | 13 |
| 2 REVISÃO DE LITERATURA | 16 |
| 2.1 SISTEMAS AGROFLORESTAIS COMO ALTERNATIVA SUSTENTÁVEL | 16 |
| 2.2 DOMÍNIO CAATINGA..... | 16 |
| 2.3 FERRAMENTAS PARA O MONITORAMENTO AMBIENTAL: VANT E APRENDIZADO DE MÁQUINA | 17 |
| 3 MATERIAL E MÉTODOS | 18 |
| 3.1. ÁREA DE ESTUDO | 18 |
| 3.2 DEFINIÇÃO E DISTRIBUIÇÃO DOS SÍTIOS EXPERIMENTAIS | 21 |
| 3.4. QUALIDADE FÍSICO-HÍDRICA DOS SOLOS | 23 |
| 3.5 COLETA E PROCESSAMENTO DE DADOS ESPECTRAIS | 26 |
| 3.6 ANÁLISE ESTATÍSTICA..... | 27 |
| 4 RESULTADOS | 28 |
| 4.1 EFLUXO DE CO ₂ , UMIDADE E TEMPERATURA DO SOLO | 28 |
| 4.2 QUALIDADE FÍSICO-HÍDRICA DOS SOLOS | 30 |
| 4.3 MODELOS PREDITIVOS PARA AS VARIÁVEIS DE SOLO | 34 |
| 5 DISCUSSÃO | 41 |
| 5.1 EFLUXO DE CO ₂ , UMIDADE E TEMPERATURA DO SOLO | 42 |
| 5.2 QUALIDADE FÍSICO-HÍDRICA DO SOLO..... | 43 |
| 5.3 MODELOS PREDITIVOS PARA AS VARIÁVEIS DE SOLO | 44 |
| 6 CONCLUSÕES | 46 |

1 INTRODUÇÃO

Os sistemas agroflorestais são amplamente reconhecidos por sua capacidade de enriquecer a paisagem, conferindo-lhe um aspecto mais natural e valorizando culturalmente o ambiente (Heimsch *et al.*, 2023). Esses sistemas permitem a manutenção das espécies florestais já estabelecidas, que podem ser integradas ao agroecossistema, influenciando diretamente a escolha de novas espécies a serem adicionadas, com foco na compatibilidade e nas simbioses entre elas para evitar impactos negativos no desenvolvimento mútuo (Carvalho *et al.*, 2023). As espécies vegetais adotadas nesses sistemas devem ser adaptadas às condições climáticas e nas questões culturais locais, fator essencial para garantir a disponibilidade sazonal de alimentos para as famílias e para os rebanhos, especialmente na estação seca, característica que fazes destes modelos de produção o mais marcante das regiões áridas e semiáridas (Santos *et al.*, 2017). Geralmente, sua adoção dispensa a necessidade de práticas de manejo agrícola mais intensivo, uma vez que o policultivo proporciona a interação entre as plantas e a provisão de serviços ecossistêmicos (Carvalho *et al.*, 2023).

Os agroecossistemas desempenham um papel significativo nas emissões globais de Gases de Efeito Estufa (GEE), liberando uma quantidade considerável desses gases para a atmosfera (Heimsch *et al.*, 2023). Estima-se que o dióxido de carbono (CO₂) gerado pelas atividades antrópicas nesses sistemas contribua com aproximadamente 22% do total de emissões de GEE, o que equivale a 13 gigatoneladas de CO₂ por ano, sendo que a agricultura e a silvicultura são os principais responsáveis por essa fração (Sukhoveeva *et al.*, 2023). Embora os sistemas agroflorestais, compostos por uma vasta diversidade biológica, sejam fontes expressivas de emissões de carbono, incluindo o efluxo de CO₂ do solo, eles também desempenham um papel crucial no equilíbrio ambiental global. Estudos indicam que esses sistemas possuem uma significativa capacidade de sequestro de carbono, fornecendo um importante serviço ecossistêmico ao atuar como reservatórios de carbono (Carvalho *et al.*, 2023).

O efluxo de CO₂ do solo é difícil de estimar devido à alta variabilidade espacial e temporal que o caracteriza, a qual pode ser mais evidente em áreas semiáridas. Características da superfície do solo, como a presença de fragmentos de rocha, moldes de minhocas e crostas biológicas, exibem padrões espaciais complexos que impactam na dinâmica do CO₂ do solo em ecossistemas semiáridos (Maestre e Cortina, 2003). A distribuição irregular da vegetação, das chuvas e a heterogeneidade das características do solo pode aumentar a variação espacial

e temporal do efluxo de CO₂ do solo em ecossistemas e agroecossistemas semiáridos. No entanto, os efeitos da variação espacial, tanto do sistema agroflorestal quanto das características do solo, no efluxo de CO₂ do solo em regiões semiáridas ainda são pouco conhecidos, muito menos ainda nos solos da Caatinga.

As práticas, como o corte insustentável (não tecnificado) da vegetação para a produção de lenha, o desenvolvimento agrícola e a pecuária extensiva, têm sido identificados como alguns dos principais distúrbios antrópicos responsáveis pela degradação dos ecossistemas (Araújo Filho *et al.*, 2018; Ramos *et al.*, 2023). A remoção contínua de biomassa ecossistêmica tem provocado uma quebra sistêmica de inúmeros ciclos biogeoquímicos, levando a uma redução significativa da vegetação nativa, o empobrecimento dos solos, a intensificação do processo de desertificação e a desestabilização do ciclo de carbono (Costa Lourenço *et al.*, 2022).

As condições climáticas desempenham um papel importante na regulação das atividades ecológicas e agropecuárias. Nos últimos trinta anos, a frequência e a intensidade das secas aumentaram globalmente devido às mudanças climáticas, comprometendo a captação de água e alterando o uso da terra, resultando em secas ocasionais, recorrentes ou permanentes nos reservatórios (Marcé *et al.*, 2019; Pekel *et al.*, 2016). Esse aumento na frequência da seca e na intermitência hidrológica afeta profundamente os ecossistemas semiáridos, impactando os componentes biológicos, suas atividades e os processos biogeoquímicos e serviços ecossistêmicos fornecidos.

Nesse contexto, os sistemas agroflorestais, quando implementados com base nos princípios da agroecologia, demonstram grande potencial não apenas para a produção agrícola, mas também para a recuperação de áreas degradadas, promovendo melhorias na qualidade do solo e nas interações positivas entre os componentes do sistema (Altieri, 2002).

Embora os sistemas agroflorestais sejam amplamente reconhecidos por seus benefícios ambientais, segundo estudo realizado por Rulev e Pugacheva (2019), ainda existe uma base teórica insuficiente que represente o comportamento de sistemas agroflorestais desde o início da sua implementação, apresentando uma lacuna significativa no entendimento da dinâmica da água e do carbono nos solos desses agroecossistemas recém implantados. Além disso, outra dificuldade recorrente e que também foi encontrada por Oliveira *et al.* (2021), é a dificuldade em obter medições constantes e monitorar o efluxo de CO₂ em diferentes áreas do solo, decorrente a alta variabilidade espaço-temporal, sendo assim, estudos que monitoram detalhadamente a entrada e a saída de carbono, são escassos. Compreender essa dinâmica é

crucial para o desenvolvimento de práticas de manejo mais eficientes, o que exige o uso de tecnologias que permitam um monitoramento contínuo e preciso dessas variáveis.

A popularização dos veículos aéreos não tripulados (VANTs) tem ganhado destaque devido ao seu amplo potencial de aplicação, superando as limitações do sensoriamento remoto tradicional ao oferecer escalas mais refinadas e monitoramento contínuo (Arantes *et al.*, 2020). O uso dessas tecnologias no monitoramento agrícola tem sido cada vez mais explorado, como demonstrado em estudos que utilizaram VANTs equipados com sensores infravermelhos para prever a umidade do solo com base na temperatura do dossel da vegetação (Li *et al.*, 2022). A relevância deste estudo reside no fato de que, ao compreender a dinâmica do carbono e da umidade em sistemas agroflorestais com maior precisão, será possível propor práticas de manejo que aumentem tanto a eficiência produtiva quanto a ambiental. Espera-se que os resultados gerem benefícios econômicos ao otimizar o uso da terra e dos recursos hídricos, sociais ao contribuir para a segurança alimentar e ambientais ao mitigar as emissões de carbono e melhorar o sequestro de carbono.

A coleta contínua de dados sobre diferentes períodos de chuva e sistemas de uso da terra, aliada ao sensoriamento remoto suborbital, possibilitará uma compreensão detalhada do comportamento sazonal e espacial do fluxo de carbono. Espera-se que essa abordagem forneça estimativas rápidas e precisas, facilitando a tomada de decisões de manejo em agroecossistemas sustentáveis.

O objetivo geral desse trabalho foi avaliar a dinâmica espaço-temporal do efluxo de CO₂ (respiração), umidade e temperatura do solo sob a influência de diferentes sistemas de uso do solo em ambiente semiárido, além de realizar o monitoramento *in situ* associado ao sensoriamento remoto suborbital com veículos aéreos não tripulados (VANTs) em um sistema agroflorestal recém implementado. De forma específica, buscou-se caracterizar a dinâmica da respiração do solo (efluxo de CO₂), umidade e temperatura nas superfícies dos solos em três tipos de uso da terra: Caatinga, pastagem e sistema agroflorestal, durante os períodos chuvoso e seco do município de Custódia, semiárido pernambucano. Para estabelecer parâmetros de qualidade físico-hídrica dos solos desses sistemas de uso, aplicou-se a metodologia Beerkan ao longo dos períodos chuvoso e seco. Também procurou-se processar imagens e dados espectrais obtidos por veículo aéreo não tripulado (VANT-RGN) para analisar índices de vegetação em área de agrofloresta, correlacionando-os com medições de respiração, temperatura e umidade dos solos; e assim, elaborar, ajustar e validar um modelo de aprendizado de máquina para prever a respiração, temperatura e umidade do solo com base

em índices de vegetação resultantes das imagens de VANTs, aprimorando a representação da distribuição espacial e temporal dessas variáveis na agrofloresta.

2 REVISÃO DE LITERATURA

2.1 SISTEMAS AGROFLORESTAIS COMO ALTERNATIVA SUSTENTÁVEL

O impacto das florestas nas características ambientais do globo terrestre é imenso, como já mencionado nesse texto, uma das características mais marcantes é a sua capacidade em estocar carbono, influenciando diretamente no seu ciclo global (Chehreh et al. 2023). Os solos desses ecossistemas possuem alta capacidade de fixação de carbono em diferentes complexos orgânicos, havendo por tanto o estabelecimento de um equilíbrio em relação as emissões (Costa Lourenço *et al.*, 2022), tendo em vista que as emissões de CO₂ ocorrem em período integral diariamente, sendo a respiração do solo a principal via de transporte de carbono até a atmosfera, a qual vem se intensificando em decorrência das mudanças climáticas (Sukhoveeva *et al.*, 2023).

Estas características mencionadas se estendem até os agroecossistemas das agroflorestas, salientando-se que o serviço ecossistêmico mencionado sobre essa função de estocagem de carbono, é condicionada por alguns fatores importantes, como a climatologia local e a atividade microbológica de decomposição do material orgânico depositado sobre o solo proveniente da serrapilheira (Costa Lourenço *et al.*, 2022), desta forma a presença de umidade no ambiente torna-se um fator influenciador, ativando toda microbiota presente no solo.

2.2 DOMÍNIO CAATINGA

Distribuída ao longo da região do semiárida do Brasil, o domínio Caatinga possui uma extensa área florestal, que é quase equivalente a área do território francês (Araújo Filho *et al.*, 2018), sendo a maior representação de uma floresta sazonalmente seca do Novo Mundo (Ramos *et al.*, 2023), segundo Kiill (2021), o domínio caatinga é representado no Brasil pelos estados Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia e Minas Gerais.

Em determinada época do ano, sua vegetação perde as folhas, o que lhe acarreta a denominação de floresta caducifólia (Araújo Filho *et al.*, 2018), apresentando uma riqueza florística consideravelmente grande, com espécies endêmicas e distribuídas nas mais variáveis

características, determinadas especialmente pelas características ambientais da sua localização, como clima, geologia, relevo e particularidades edáficas (Ramos *et al.*, 2023).

2.3 FERRAMENTAS PARA O MONITORAMENTO AMBIENTAL: VANT E APRENDIZADO DE MÁQUINA

Segundo informações contidas na plataforma digital da EMBRAPA, o geoprocessamento é definido por um conjunto de ferramentas computacionais que possuem o objetivo de extrair informações geográficas e auxiliar tomadas de decisões ao cruzar informações provenientes de diversas fontes, as quais podem ser chamadas de SIGs (Sistemas de Informações Geográficas). O geoprocessamento aliado às técnicas do sensoriamento remoto, permite que seja realizado o estudo em diferentes escalas espaciais e temporais, com maior frequência sobre áreas extensas (Kupková *et al.*, 2023).

Partindo-se disso, surgem os Veículos Aéreos Não Tripulados (VANTs), os quais têm ganhado espaço na realização de vistorias aéreas controladas remotamente, obtendo resultados satisfatórios com os avanços na captura de imagens com sensores e câmeras modernos, com o auxílio de softwares de processamento de imagens (Farooque *et al.*, 2023), conseguindo desta forma realizar o monitoramento de grandes áreas de maneira relativamente mais barata, tendo em vista os altos custos para a aquisição de equipamentos de levantamento terrestre (Chehreh *et al.*, 2023).

Com os dados provenientes das imagens coletadas com o VANT, é possível realizar o aprendizado de máquina, um processo que consiste na alimentação de um sistema com dados que irão treinar um algoritmo para que este seja capaz de construir modelos analíticos, os quais se tornam melhores conforme aumenta a base de dados inseridas no seu sistema (Janiesch, Zschech e Heinrich, 2021). Aliado ao uso de VANTs, o aprendizado de máquina é uma eficiente ferramenta para realização do monitoramento ambiental e esse método tem sido utilizado frequentemente por pesquisadores, como em estudo realizado por Huang *et al.* (2025), conduzido na cidade de Lihu, China, onde buscou melhorar a precisão da classificação da vegetação e da observação de plantações a nível de bacia hidrográfica realizando voo com VANT e uso de aprendizado de máquina, obtendo um método de classificação eficiente e confiável.

Existem diversos modelos capazes de trabalhar com o aprendizado de máquina e a sua escolha irá depender das particularidades de cada objetivo associada às particularidades de cada modelo. Como por exemplo, em estudo realizado por Mouafik, Mounir e Aboudi (2025), no Marrocos, buscou avaliar o desempenho de vários modelos de aprendizado de máquina e

determinar qual conjunto de dados foi mais confiável para prever a cobertura e densidade da população florestal de Argania coletando imagens via satélite e VANT. Os modelos de aprendizado de máquina avaliados pelo estudo foram os algoritmos Extreme Gradient Boosting (XGBoost), Light Gradient Boosting Machine (LightGBM), Gradient Boosted Decision Trees (GBDT), Random Forest (RF) e Artificial Neural Networks (ANN), com destaque para o XGBoost e LightGBM que superaram significativamente os outros modelos avaliados.

Vale ressaltar que existe carência de estudos que busquem avaliar a eficiência de modelos preditivos de aprendizado de máquina sobre variáveis do solo como umidade, temperatura e especialmente o efluxo de CO₂ (respiração do solo).

3 MATERIAL E MÉTODOS

3.1. ÁREA DE ESTUDO

O experimento foi conduzido no Sítio Brabo, localizado na zona rural do Município de Custódia – PE, nordeste brasileiro, com clima regional descrito, segundo a classificação climática de Köppen, como BSh (Alvares *et al.*, 2013), com precipitação média anual de 540 mm, conforme a normal climatológica (1992 – 2022), apresentada na Figura 1, e em consonância ao comportamento pluviométrico registrado no ano experimental, de dezembro de 2023 a outubro de 2024.

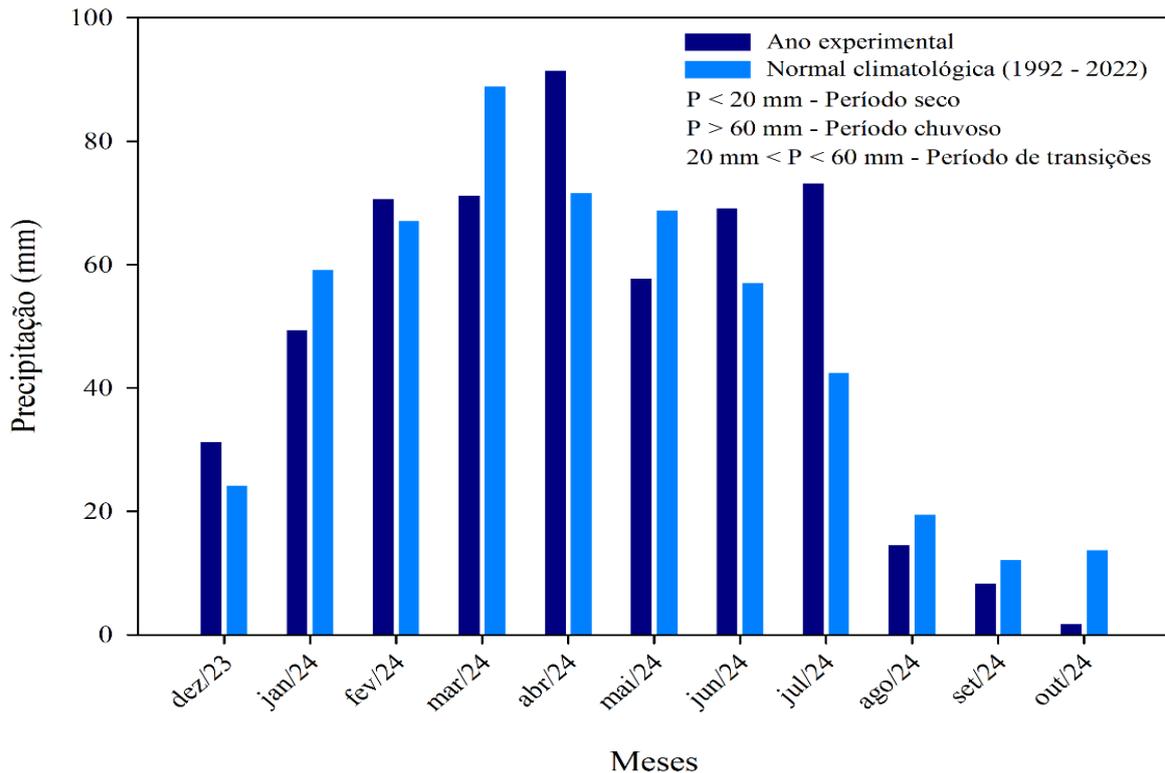


Figura 1. Comportamento da pluviosidade durante o ano experimental, consoante a normal climatológica regional (1992 – 2022). Fonte: Elaboração própria com base em dados da NASA POWER (2024)

O critério adotado para classificação dos períodos de chuvas e suas transições foi baseado na quantidade de chuva registrada mensalmente pela normal climatológica. Foi considerado como período seco os meses com precipitação acumulada mensal abaixo de 20 mm, abrangendo os meses de agosto a novembro, já os meses com precipitação entre 20 mm e 60 mm, foram definidos como período de transição entre uma estação e outra, sendo assim dezembro e janeiro foram classificados como transição seco:chuvoso, enquanto junho e julho a transição chuvoso:seco. Por fim, os meses com precipitação acima de 60 mm foram considerados como parte do período chuvoso, englobando os meses de fevereiro a março.

No local de estudo (Figura 2), foram estabelecidos três cenários dos usos do solo, definidos como Caatinga (CA – 8°03'29.5"S 37°31'08.8"W), pastagem (PA – 8°03'32.1"S 37°31'41.4"W) e um sistema agroflorestal recém implantado (SAF - 8°03'31"S 37°31'38"W). Este último, devido a declividade do terreno, foi dividido em SAF1 (parte mais alta do terreno) e SAF2 (parte mais baixa do terreno), com uma área total de aproximadamente 4000 m² (Figura 2). O sistema agroflorestal conta com as seguintes espécies de plantas nativas: Angico (*Anadenanthera macrocarpa* (Benth.) Brenan), mulungu (*Erythrina verna* Vell.), pau-ferro (*Libidibia ferrea* (Mart. ex Tul.) L.P. Queiroz), aroeira (*Schinus terebinthifolia* Raddi), caju

(*Anacardium occidentale* L.), e umbu (*Spondias tuberosa* Arruda). Além das exóticas: sabiá (*Mimosa caesalpinifolia* Benth.), acerola (*Malpighia emarginata* DC.).

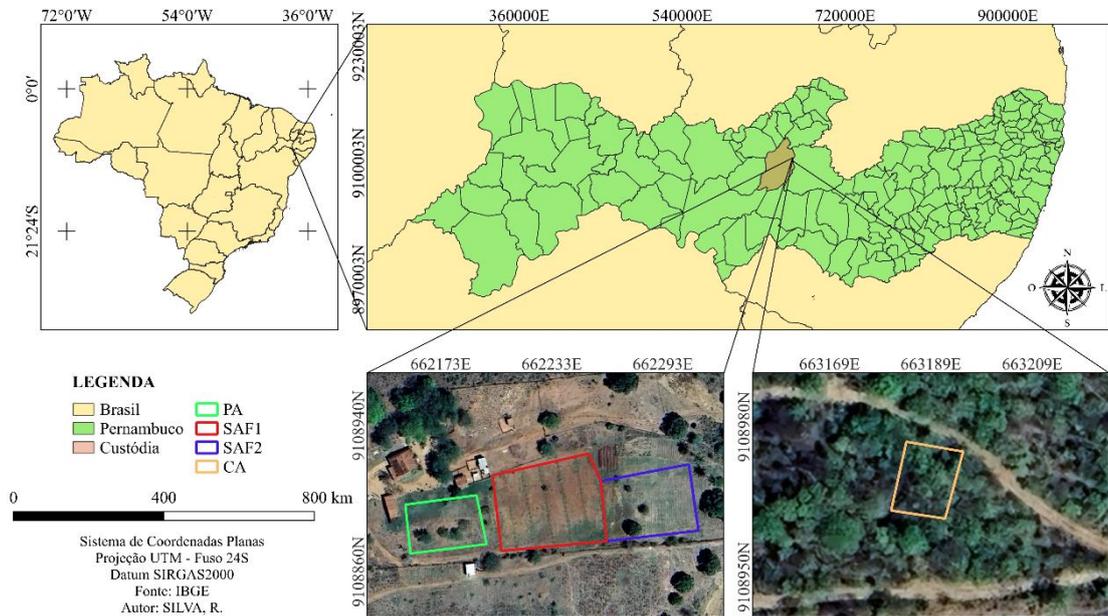


Figura 2. Localização do Sítio Brabo, em Custódia-PE, destacando as áreas experimentais de pastagem (PA), sistema agroflorestal (SAF1 e SAF2) e Caatinga (CA).

Os solos predominantes nas áreas de estudo são os Neossolos Litólicos, Luvisolos Crômicos e Cambissolos Eutróficos (Santos, 2018). As características texturais e os teores de carbono orgânico das diferentes áreas experimentais refletem bem as condições típicas desses solos (Tabela 1).

Tabela 1. Análise textural e carbono orgânico do solo (COS) da superfície (0 - 20cm) dos solos sítios experimentais.

| Uso do solo | Pontos | Areia | Silte | Argila | Classe textural | COS |
|-------------|--------|-------|-------|--------|-------------------------|----------|
| | | (%) | | | | (dag/kg) |
| CA | 1 | 74,67 | 16,79 | 8,54 | Franco arenoso | 1,13 |
| | 2 | 71,79 | 22,53 | 5,68 | Franco arenoso | 1,54 |
| | 3 | 73,57 | 17,66 | 8,76 | Franco arenoso | 1,44 |
| | 4 | 78,64 | 10,18 | 11,18 | Franco arenoso | 0,90 |
| PA | 1 | 80,64 | 5,46 | 13,90 | Franco arenoso | 1,39 |
| | 2 | 69,02 | 22,18 | 8,80 | Franco arenoso | 1,22 |
| | 3 | 71,15 | 13,20 | 15,65 | Franco arenoso | 1,09 |
| | 4 | 82,40 | 10,55 | 7,05 | Areia franca | 1,50 |
| SAF1 | 1 | 58,76 | 14,86 | 26,38 | Franco argiloso arenosa | 1,14 |
| | 2 | 64,62 | 15,23 | 20,15 | Franco argiloso arenosa | 0,98 |
| | 3 | 61,69 | 15,05 | 23,26 | Franco argiloso arenosa | 1,01 |
| | 4 | 74,58 | 14,05 | 11,37 | Franco arenoso | 0,89 |
| SAF2 | 1 | 73,94 | 13,72 | 12,35 | Franco arenoso | 1,02 |
| | 2 | 83,70 | 10,50 | 5,80 | Areia franca | 0,48 |
| | 3 | 88,09 | 7,15 | 4,75 | Areia | 0,54 |
| | 4 | 92,49 | 3,81 | 3,71 | Areia | 0,48 |

Caatinga (CA), Pastagem (PA) e Sistemas Agroflorestais (SAF1-parte alta e SAF2-parte baixa).

Dentre os sistemas de uso do solo, as porcentagens médias de areia, silte e argila variaram de 58,76 a 92,49%, 3,81 a 22,53% e 3,71 a 26,38%, respectivamente. Os coeficientes de variação variaram de 3,89 a 10,59% para a fração arenosa, de 3,52 a 48,56% para a fração silte e de 26,36 a 58,52% para a fração argila. Conforme apresentado na Tabela 1, do total de 16 amostras de solo analisadas, 13 foram classificadas como franco-arenosa, 3 como areia-franca, 3 como franco-argilo-arenosa e 2 como areia. Quanto aos valores de carbono orgânico do solo das áreas estudadas, CA e PA apresentaram valores mais altos em relação ao SAF1 e SAF2. A similaridade nas texturas dos solos e do carbono orgânico é importante porque sugere que possíveis diferenças nas propriedades dos solos da Caatinga e as áreas de adjacentes de pastagem e agroflorestas, podem ser atribuídas com certo grau de confiança aos efeitos do uso da terra. O maior teor de argila foi constatado entre os solos da SAF1.

3.2 DEFINIÇÃO E DISTRIBUIÇÃO DOS SÍTIOS EXPERIMENTAIS

A condução experimental foi realizada a partir de sítios alocados de forma representativa dentro de cada área de estudo (CA, PA e SAF), os quais delimitaram os pontos

de amostragem e monitoramento do efluxo de CO₂, da umidade e da temperatura dos solos. Além disso, foram realizadas medições da infiltração e o levantamento de algumas propriedades físico-hídricas dos solos.

Nas áreas de Caatinga e pastagem, por possuírem tamanhos semelhantes, foram implementados 4 sítios (pontos de coleta) em cada uma delas, enquanto no sistema agroflorestal foram instalados 8 sítios, sendo quatro na parte mais alta (SAF1) e outros quatro na parte mais baixa (SAF2) do terreno. Todas as coletas de dados realizadas até o fim do experimento ocorreram nos 16 pontos distribuídos nos três diferentes cenários de uso da terra.

3.3 MEDIÇÕES DE EFLUXO DE CO₂, UMIDADE E TEMPERATURA DO SOLO

As coletas de dados de efluxo de CO₂, umidade e temperatura do solo seguiram metodologia já realizada por Oresca et al. (2024), somada algumas adaptações. As medições foram realizadas utilizando um Analisador de Gás Infravermelho (IRGA Câmara, modelo 82000-01S, e data logger, modelo LI-870, LI-COR®). Em cada ponto de coleta de dados, foi instalado um sítio para a acoplagem da câmara do IRGA e assim possibilitou obter informações referentes ao efluxo de CO₂ (respiração do solo), umidade e temperatura do solo. Para instalação desses sítios de observação, foi utilizado um anel de PVC de diâmetro adequado para o encaixe perfeito da câmara ao anel, isolando a interferência atmosférica.

Após os anéis de PVC serem fixados ao solo e permanecerem em repouso por 15 dias para estabilização dos agregados do solo e da atividade microbiana, foi realizada a padronização das dimensões do anel ao equipamento, e então efetuada a primeira coleta de dados. Foi estabelecido que, em cada ponto de coleta, o IRGA realizaria 3 repetições, com cada leitura tendo duração de 45 segundos. As medições foram feitas mensalmente, iniciando em dezembro de 2023 e seguindo até outubro de 2024, com exceção dos meses de julho e setembro devido a impedimentos logísticos, totalizando, assim, nove meses de dados coletados.

Para coletar informações sobre o efluxo de CO₂ o equipamento faz o fechamento da câmara inteligente acoplando-a ao anel de PVC no solo e faz a extração de todo o CO₂ presente na sua área interna e dá início à contabilização da variação no acúmulo de dióxido de carbono proveniente da respiração das raízes (respiração autotrófica) e microrganismos (respiração heterotrófica), desta forma, o fluxo de gases é apresentado em uma unidade de concentração molecular, por unidade de área e por unidade de tempo (R_s , $\mu\text{mol m}^{-2} \text{s}^{-1}$). Para coleta dos dados de conteúdo volumétrico de água (θ , $\text{m}^3 \text{m}^{-3}$) e temperatura (T_s , °C) do solo,

conforme o funcionamento da câmara, se encontra fixa ao solo a sonda HydraProbe (LICOR®) e essa realiza tais leituras, respectivamente.

3.4. QUALIDADE FÍSICO-HÍDRICA DOS SOLOS

Avaliações das propriedades físico-hídricas do solo foram realizadas em duas estações distintas (seca e chuvosa) por meio de ensaios de infiltração com um infiltrômetro de anel simples. Um cilindro de 15 cm de diâmetro interno foi inserido no solo a aproximadamente 10 mm de profundidade para minimizar perdas laterais de água durante o teste (Lassabatère *et al.*, 2006). No período seco, as medições foram realizadas em 16 pontos, cobrindo todas as áreas designadas, em 14 de dezembro de 2023 e o mesmo para o período chuvoso, o qual ocorreu em 12 de junho de 2024. Durante cada avaliação sazonal, foram coletadas amostras de solo indeformado, permitindo determinar a densidade do solo (D_s) e amostras deformadas para a umidade inicial (θ_0) e final (θ_s) do solo, adotando-se θ_s igual à porosidade total. O método de Beerkan foi utilizado para a caracterização físico-hídrica dos solos (Lassabatère *et al.*, 2006). Tal método estima simultaneamente os parâmetros de retenção de água (Genuchten, van, 1980) e a condutividade hidráulica do solo (Brooks e Corey, 1964), seguindo a condição de Burdine (Burdine, 1953), onde:

$$\theta(h) = \left(\frac{\theta - \theta_r}{\theta_s - \theta_r} \right) = \left[1 + \left(\frac{h}{h_g} \right)^n \right]^{-m} \quad \text{com} \quad m = 1 - \frac{2}{n} \quad (1)$$

$$K(\theta) = K_s \left(\frac{\theta - \theta_r}{\theta_s - \theta_r} \right)^\eta \quad \text{com} \quad \eta = \frac{2}{mn} + 2 + p \quad (2)$$

onde θ é o conteúdo volumétrico de água do solo [$L^3 L^{-3}$]; θ_r e θ_s o conteúdo volumétrico de água do solo residual e saturado [$L^3 L^{-3}$], respectivamente; h é o potencial matricial da água do solo [L]; h_g [L] é um valor de escala de h ; n , m e η são parâmetros de forma; p é o parâmetro de tortuosidade definido como igual a 1 (Burdine, 1953) e K_s é a condutividade hidráulica saturada do solo [$L T^{-1}$]. O valor de θ_r é assumido como zero. θ_s foi medido a partir de amostras de solo coletadas no final do teste de infiltração. As propriedades hidráulicas foram, portanto, representadas usando cinco parâmetros: θ_s , n , h_g , K_s e η . Os parâmetros de forma n e η dependem da textura do solo, enquanto θ_s , h_g e K_s dependem da estrutura do solo (Haverkamp *et al.*, 1994).

Para caracterizar os parâmetros dos solos (n , η , θ_s , K_s e h_g) que descrevem as curvas de retenção, $\theta(h)$ (Eq. 1), e de condutividade hidráulica, $K(\theta)$ (Eq. 2), utilizou-se o programa BEST (*Beerkan Estimation of Soil Transfer Parameters through Infiltration Experiments*)

(Lassabatère *et al.*, 2006). Os detalhes sobre o método são apresentados em Souza *et al.* (2008).

O parâmetro de forma n foi estimado a partir da porcentagem de areia e argila, sendo calculado conforme Minasny e McBratney (2007). Conhecido o seu valor, obteve-se os parâmetros m (Eq. 1) e η (Eq. 2), conforme as hipóteses de (Burdine, 1953). Os parâmetros de escala, h_g e K_s são determinados pela análise de inversão da infiltração, usando a fórmula analítica definida por Haverkamp *et al.* (1994) para infiltração acumulada $I_{3D}(t)$ e taxa de infiltração $q(t)$, descritas para fluxos sobre regime transiente e estado estacionário, respectivamente (Lassabatère *et al.*, 2006). O BEST-steady foi escolhido com base no seu melhor desempenho conforme apresentado em diversos trabalhos na literatura (Bagarello *et al.* 2014; Castellini *et al.*, 2016).

Para a avaliação da qualidade físico-hídrica do solo, foram selecionados alguns indicadores da literatura, dos quais apenas cinco fornecem faixas ótimas ou limites críticos (Tabela 2). Os indicadores foram os seguintes: macroporosidade (P_{mac}), capacidade de aeração (CAer), capacidade de água disponível para as plantas (CADP), capacidade de campo relativa (CCR), tamanho médio dos poros ponderado pelo fluxo (λ_m), número de poros hidráulicamente ativos por unidade de área (C_{λ_m}), sorvidade (S), condutividade hidráulica saturada (K_s) e densidade do solo (D_s) (Canarache, 1990; Pieri, 1992; Reynolds *et al.*, 2007, 2009; Topp *et al.*, 1997). Estudos recentes (Agnese *et al.*, 2011; Bagarello *et al.*, 2011; Iovino *et al.*, 2016; Kelishadi *et al.*, 2014; Ozalp *et al.* 2016) destacaram a importância desses indicadores na avaliação da capacidade do solo em armazenar e fornecer ar e água às raízes, além de sua utilidade na detecção de possíveis processos de degradação (Castellini *et al.*, 2013).

Tabela 2. Indicadores de qualidade físico-hídrica do solo (IQFHS) e seus níveis críticos: Macroporosidade (P_{mac}), capacidade de aeração ($CAer$), capacidade de água disponível para as Plantas ($CADP$), capacidade de campo relativa (CCR), condutividade hidráulica saturada.

| IQFHS | Valores de referência |
|--|--|
| Estimados | |
| $P_{mac} (m^3 m^{-3}) = \theta_S - \theta_M$ | $P_{mac} \geq 0,07$ ótima; $0,04 \leq P_{mac} < 0,07$ intermediária; $P_{mac} < 0,04$ ruim |
| $CAer (m^3 m^{-3}) = \theta_S - \theta_{CC}$ | $CAe > 0,14$ ótima; $0,10 \leq CAer \leq 0,14$ intermediária; $CAer < 0,10$ ruim |
| $CADP (m^3 m^{-3}) = \theta_{CC} - \theta_{PMP}$ | $CADP \geq 0,20$ ótima; $0,15 \leq CADP < 0,20$ boa; $0,10 \leq CADP < 0,15$ limitada; $CADP < 0,10$ ruim |
| $CCR (-) = \theta_{FE} / \theta_S$ | $0,6 \leq CCR \leq 0,7$ ótima; $CCR < 0,6$ - limitação de água; $CCR > 0,7$ - aeração limitada |
| Medidos | |
| $K_s (mm h^{-1})$ # | $18 \leq K_s \leq 180$ - ótima; $3,6 < K_s \leq 18$ e $180 < K_s \leq 360$ - intermediária; $K_s > 360$ - limite crítico superior; $K_s < 3,6$ - limite crítico inferior |
| $D_s (g cm^{-3}) = M_{SS} / V_T$ | $0,9 \leq D_s \leq 1,2$ ótima; $0,85 \leq D_s < 0,9$ e $1,2 < D_s \leq 1,25$ - intermediária; $D_s > 1,25$ e $D_s < 0,85$ - críticas |

θ_s , conteúdo volumétrico de água do solo saturado; θ_M , conteúdo volumétrico de água do solo à $h = -0,1$ m H_2O ; θ_{FC} , conteúdo volumétrico de água na capacidade de campo ($h = -1$ m H_2O); θ_{PMP} , conteúdo volumétrico de água no ponto de murcha permanente ($h = -150$ m H_2O); M_{SS} , massa do solo seco (g) e V_T é volume total do solo (m^3). # Determinado por infiltração com a metodologia Beerkan.

Além dos parâmetros relacionados à descrição das curvas $\theta(h)$ (Eq. 1) e $K(\theta)$ (Eq. 2) já mencionados, os parâmetros indicativos da qualidade físico-hídrica do solo, tomando como referência padrões determinados por Reynolds et al. (2007, 2009) (Tabela 2), também foram estimados a partir da metodologia Beerkan. Seis indicadores foram derivados da curva estimada de retenção de água no solo (P_{mac} , $CAer$, $CADP$, CCR , λ_m e C_{λ_m}). Enquanto que S e K_s foram determinadas experimentalmente por infiltração.

O tamanho médio dos poros ponderados pelo fluxo λ_m (mm) (Eq. 3) (Mubarak *et al.*, 2009) e o número de poros hidraulicamente ativos por unidade de área C_{λ_m} (número de λ_m por m^2) (Eq. 4) (Watson e Luxmoore, 1986) foram calculados de acordo com as seguintes relações:

$$\lambda_m = \frac{\sigma_w}{\rho_w g \alpha_h} \quad (3)$$

$$C_{\lambda m} = \frac{8\mu K_s}{\rho_w g \pi \lambda_m} \quad (4)$$

onde σ_w é a tensão superficial solo-água ($0,0719 \text{ N m}^{-1}$), ρ_w é a densidade da água (103 kg m^{-3}), g é a aceleração gravitacional ($9,81 \text{ m s}^{-2}$), α_h (L) é o comprimento capilar macroscópico calculado a partir do parâmetro de escala h_g como $\alpha_h = h_g$ (Castellini et al., 2016; Haverkamp, 2006; Souza et al., 2014), e μ é a viscosidade dinâmica da água ($0,00089 \text{ kg m}^{-1} \text{ s}^{-1}$). O $C_{\lambda m}$ fornece uma descrição geral do número de λ_m (Iovino *et al.*, 2016).

3.5 COLETA E PROCESSAMENTO DE DADOS ESPECTRAIS

Um Veículo Aéreo Não Tripulado (VANT), modelo Phantom 4, posicionado a uma altura de 30 metros e equipado com um sensor Mapir Survey3 RGN e GSD equivalente a 1 cm, possibilitou a detecção da reflectância das bandas Red (vermelho), Green (verde) e NIR (infravermelho próximo), com o objetivo de corroborar a faixa do infravermelho utilizada pelo IRGA. Para garantir melhores resultados na cobertura de aquisição do dados, optou-se por uma calibração que voou que garantisse a sobreposição de 70% lateral e 80% frontal (Arantes *et al.*, 2020). O sobrevoo foi realizado exclusivamente sobre a área da agrofloresta, abrangendo tanto a parte alta quanto a baixa, que são paralelas entre si. Isso permitiu aumentar a área coberta em um único voo do VANT, capturando a heterogeneidade do sistema agroflorestal. Assim, foram considerados 8 pontos de amostragem por data de coleta, realizadas em dois momentos: 25 de janeiro e 20 de junho de 2024, correspondendo aos períodos de transição seco:chuvoso e chuvoso:seco, respectivamente, totalizando 16 pontos amostrais.

Com o auxílio do aplicativo DronedePloy, planejou-se os voos sempre próximo ao meio-dia visando minimizar os efeitos de sombreamento. Cinco alvos foram distribuídos uniformemente na área de voo para o georreferenciamento do ortomosaico, sendo a posição dos centróides-alvo determinada com um receptor GNSS, modelo Stonex 850A.

Para converter os valores digitais das imagens para reflectância de superfície, utilizou-se um painel específico com valores de reflectância conhecidos (proporção entre a radiação incidente e refletida), que serviu como referencial para a calibração das imagens no *software Mapir Camera Control*. As imagens calibradas foram processadas no *software Agisoft Metashape Professional*, versão 1.5.2, alinhando as fotos por pontos homólogos, gerando o modelo digital de superfície e por fim, o ortomosaico.

Os valores de reflectância, contendo a resposta espectral das áreas medidas em campo com o IRGA, foram extraídos a fim de determinar as correlações com as variáveis do solo (respiração, umidade e temperatura do solo). A partir desses valores extraídos foram elaborados índices de vegetação.

Os índices de vegetação deste estudo foram selecionados com base naqueles usualmente aplicados em estudos desta natureza (Silva et al., 2020), como o Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação por Diferença Normalizada Verde (GNDVI), Índice de Vegetação Ajustado ao Solo (SAVI) e o Índice de Vegetação Aprimorado (EVI) (Tabela 3).

Tabela 3. Índices de vegetação empregados no sistema agroflorestal.

| Índice | Equação | Autores |
|--|---------|---------------------------------|
| NDVI = (NIR-vermelho)/(NIR+vermelho) | 4 | (Rouse <i>et al.</i> , 1974) |
| GNDVI = (NIR-verde)/(NIR+verde) | 5 | (Gitelson <i>et al.</i> , 1995) |
| $SAVI = \frac{1+L}{2} \cdot \frac{NIR - vermelho}{NIR + vermelho + L}$ | 6 | (Huete, 1988) |
| $EVI = 2,5 \cdot \frac{NIR - vermelho}{(NIR + 6 \cdot vermelho - 7,5 \cdot azul) + 1}$ | 7 | (Justice <i>et al.</i> , 1998) |

Bandas infravermelho próximo (NIR), vermelho, verde e azul do espectro eletromagnético; enquanto L é um fator de ajuste do solo.

A matriz de correlação de Pearson para obtenção das bandas e índices correlacionados com os dados *in situ*, assim como a geração de gráficos, foi desenvolvida em ambiente R Studio 4.4.2 (R Development Core Team, 2024).

3.6 ANÁLISE ESTATÍSTICA

Foi realizada uma análise de distribuição temporal, dos dados coletados mensalmente com o IRGA (efluxo de CO₂, umidade e temperatura do solo), na qual foram calculadas a média e o erro padrão dessas variáveis de resposta para cada sistema de uso do solo, durante cada mês e período de estudo. A normalidade dos dados foi verificada pelo teste de Shapiro-Wilk, com nível de significância de 5%. Para as variáveis que não atenderam aos critérios de normalidade, foram explorados métodos de transformação de dados, mas nenhum se mostrou

eficaz. Assim, quando necessário, foram adotados métodos não paramétricos. O teste de Kruskal-Wallis substituiu a ANOVA, e o teste de Dunn foi utilizado como post-hoc não paramétrico, substituindo o teste de Tukey.

A modelagem foi baseada no algoritmo de aprendizado de máquina *Random Forest* (RF), que utilizou os valores de refletância registrados nas bandas espectrais e nos índices de vegetação, identificando quais conjuntos de bandas espectrais melhor respondem à variabilidade da variável de referência no campo. A modelagem foi realizada considerando a média da resposta espectral dos pixels do interior do tubo de PVC nos 16 pontos de coleta na área de Agrofloresta. Para isso, foi utilizada a linguagem de programação R (R CORE TEAM, 2024) por meio do pacote CARET (Kuhn *et al.*, 2024).

As estimativas foram validadas a partir de métodos estatísticos que determinam o grau de associação entre os produtos gerados. Para isso, foi avaliado o coeficiente de correlação (ρ) entre as variáveis de solo e os dados espectrais. Já a avaliação do desempenho dos modelos de predição da respiração, umidade e temperatura do solo foi realizada utilizando o coeficiente de determinação (R^2), raiz do quadrado médio do erro (RMSE) e o erro médio absoluto (MAE). As amostras foram divididas em conjunto treino e teste, utilizando o método de validação cruzada denominada de k-fold, o qual separou em 5 partes os dados no processo de validação.

4 RESULTADOS

4.1 EFLUXO DE CO₂, UMIDADE E TEMPERATURA DO SOLO

Os resultados apresentados na Figura 3 mostram a variação do efluxo de CO₂ nas 9 coletas realizadas ao longo dos 11 meses de estudo nos três diferentes sistemas de uso do solo: Caatinga (CA), pastagem (PA) e duas áreas de Agroflorestas (SAF1 e SAF2). Na análise temporal desses dados, considerou-se a distribuição de duas maneiras complementares: (1) uma distribuição que evidencia a variação ao longo de cada mês de coleta, e (2) uma distribuição sazonal, na qual os dados foram agrupados seguindo a ordem dos períodos chuvoso, seco e suas transições. Ambas as abordagens apresentam graficamente os valores médios e os respectivos erros padrão, permitindo uma análise detalhada da dinâmica temporal das variáveis.

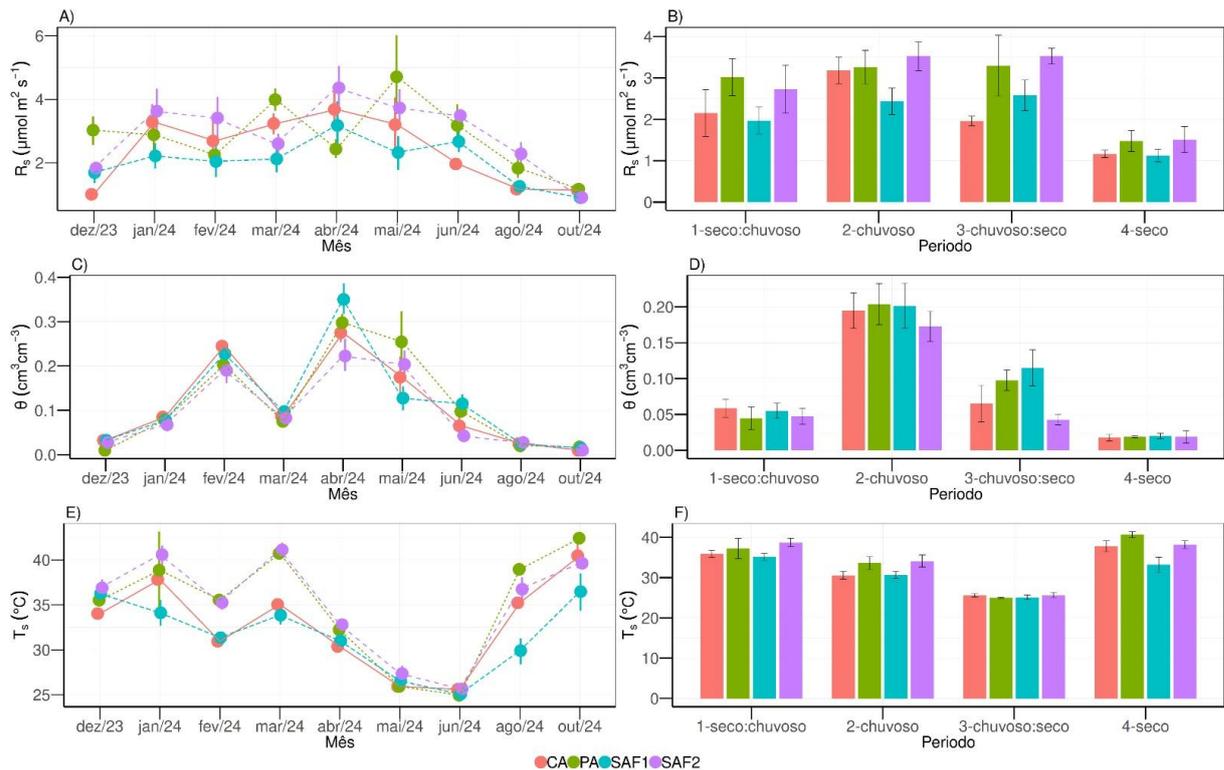


Figura 3 Médias e intervalos de confiança, IC (baseado no erro padrão e na distribuição t de Student) da respiração (R_s , $\mu\text{mol m}^{-2}\text{s}^{-1}$) (A e B), umidade (θ , $\text{m}^3 \text{m}^{-3}$) (C e D) e temperatura do solo (T_s , $^{\circ}\text{C}$) (E e F), calculados por método não paramétrico de bootstratp para os diferentes sistemas de uso do solo (CA – Caatinga, PA – Pastagem, SAF1 e SAF2 – Sistemas agroflorestais). Variação mensal (dezembro de 2023 a outubro de 2024) e por períodos (seco:chuvoso, chuvoso, chuvoso:seco e seco).

O efluxo de CO_2 apresentou variações significativas entre os sistemas ao longo dos nove meses de medições com o IRGA. Em geral, os valores oscilaram entre 1,0 e $4,3 \mu\text{mol m}^{-2} \text{s}^{-1}$, com os maiores valores registradas nos meses de março, abril e maio de 2024 (Figura 3A). O SAF2 apresentou os valores mais elevados de R_s durante a maior parte do período, enquanto o SAF1, registrou os valores mais baixos em quase todos os meses. A pastagem (PA) destacou-se por apresentar picos em março ($4,0 \mu\text{mol m}^{-2} \text{s}^{-1}$) e maio ($4,7 \mu\text{mol m}^{-2} \text{s}^{-1}$), indicando maior oscilação nos meses mais chuvosos. O SAF1 apresentou comportamento mais uniforme, com uma amplitude de variação de $1,9 \mu\text{mol m}^{-2} \text{s}^{-1}$ de dezembro até agosto, com picos em abril (Figura 3A). O sistema SAF2 apresentou os maiores valores no geral, atingindo um pico de $4,4 \mu\text{mol m}^{-2} \text{s}^{-1}$ em maio e mantendo-se acima de $1,8 \mu\text{mol m}^{-2} \text{s}^{-1}$ na maioria dos meses, exceto em outubro (Figura 3A).

Sazonalmente, na Caatinga, o R_s aumentou do período seco:chuvoso para o chuvoso, reduzindo expressivamente entre os períodos chuvoso:seco e seco (Figura 3B). A ausência de sobreposição dos intervalos de confiança evidenciam diferenças potenciais entre os períodos. Nos demais sistemas (PA, SAF1 e SAF2), a sobreposição dos intervalos de confiança entre os

períodos seco:chuvoso, chuvoso e chuvoso:seco sugere estabilidade de R_s , com redução apenas no período seco (Figura 3B).

Assim como nas emissões de CO_2 , a umidade do solo também apresentou variabilidade ao longo dos meses em estudo (Figura 3C) e entre os períodos (Figura 3D), foi identificada uma tendência crescente de dezembro a fevereiro, iniciando no período seco:chuvoso e seguindo até o período chuvoso. Houve uma breve redução nos valores médios em março, seguida de um aumento acentuado em abril, que apresentou o maior pico de umidade do solo. A partir de abril, as observações mostraram uma queda contínua até outubro, período seco. Entre os quatro sistemas analisados, o SAF1 apresentou os maiores valores médios, seguido pela pastagem (PA), Caatinga (CA) e, por último, o SAF2, com médias inferiores.

Os valores médios da temperatura (Figura 3E e 3F) mostraram um comportamento inversamente proporcional ao observado para a umidade do solo. Em dezembro, já foram observadas temperaturas elevadas, e em janeiro, atingiu seu pico, com 43,2 °C para a PA. A partir de fevereiro, com a chegada do período chuvoso, as temperaturas começaram a diminuir, alcançando os menores valores registrados durante o período de transição chuvoso:seco até junho, com 30,95 °C. Com o início do período seco, a temperatura voltou a subir, atingindo outro pico em outubro, com 42,41 °C. Entre os sistemas analisados, a pastagem (PA) apresentou as temperaturas mais altas, seguida pelo SAF2, Caatinga (CA) e, por último, o SAF1, com os valores mais baixos.

4.2 QUALIDADE FÍSICO-HÍDRICA DOS SOLOS

Os parâmetros n , η , θ_s , K_s e h_g obtidos com o algoritmo BEST-steady para descrever as curvas $\theta(h)$ (Eq. 1) e $K(\theta)$ (Eq. 2) para cada uso do solo e períodos estão apresentados na Tabela 4. Os parâmetros n e η nas áreas de CA, evidenciaram-se diferentes daqueles obtidos na SAF2, sendo semelhantes às demais áreas em ambos os períodos. Os valores de n para $\theta(h)$, tal como esperado, por ser dependente da textura, foram maiores no SAF2 (Tabela 4) pelo fato dos solos apresentarem as classes texturais com maior teor de areia (Tabela 1). Por outro lado, os valores de η para $K(\theta)$ foram menores. Esta relação inversa entre n e η se deve ao próprio formalismo matemático para se obter η (Eq. 2). Para ambos os períodos, chuvoso e seco, apesar de apresentarem variações numéricas no valor de suas médias, não houve diferença significativa entre períodos e sistemas, no comportamento dos parâmetros θ_s , K_s e h_g .

Tabela 4. Valores médios e desvio padrão dos parâmetros das curvas de retenção, $\theta(h)$, e condutividade hidráulica, $K(\theta)$, dos solos das áreas de Caatinga (CA), pastagem (PA) e sistemas agroflorestais (SAF1 e SFA2), obtidos com a metodologia Beerkan (BEST-steady).

| Uso do solo | n | η | θ_s ($\text{m}^3 \text{m}^{-3}$) | K_s (mm s^{-1}) | h_g (mm) [‡] |
|-----------------|----------------|----------------|---|------------------------------|-------------------------|
| Período chuvoso | | | | | |
| CA | 2,29 ± 0,01ab | 9,83 ± 0,26ab | 0,383 ± 0,065 | 0,015 ± 0,003 | 16,88 ± 12,60 |
| PA | 2,30 ± 0,05abc | 9,77 ± 1,22bc | 0,331 ± 0,022 | 0,022 ± 0,016 | 16,06 ± 14,53 |
| SAF1 | 2,20 ± 0,05abc | 13,48 ± 2,26bc | 0,328 ± 0,012 | 0,020 ± 0,014 | 20,11 ± 13,43 |
| SAF2 | 2,49 ± 0,23c | 7,76 ± 2,09c | 0,317 ± 0,056 | 0,021 ± 0,016 | 13,85 ± 7,39 |
| Período seco | | | | | |
| CA | 2,29 ± 0,01ab | 9,83 ± 0,26ab | 0,341 ± 0,021 | 0,019 ± 0,014 | 15,00 ± 21,55 |
| PA | 2,30 ± 0,05abc | 9,77 ± 1,22bc | 0,396 ± 0,072 | 0,027 ± 0,017 | 25,22 ± 13,37 |
| SAF1 | 2,20 ± 0,05abc | 13,48 ± 2,26bc | 0,406 ± 0,063 | 0,020 ± 0,013 | 26,36 ± 21,04 |
| SAF2 | 2,49 ± 0,23c | 7,76 ± 2,09c | 0,362 ± 0,058 | 0,022 ± 0,007 | 29,99 ± 20,86 |

[‡] valor absoluto de h_g . Letras minúsculas para comparações entre os usos do solo. Letras iguais, os valores são estatisticamente iguais. Comparações múltiplas para variáveis normais foram realizadas usando o teste de Tukey ($p < 0,05$), enquanto comparações para variáveis não normais foram realizadas usando o teste de Dunn com correção de Bonferroni ($p < 0,05$).

A Figura 4 a seguir apresenta a representação gráfica do comportamento observado em campo durante os períodos seco e chuvoso nos diferentes sistemas de uso do solo, destacando seus limites críticos para os indicadores da qualidade físico-hídrica do solo (IQFHS), conforme descrito anteriormente na Tabela 2. Para essa análise, foram utilizados a média e os intervalos de confiança (IC), baseados no erro padrão e na distribuição t de Student, calculados por meio do método não paramétrico de Bootstrap.

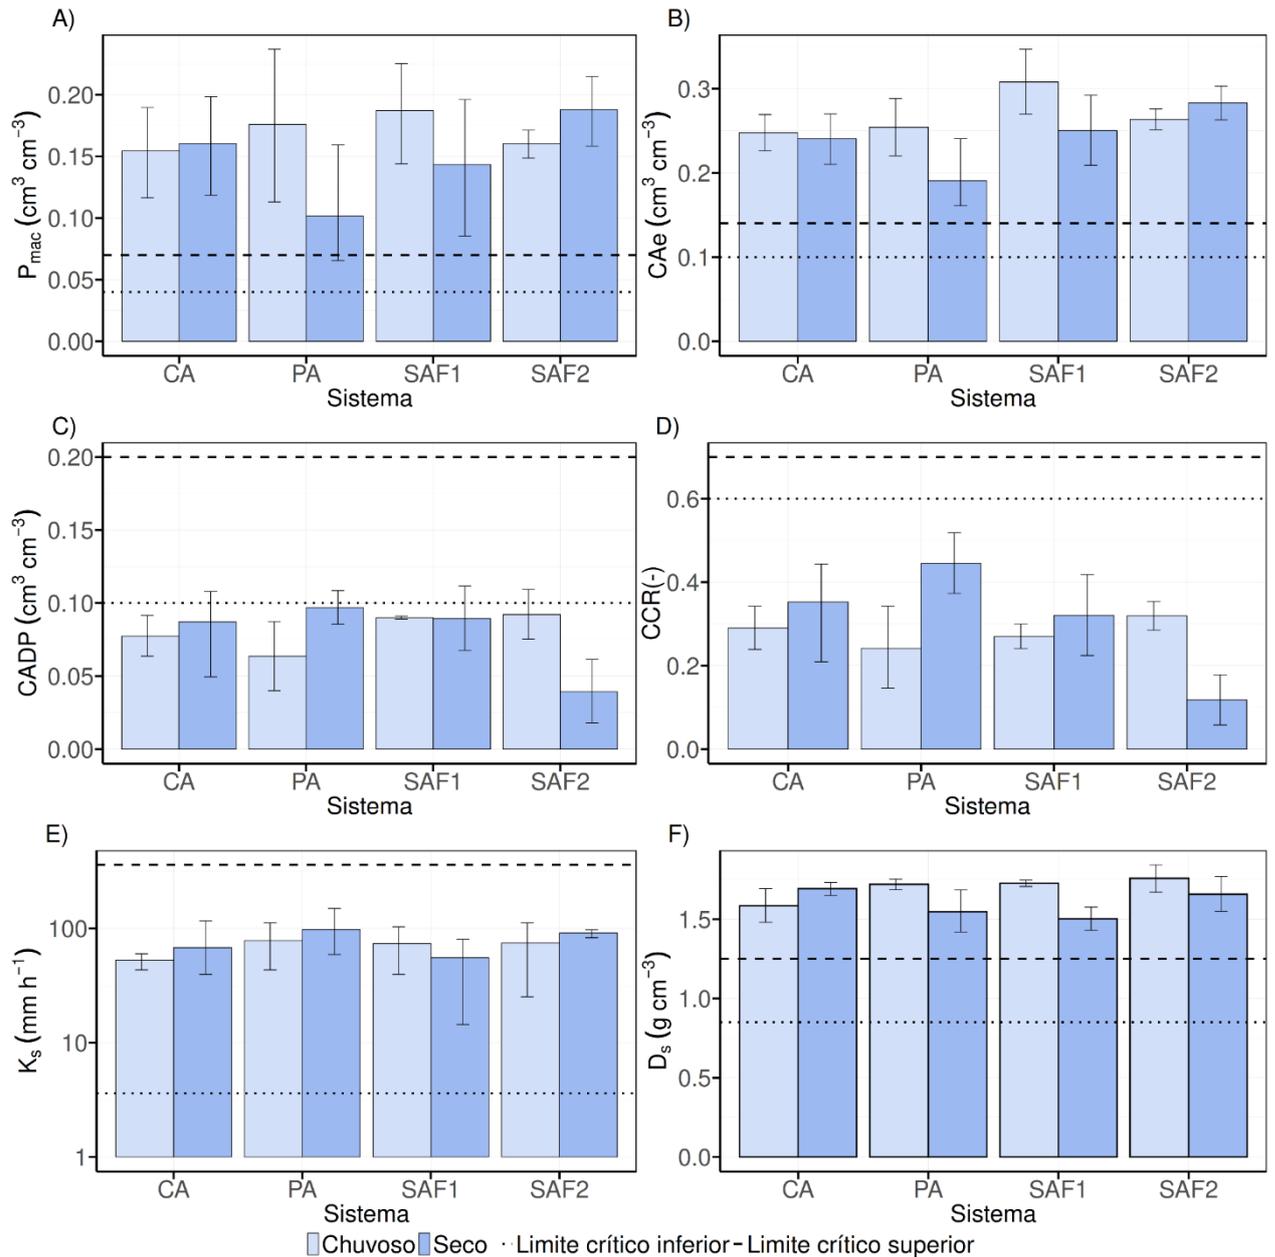


Figura 4. Médias e intervalos de confiança, IC (baseado no erro padrão e na distribuição t de Student) dos parâmetros de referência e seus limites críticos (Reynolds et al., 2007, 2009), calculados por método não paramétrico de bootstratp para os diferentes sistemas de uso da terra (CA – Caatinga, PA – Pastagem, SAF1 – Agrofloresta parte alta, SAF2 – Agrofloresta parte baixa), durante os períodos chuvoso e seco. Onde: P_{mac} - Macroporosidade ($m^3 m^{-3}$) – A, CAe - Capacidade de aeração ($m^3 m^{-3}$) – B, CADP - Capacidade de água disponível ($m^3 m^{-3}$) – C, CCR - Capacidade de campo relativa (adimensional) – D, K_s - Condutividade hidráulica ($mm h^{-1}$) – E e D_s – densidade do solo ($g cm^{-3}$) – F.

A P_{mac} (Figura 4A) não apresentou diferenças estatísticas significativas entre os sistemas de uso do solo nem entre os períodos avaliados, uma vez que todas as barras de erro padrão se sobrepõem, indicando que os resultados são estatisticamente equivalentes. Vale destacar que as médias observadas para a P_{mac} se mantiveram consistentemente acima do limite crítico superior. De maneira similar, a análise da CAe (Figura 4B) também revelou que,

embora houvesse variação sazonal, não houve diferenças estatísticas entre os sistemas nos períodos seco e chuvoso. No entanto, é importante ressaltar que, no período seco, a pastagem (PA) apresentou uma média inferior à do SAF1 no período chuvoso. Apesar de o SAF1 apresentar uma barra de erro mais ampla, os resultados foram estatisticamente semelhantes aos dos outros sistemas em ambos os períodos. Além disso, todas as observações permaneceram acima do limite crítico superior.

A CADP (Figura 4C) apresentou um comportamento similar em quase todos os sistemas, independentemente do período, exceto no SAF2, que exibiu uma CADP inferior no período seco em comparação com o período chuvoso. Vale ressaltar que, ao contrário da Pmac e da CAe, a CADP permaneceu abaixo do limite crítico inferior. Em relação à CCR (Figura 4D), apenas a PA e o SAF2 apresentaram comportamentos distintos entre os períodos. No período seco, a PA registrou uma CCR maior que no período chuvoso, enquanto no SAF2 a CCR média foi mais baixa no período seco em comparação com o chuvoso. Em ambos os casos, todas as médias ficaram abaixo do limite crítico inferior.

A condutividade hidráulica saturada (K_s) (Figura 4E) não apresentou diferenças significativas entre os períodos ou sistemas, com todas as médias observadas situando-se entre os limites crítico inferior e superior. Em contraste, a densidade do solo (D_s) (Figura 4F) exibiu variação apenas no SAF1, onde o valor médio no período chuvoso foi superior ao do período seco. Vale destacar que, em ambos os períodos, todos os sistemas apresentaram médias de K_s acima do limite crítico superior.

Na Figura 5A, observa-se que o conteúdo de água no solo (θ_0), medido no início das infiltrações, foi significativamente maior no período chuvoso em comparação ao período seco, em todos os sistemas. Durante o período chuvoso, os sistemas CA, PA e SAF1 apresentaram médias estatisticamente semelhantes entre si, sendo superior à do sistema SAF2. Por outro lado, no período seco, a média observada no SAF2 foi estatisticamente equivalente à da CA, enquanto a PA se destacou por apresentar a menor média nesse período.

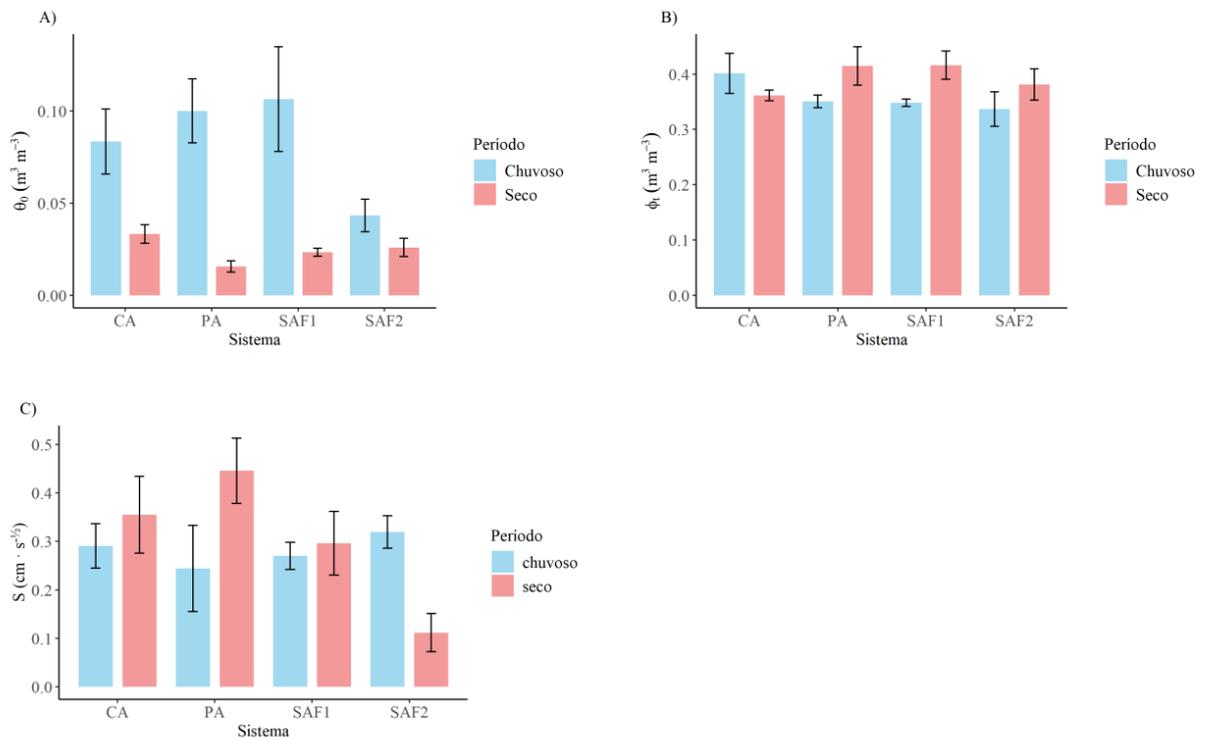


Figura 5. Representação gráfica dos testes de Tukey ($p < 0,05$) para dados paramétricos e de Dunn para dados não paramétricos, comparando os diferentes sistemas de uso da terra (CA – Caatinga, PA – Pastagem, SAF1 – Agrofloresta parte alta, SAF2 – Agrofloresta parte baixa) nos períodos chuvoso e seco. Os parâmetros analisados incluem: θ_0 - Umidade inicial ($\text{m}^3 \text{m}^{-3}$) – A, ϕ_t - Porosidade total ($\text{m}^3 \text{m}^{-3}$) – B, e S - Sorvidade ($\text{cm} \text{ s}^{-1/2}$) – C, no município de Custódia-PE.

Em relação a porosidade total (ϕ_t), apenas os sistemas PA e SAF1 apresentaram diferença entre os períodos, aumentando consideravelmente, na passagem do período chuvoso para o seco (Figura 5B). Nos outros sistemas, os valores médios de ϕ_t foram iguais em ambos os períodos. A sorvidade (S) (Figura 5C) também respondeu à mudança de período nos sistemas PA e SAF2. No período seco, o sistema PA apresentou a maior média entre todos os sistemas, além de superar a sua própria média do período chuvoso. Em contrapartida, no sistema SAF2, a maior média foi constatada no período chuvoso, superando a do período seco.

4.3 MODELOS PREDITIVOS PARA AS VARIÁVEIS DE SOLO

Após a execução dos procedimentos inerentes aos processamentos das imagens, obteve-se os mapas com as duas áreas de agrofloresta, referentes a ambos os períodos de transição seco:chuvoso (Figura 6A) e seco (Figura 6B). Os mapas, obtidos nos meses de janeiro e junho de 2024, respectivamente, permitem analisar a resposta das plantas à dinâmica sazonal. Em janeiro (Figura 6A), o mapa reflete a transição do período seco para o

chuvoso, evidenciando uma maior área de solo exposto em comparação à cobertura vegetal. Em junho (Figura 6B), essa dinâmica se inverte, com uma predominância da cobertura vegetal sobre o solo exposto.

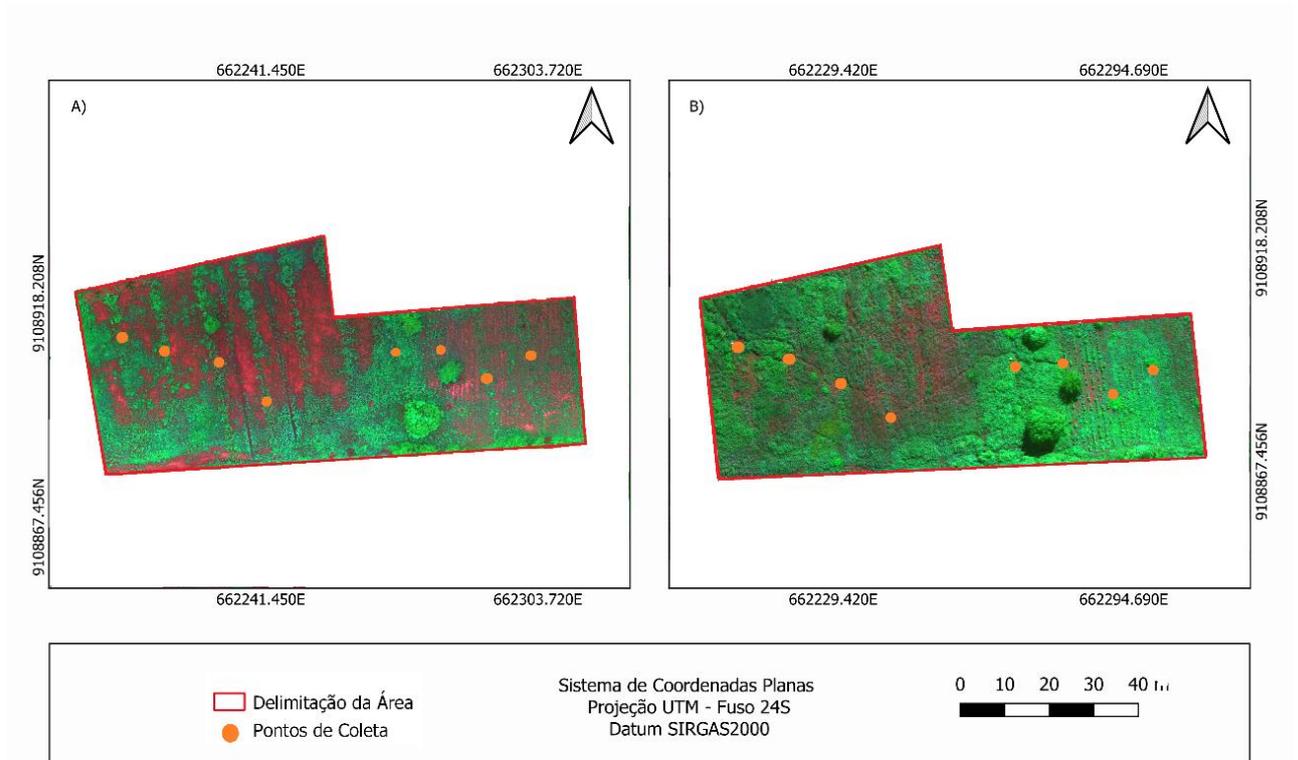


Figura 6. Ortomosaico da área de estudo (agrofloresta parte alta e baixa), gerado a partir da coleta de imagens pelo sensor RGN. Onde A) janeiro e B) junho, Custódia-PE.

Com os dados obtidos in situ, gerou a matriz de correlação de Pearson (Figura 7) entre as bandas espectrais e índices de vegetação, consoantes aos dados de respiração do solo (R_s), umidade do solo (θ) e temperatura do solo (T_s).

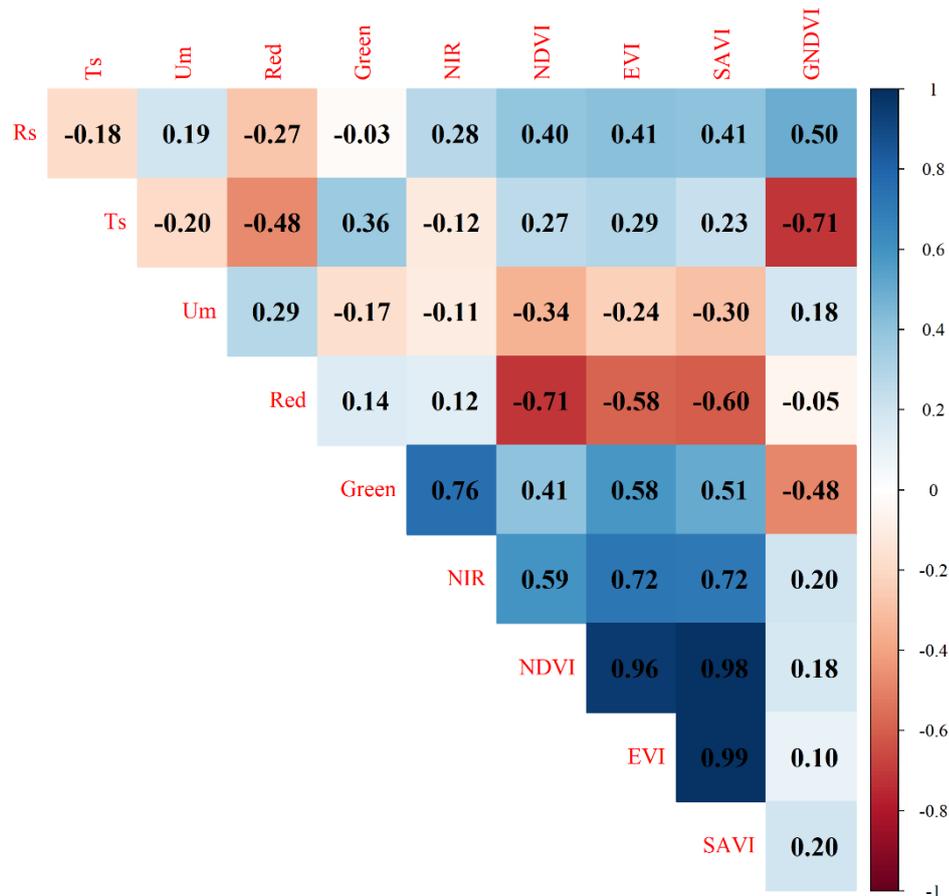


Figura 7. Matriz de correlação de Pearson entre os parâmetros coletados no solo (R_s – Respiração do solo ($\mu\text{molm}^{-2}\text{s}^{-1}$), θ – Umidade do solo (m^3m^{-3}) e T_s – Temperatura do solo ($^{\circ}\text{C}$)), e reflectância das bandas espectrais (Red – Banda Vermelho, Green – Banda Verde e NIR – Banda Infravermelho Próximo) e índices de vegetação (NDVI, EVI, SAVI e GNDVI) obtidos pelo valor médio dos pixels na imagem selecionados no interior do tubo de coleta dos dados in situ. Custódia-PE.

Entre as bandas espectrais, a faixa do vermelho foi a que apresentou as maiores correlações com os parâmetros de campo, em especial com a T_s , expressando $r=-0,48$, com um comportamento inversamente proporcional. Entre os índices de vegetação, o GNDVI se destacou, evidenciando alta correlação com a temperatura do solo (T_s , $r=-0,71$) e correlação moderada com a respiração do solo (R_s , $r=0,50$) e, enquanto o NDVI foi a variável espectral com maior correlação com umidade do solo (θ , $r= -0,34$).

A modelagem realizada com o algoritmo de aprendizado de máquina RF, apresentou excelentes ajustes na predição das variáveis de campo ao considerar todas as bandas e índices de vegetação (Tabela 5). Os resultados indicaram erros relativamente baixos e capturaram parte significativa da variabilidade dos dados observados em campo. Os modelos de estimativa da R_s e θ apresentaram desempenho satisfatório, com um bom ajuste (R^2) e erros

relativamente baixos. Por outro lado, a variável T_s apresentou desempenho moderado devido à magnitude dos dados, com um ajuste inferior em comparação às demais variáveis.

Tabela 5. Erro quadrático médio (RMSE), coeficiente de determinação (R^2) e erro médio absoluto (MAE) após a validação cruzada para a respiração do solo (R_s), umidade do solo (θ) e temperatura do solo (T_s) em relação às bandas espectrais e índices de vegetação.

| Propriedades | RMSE | R^2 | MAE |
|---|-------|-------|-------|
| R_s ($\mu\text{mol m}^{-2}\text{s}^{-1}$) | 0,925 | 0,814 | 0,764 |
| θ ($\text{m}^3 \text{m}^{-3}$) | 0,036 | 0,923 | 0,035 |
| T_s ($^{\circ}\text{C}$) | 2,967 | 0,762 | 2,408 |

Ao analisar a dispersão dos dados (Figura 8), observa-se que os modelos das variáveis T_s e R_s demonstraram maior precisão preditiva, sendo esse comportamento evidenciado pela menor dispersão dos pontos em relação à linha de tendência. A variável θ , apesar de dispor do maior valor de R^2 , apresentou maiores erros nas estimativas, exposto pela maior dispersão dos pontos.

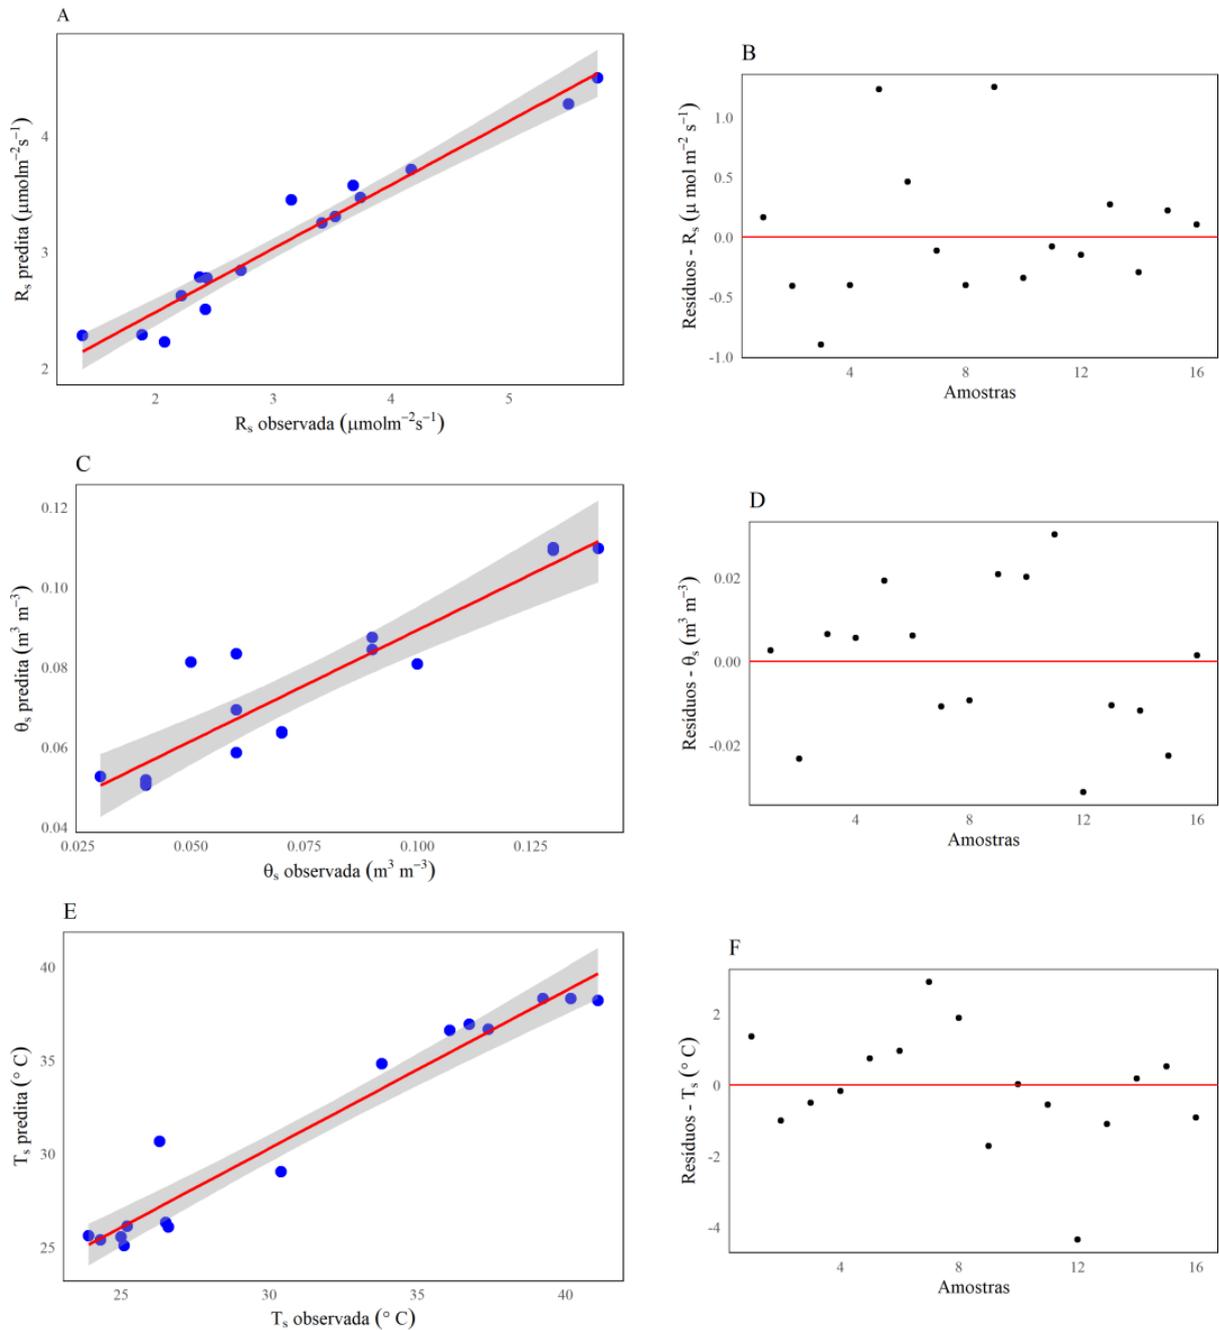


Figura 8. Representação gráfica do modelo de predição e resíduo, respectivamente, obtido para cada parâmetro mensurado no solo (R_s – Respiração do solo ($\mu\text{mol m}^{-2}\text{s}^{-1}$) - A e B, θ_s – Umidade do solo ($\text{m}^3\text{ m}^{-3}$) - C e D e T_s – Temperatura do solo ($^{\circ}\text{C}$) - E e F).

Foi observado que, para as variáveis de campo, o algoritmo RF gerou valores preditivos próximos aos valores observados (Figura 9). No entanto, identificaram-se variações nos valores estimados, especialmente nos pontos extremos, onde os modelos mostraram menor eficiência.

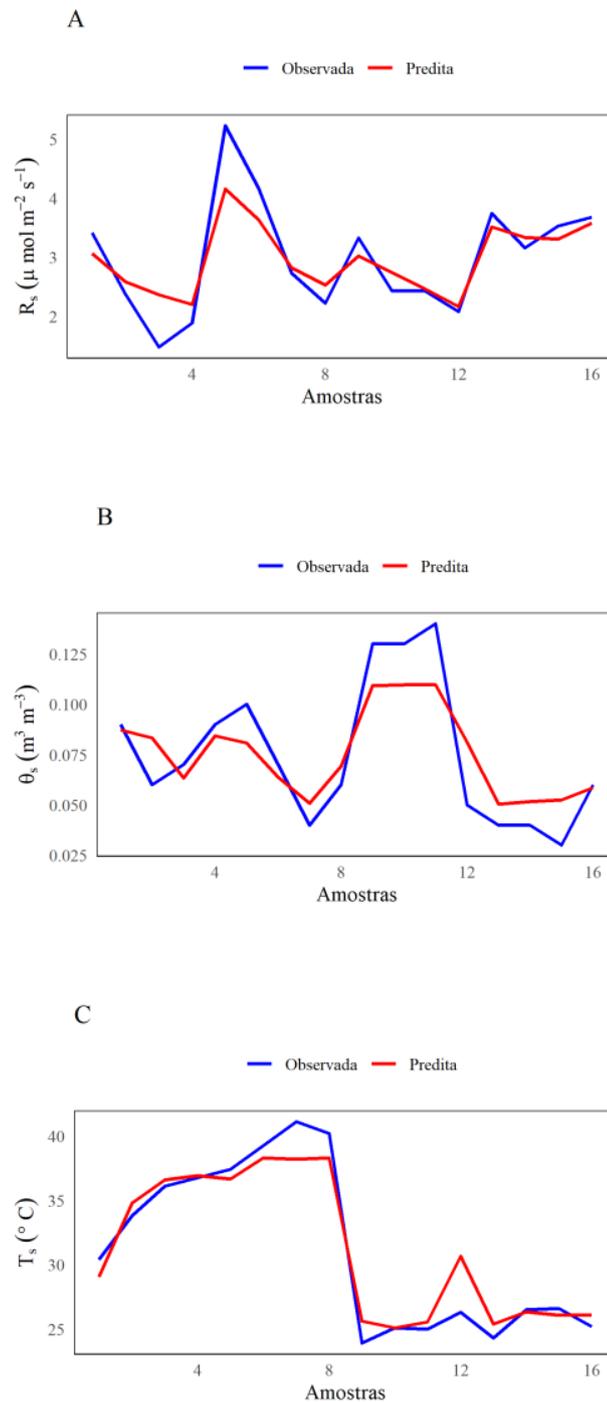


Figura 9 Comportamento dos valores de Respiração do solo (R_s , $\mu\text{mol m}^{-2} \text{s}^{-1}$) - (A), Umidade do solo (θ , $\text{m}^3 \text{m}^3$) - (B) e Temperatura do solo (T_s , $^{\circ}\text{C}$) - (C), mensuradas em campo com o IRGA e preditas pelo modelo.

Após a obtenção do modelo preditivo e a detecção de resultados satisfatórios dos valores preditos em relação aos observados, foi realizado a predições das variáveis para toda área da agrofloresta (Figura 10).

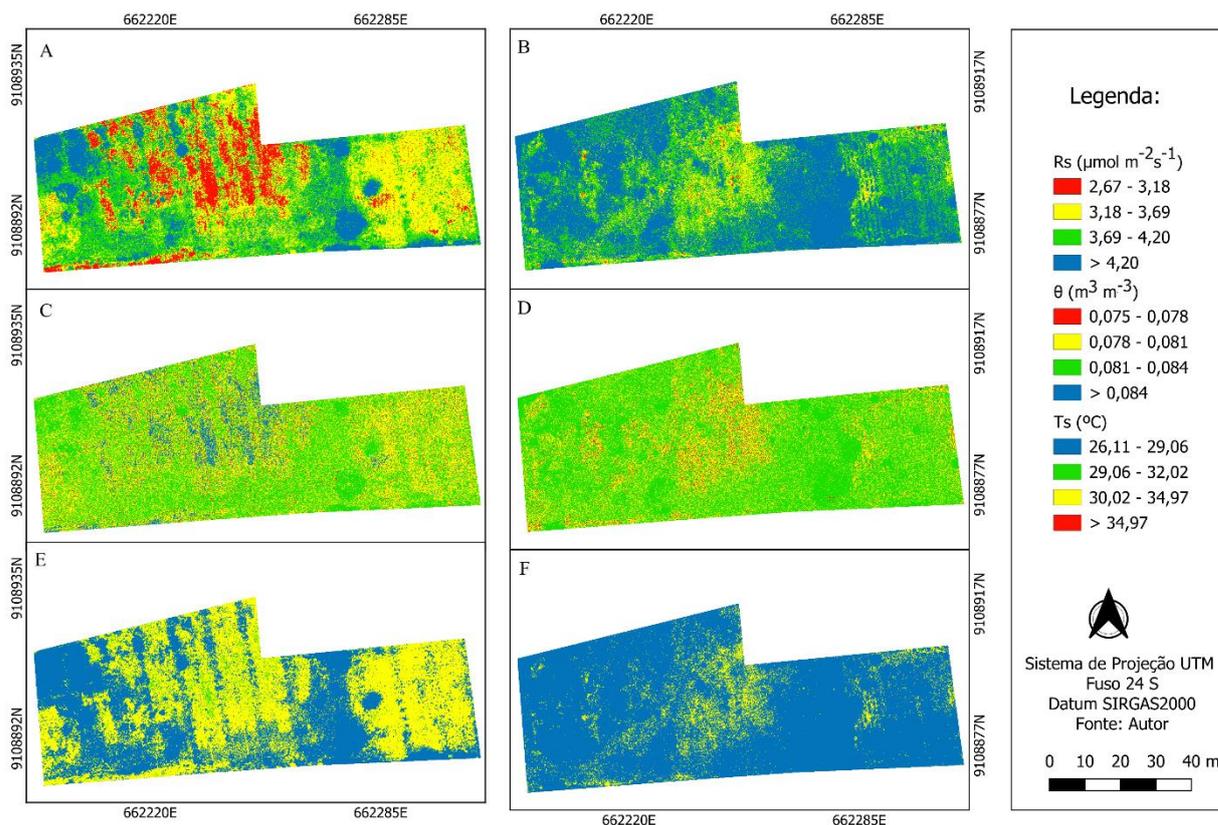


Figura 10. Mapas de espacialização das variáveis previstas pelo modelo obtido para o sistema agroflorestal. A e B - Respiração do solo (R_s , $\mu\text{mol m}^{-2} \text{s}^{-1}$), C e D - umidade do solo (θ , m^3m^3) e E e F - temperatura do solo (T_s , $^{\circ}\text{C}$), para os meses de janeiro e junho respectivamente.

Dessa forma, foi possível obter uma visão ampla sobre a área de agrofloresta, permitindo discretizar o comportamento e padrão espacial de cada variável estudada. A respiração e a umidade do solo apresentaram valores inferiores no período com menor precipitação (Figuras 10A e C) e maiores valores nos períodos com maior precipitação (Figuras 10B e D), respectivamente. A temperatura do solo seguiu o mesmo padrão relacionado aos efeitos da pluviosidade, com valores elevados em janeiro e inferiores em junho (Figuras 10E e F).

A Tabela 6 apresenta o valor representativo da área ocupada em cada uma das classes distribuídas pelas variáveis previstas apresentadas na Figura 10. No mês de janeiro, em 69,4 % da área de agrofloresta, os valores de respiração do solo encontravam-se entre 3,18 – 4,20 $\mu\text{mol m}^{-2}\text{s}^{-1}$. Enquanto no mês de junho, 86,57 % da área apresentou valores de R_s com a mesma magnitude.

Tabela 6 Distribuição do quantitativo espacial para cada classe das variáveis previstas pelo modelo, na agrofloresta, para os meses de janeiro e junho de 2023.

| Variáveis previstas | Classes | Janeiro | | Junho | |
|--|---------------|----------------|-------|----------------|--------|
| | | m ² | % | m ² | % |
| R _s (μmol m ⁻² s ⁻¹) | 2,67 – 3,18 | 665,17 | 14,09 | 37,36 | 0,79 |
| | 3,18 – 3,69 | 1667,50 | 35,34 | 700,87 | 14,85 |
| | 3,69 – 4,20 | 1607,00 | 34,06 | 1736,19 | 36,79 |
| | > 4,20 | 737,89 | 15,64 | 2207,44 | 49,78 |
| θ (m ³ m ⁻³) | 0,075 – 0,078 | 207,13 | 4,39 | 169,75 | 3,59 |
| | 0,078 – 0,081 | 2029,94 | 43,02 | 1439,39 | 30,50 |
| | 0,081 – 0,084 | 2116,51 | 44,86 | 3061,16 | 64,88 |
| | > 0,084 | 324,00 | 6,86 | 12,33 | 0,26 |
| T _s (°C) | 26,11 – 29,06 | 2278,84 | 48,30 | 3865,27 | 81,92 |
| | 29,06 – 32,02 | 276,89 | 5,86 | 67,19 | 1,42 |
| | 32,02 – 34,97 | 2121,83 | 44,97 | 749,99 | 15,89 |
| | > 34,97 | 0 | 0 | 0,11 | 0,0023 |

R_s – Respiração do solo; θ - Umidade do solo e T_s – Temperatura do solo.

Para a umidade do solo prevista pelo modelo, os valores pertencentes a primeira e quarta classe, não foram tão representativos na área, ocupando juntas apenas 11,25% e 3,85% da área entre janeiro e junho, já os valores de umidade pertencentes às classes centrais, segunda e terceira, 0,078 – 0,081 e 0,081 – 0,084 m³ m⁻³ respectivamente, foram mais representativos na área de estudo em ambos os meses, ocupando juntas 87,88 % e 95,38 % para janeiro e junho respectivamente, com destaque para junho, o qual obteve 64,88% dos valores da terceira classe ocupando a área de estudo.

Para a variável temperatura, em janeiro foi observado predominância das classes com intervalo 26,11-29,06 °C e 32,02-34,97 °C abrangendo 48,30% e 44,97% do total da área, respectivamente. Já no mês de junho, a classe predominante foi a primeira, englobando aproximadamente 82% da área.

5 DISCUSSÃO

A variação sazonal teve um impacto direto no comportamento do efluxo de CO₂, na umidade e na temperatura do solo, enquanto apenas alguns parâmetros físico-hídricos do solo mostraram sensibilidade às mudanças sazonais ao longo dos nove meses de estudo. Além desse fenômeno, outro fator que influenciou o comportamento das variáveis foram as características físicas do solo de cada sistema, as quais se relacionam diretamente com cada variável resposta, conforme sua natureza física.

A influência do sistema agroflorestal sobre o ambiente foi inferior ao esperado para esse modelo de agroecossistema, possivelmente devido à sua implantação recente, o que sugere a necessidade de maior maturidade do sistema. Por outro lado, o sensoriamento remoto suborbital possibilitou a criação de modelos preditivos e a geração de mapas de espacialização com variáveis preditas ao longo de toda a área da agrofloresta, demonstrando seu potencial na gestão do agroecossistema.

5.1 EFLUXO DE CO₂, UMIDADE E TEMPERATURA DO SOLO

Com a ocorrência de precipitação, espera-se um aumento imediato no transporte de CO₂ proveniente do gás acumulado nos poros do solo, forçado a sair devido ao preenchimento dos mesmos pela água (Jiang *et al.*, 2021). Em seguida, a precipitação desencadeia uma série de eventos no solo, ativando a atividade metabólica da microbiota, o que, por sua vez, eleva significativamente as emissões de dióxido de carbono via respiração (Jiang *et al.*, 2021; Lv, Liu e Ding, 2024). A umidade disponível também favorece a germinação de sementes dormentes, estimulando a proliferação de plantas. Esse processo aumenta a quantidade de raízes respirando dentro do solo e reduz a área exposta aos efeitos da radiação solar, o que resulta em uma queda na temperatura do solo à medida que a população de plantas cresce no sistema (Lozano-Parra *et al.*, 2018).

Os solos mais arenosos, como os presentes nos sistemas SAF2 e PA, apresentaram as emissões de CO₂ mais elevadas, devido à maior macroporosidade, que facilita o transporte do gás para a atmosfera (Souza *et al.*, 2019). Um caso particular é o sistema PA, que manteve uma cobertura vegetal, composta predominantemente pelas gramíneas capim capiaçu (*Pennisetum purpureum* Schumach) e capim Bufel (*Cenchrus ciliaris* L.), por um período mais longo. Embora tenha ocorrido uma queda nas emissões durante o período seco, o sistema reagiu rapidamente às chuvas, com a vegetação recobrando o solo de forma eficiente (Concilio *et al.*, 2015).

No sistema SAF1, a umidade proveniente das chuvas permaneceu por mais tempo na camada superficial do solo devido à alta capacidade de retenção de água das partículas de

argila (Al-Shayea, 2001), o que resultou em valores elevados de umidade ao longo do estudo. Em contrapartida, o solo do SAF2, por ser mais arenoso, apresentou os menores valores de umidade, devido à sua baixa capacidade de retenção de água e, conseqüentemente, a maior perda por evaporação e infiltração (Liu et al., 2023).

5.2 QUALIDADE FÍSICO-HÍDRICA DO SOLO

Por natureza própria, os parâmetros de forma n e η estão intimamente relacionados à textura do solo, portanto como esperado, não houve alterações em seus valores observados em cada um dos períodos estudados, apenas diferenças sutis entre os sistemas como já exposto na seção de resultados, além desses, a variação sazonal não foi suficiente para apresentar mudanças entre θ_s , K_s e h_g também por conta da textura e também a porosidade.

Em relação à macroporosidade (P_{mac}), mesmo que todos os sistemas apresentem valores acima dos limites críticos, situação classificada como ótima, a ausência da variação significativa entre os períodos sugere que a estrutura da matriz do solo nesses ambientes se mantém relativamente estável, independentemente das condições de umidade, diferindo do que foi encontrado por Simões et al., (2020) o qual mostrou variação da macroporosidade de acordo com as mudanças sazonais do regime hídrico. A capacidade de aeração (CAe) apresentou médias acima do limite crítico superior, o que a qualifica numa situação ótima de aeração do solo, característica relacionada à porosidade total do solo, incluindo, portanto, a situação descrita anteriormente relacionada ao ótimo estado da macroporosidade, relação que também é descrita por Pott et al. (2017).

Para a Capacidade de Água Disponível (CADP), todas as observações médias independente do sistema ou período, apresentaram valores abaixo do limite crítico inferior, o que indica, portanto, que a variação sazonal da umidade, não foi suficiente para que a CADP deixasse de apresentar uma condição ruim, especialmente no período seco, assim como também a influência dos sistemas agroflorestais sobre o solo ainda ser prematura. O que sugere que os solos estudados possuem baixa capacidade de retenção de água disponível para as plantas, condição relacionada ao baixo teor de argila apresentado, o que pode comprometer a produtividade vegetal em períodos de estiagem (Poulos *et al.*, 2021). A capacidade de campo relativa (CCR) também demonstrou valores abaixo dos limites críticos, indicando que os sistemas estudados possuem baixa capacidade de retenção de água e conseqüentemente, podem estar sujeitos a risco de estresse hídrico (Feifel *et al.*, 2024).

A condutividade hidráulica (K_s) não apresentou diferenças significativas entre os sistemas ou períodos, se contrapondo ao que foi encontrado por Kargas et al. (2021) em função da alta variabilidade espacial na sua área de estudo, porém todos os valores ficaram acima do limite crítico inferior, sugerindo que os solos de todos os sistemas possuem capacidade intermediária de condução de água no solo. Quanto à densidade do solo (D_s), todos os valores foram elevados, pois estes ocorrem em função da composição mineral do solo. Solos arenosos apresentam densidade do solo superior aos argilosos e siltosos (Igwe, 2017; Libardi, 2018). Todos os resultados se encontram acima do limite crítico superior, apresentando elevado adensamento.

No período seco, o sistema PA apresentou o menor valor de umidade inicial, o que pode ser resultado da alta evapotranspiração e baixa capacidade de retenção de água desse sistema (Sun *et al.*, 2014). O comportamento da ϕ_t seguiu uma tendência semelhante ao comportamento que já fora apresentado pela umidade no ponto de saturação, por possuírem princípios que se complementam. Esses resultados reforçam a importância da estrutura do solo e da distribuição de poros na retenção de água (Sun *et al.*, 2014).

A sorvidade do solo (S) está diretamente relacionada à capacidade do solo de absorver água por capilaridade, e os resultados indicam que, no período seco, os solos desses sistemas são mais eficientes na captação de água, com exceção do SAF2, que pode estar mais suscetível à perda de água superficial (Shaver *et al.*, 2013).

5.3 MODELOS PREDITIVOS PARA AS VARIÁVEIS DE SOLO

A percepção sobre as diferentes densidades de vegetação apresentada sobre a cobertura do solo na agrofloresta para os meses de janeiro e junho, demonstra o quão influentes foram os efeitos provocados pela sazonalidade pluvial sobre o cenário, influenciando, portanto, no comportamento das variáveis preditas pela modelagem.

O modelo de estimativa da variável θ demonstrou englobar grande parte da variabilidade em campo, resultando em um alto valor de R^2 na modelagem. No entanto, apresentou maior dispersão dos valores na reta de regressão, o que pode acarretar maiores erros nas estimativas do modelo. Por sua vez, os modelos de R_s e T_s apresentaram valores moderados de R^2 , aliado a menores erros na distribuição dos valores preditos e estimados.

Destaca-se que ambas as variáveis analisadas apresentaram R^2 acima de 0,70, indicando um bom ajuste dos modelos, além de erros mínimos nas previsões, o que reflete a capacidade do RF em fornecer previsões consistentes, mesmo para variáveis com maior variabilidade em campo. Em contexto semelhante no trabalho desenvolvido por Zheng et al. (2018), buscou estimar o conteúdo de nitrogênio foliar no trigo de inverno aplicando vários algoritmos e dentre eles o RF, o qual se sobressaiu com o melhor resultado apresentado pelas previsões. Além desse, outro estudo realizado por Sodango et al. (2021) avaliou o desempenho do RF na previsão de carbono orgânico do solo em vários usos da terra, onde também foi capaz de obter previsões precisas. (Liu *et al.*, 2024), também utilizaram aprendizado de máquina e aplicaram o algoritmo RF para obtenção de um modelo preditivo para o conteúdo de água no solo a partir de imagens aéreas coletadas por sensor multiespectral em VANT, e obtiveram monitoramento eficiente das variações espaço-temporais da umidade do solo.

O bom desempenho do RF na previsão das variáveis de solo englobadas no estudo pode ser atribuído à relação direta entre as variações dessas propriedades em campo e mudanças na cobertura vegetal, matéria orgânica e estrutura do solo, o que promove alterações na resposta espectral, e consequentemente no registro pelos sensores remotos. Essas alterações espectrais tornam a informação mais facilmente estimável por meio de imagens. Ainda assim, ambos os modelos apresentaram subestimativa nos valores extremos de R_s , θ , T_s , o que se deve a baixa amostragem, resultando em poucos valores extremos para aprendizado do modelo, indicando nesse sentido, necessidade de maior amostragem em campo.

Sendo assim, a partir dos modelos preditivos gerados pelo aprendizado de máquina aplicando o algoritmo RF e obtendo análise de espacialização para respiração, umidade e temperatura do solo preditas na agrofloresta, foi possível perceber a coerência das previsões, as quais correspondem com o comportamento esperado pelas variáveis em função das características locais e sazonais.

6 CONCLUSÕES

O comportamento do efluxo de CO₂, da umidade e da temperatura do solo foi analisado à luz da sazonalidade e das características espaciais, assim como a resistência de determinados parâmetros da qualidade físico-hídrica do solo às variações temporais, evidenciando como essas variáveis se comportaram em função das diferentes texturas do solo. Além disso, foi possível caracterizar o impacto ambiental de um sistema agroflorestal recém-implantado. O uso de VANTs permitiu a construção de modelos preditivos para monitorar de forma rápida, prática e precisa o comportamento do efluxo de CO₂, da umidade e da temperatura do solo em agroflorestas em estádios iniciais de desenvolvimento, fornecendo uma ferramenta eficaz para a gestão e monitoramento desses parâmetros em larga escala.

Vale salientar que o aumento no número de amostras pode apresentar resultados ainda mais satisfatórios, especialmente quando relacionado a modelagem, aumentando a precisão das previsões e minimizando os erros das estimativas.

REFERÊNCIAS

- AGNESE, C.; BAGARELLO, V.; BAIAMONTE, G.; IOVINO, M. Comparing Physical Quality of Forest and Pasture Soils in a Sicilian Watershed. **Soil Science Society of America Journal**, v. 75, n. 5, p. 1958–1970, set. 2011.
- AL-SHAYEA, N. A. The combined effect of clay and moisture content on the behavior of remolded unsaturated soils. **Engineering Geology**, v. 62, n. 4, p. 319–342, dez. 2001.
- ALTIERI, M. A. Agroecology: the science of natural resource management for poor farmers in marginal environments. **Agriculture, Ecosystems & Environment**, v. 93, n. 1–3, p. 1–24, dez. 2002.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; MORAES GONÇALVES, J. L. DE; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.
- ARANTES, L. T.; ARANTES, B. H. T.; GIONGO, P. R.; CECCATO, G. Z.; MORAES, V. H.; SAITO, Y. K.; GOMES, L. F.; CASTRO, A. C. **Comportamento espectral e detecção de laranjeiras (Citrus sinensis L. Osbeck) com estresse hídrico, por meio de drone Revista Brasileira de Geografia Física**. [s.l: s.n.].
- ARAÚJO FILHO, R. N. DE; FREIRE, M. B. G. DOS S.; WILCOX, B. P.; WEST, J. B.; FREIRE, F. J.; MARQUES, F. A. Recovery of carbon stocks in deforested caatinga dry forest soils requires at least 60 years. **Forest Ecology and Management**, v. 407, p. 210–220, 1 jan. 2018.
- BAGARELLO, V.; PRIMA, S. DI; IOVINO, M. Comparing Alternative Algorithms to Analyze the Beerkan Infiltration Experiment. **Soil Science Society of America Journal**, v. 78, n. 3, p. 724–736, maio 2014.
- BAGARELLO, V.; PRIMA, S. DI; IOVINO, M.; PROVENZANO, G.; SGROI, A. Testing different approaches to characterize Burundian soils by the BEST procedure. **Geoderma**, v. 162, n. 1–2, p. 141–150, abr. 2011.
- BROOKS, R. H.; COREY, A. T. Hydraulic properties of porous media. **Hydrology Paper**, v. 3, p. 27, 1964.
- BURDINE, N. T. Relative Permeability Calculations From Pore Size Distribution Data. **Journal of Petroleum Technology**, v. 5, n. 03, p. 71–78, 1 mar. 1953.
- CANARACHE, A. PENETR — a generalized semi-empirical model estimating soil resistance to penetration. **Soil and Tillage Research**, v. 16, n. 1–2, p. 51–70, abr. 1990.
- CARVALHO, F. E. L.; ESCOBAR-PACHAJOA, L. D.; CAMARGO, I. D.; ROJAS-MOLINA, J.; JAIMES-SUÁREZ, Y. Y.; RIVERA-MENESES, J. J. The interspecific interactions in agroforestry systems enhance leaf water use efficiency and carbon storage in cocoa. **Environmental and Experimental Botany**, v. 205, p. 105119, 1 jan. 2023.
- CASTELLINI, M.; IOVINO, M.; PIRASTRU, M.; NIEDDA, M.; BAGARELLO, V. Use of BEST Procedure to Assess Soil Physical Quality in the Baratz Lake Catchment (Sardinia, Italy). **Soil Science Society of America Journal**, v. 80, n. 3, p. 742–755, 24 maio 2016.
- CASTELLINI, M.; PIRASTRU, M.; NIEDDA, M.; VENTRELLA, D. Comparing physical quality of tilled and no-tilled soils in an almond orchard in South Italy. **Italian Journal of Agronomy**, v. 8, p. 149–157, 2013.
- CHEHREH, B.; MOUTINHO, A.; VIEGAS, C. **Latest Trends on Tree Classification and Segmentation Using UAV Data—A Review of Agroforestry Applications Remote Sensing** MDPI, , 1 maio 2023.
- CONCILIO, A. L.; PREVÉY, J. S.; OMASTA, P.; O'CONNOR, J.; NIPPERT, J. B.; SEASTEDT, T. R. Response of a mixed grass prairie to an extreme precipitation event. **Ecosphere**, v. 6, n. 10, p. 1–12, 6 out. 2015.

- COSTA LOURENÇO, E. R.; ISRAREL DE SOUZA, B.; D'ANDREA, A. F.; LELIS LEAL DE SOUZA, J. J. Temporal variation of soil CO₂ emission in different land uses in the Caatinga. **Applied Geography**, v. 140, 1 mar. 2022.
- FAROOQUE, A. A.; AFZAAL, H.; BENLAMRI, R.; AL-NAEMI, S.; MACDONALD, E.; ABBAS, F.; MACLEOD, K.; ALI, H. Red-green-blue to normalized difference vegetation index translation: a robust and inexpensive approach for vegetation monitoring using machine vision and generative adversarial networks. **Precision Agriculture**, 1 jun. 2023.
- FEIFEL, M.; DURNER, W.; HOHENBRINK, T. L.; PETERS, A. Effects of improved water retention by increased soil organic matter on the water balance of arable soils: A numerical analysis. **Vadose Zone Journal**, v. 23, n. 1, 25 jan. 2024.
- GENUCHTEN, M. TH. VAN. A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils. **Soil Science Society of America Journal**, v. 44, n. 5, p. 892–898, set. 1980.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N.; BLAUSTEIN, J. **Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODISREMOTE SENS. ENVIRON.** [s.l.] ©Elsevier Science Inc, 1995.
- HAVERKAMP, R. Soil properties and moisture movement in the unsaturated zone. *Em: DELLEUR, J. W. (Ed.). . The Handbook of Groundwater Engineering.* [s.l.] CRC, 2006. p. 1–59.
- HAVERKAMP, R.; ROSS, P. J.; SMETTEM, K. R. J.; PARLANGE, J. Y. Three-dimensional analysis of infiltration from the disc infiltrometer: 2. Physically based infiltration equation. **Water Resources Research**, v. 30, n. 11, p. 2931–2935, 9 nov. 1994.
- HEIMSCH, L.; HUUSKO, K.; KARHU, K.; MGANGA, K. Z.; KALU, S.; KULMALA, L. Effects of a tree row on greenhouse gas fluxes, growing conditions and soil microbial communities on an oat field in Southern Finland. **Agriculture, Ecosystems & Environment**, v. 352, p. 108525, 15 ago. 2023.
- HUANG, T. *et al.* Deciphering the UAV-LiDAR contribution to vegetation classification using interpretable machine learning. **Computers and Electronics in Agriculture**, v. 235, p. 110360, ago. 2025.
- HUETE, A. R. **A Soil-Adjusted Vegetation Index (SAVI) 295REMOTE SENSING OF ENVIRONMENT.** [s.l: s.n.].
- IGWE, O. The Combined Effect of Particle Size Distribution and Relative Density on the Large Strain Behavior of Sandy Soils. **Geotechnical and Geological Engineering**, 16 out. 2017.
- IOVINO, M.; CASTELLINI, M.; BAGARELLO, V.; GIORDANO, G. Using Static and Dynamic Indicators to Evaluate Soil Physical Quality in a Sicilian Area. **Land Degradation & Development**, v. 27, n. 2, p. 200–210, 19 fev. 2016.
- JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. **Electronic Markets**, v. 31, n. 3, p. 685–695, 8 set. 2021.
- JIANG, Z.; BIAN, H.; XU, L.; LI, M.; HE, N. Pulse Effect of Precipitation: Spatial Patterns and Mechanisms of Soil Carbon Emissions. **Frontiers in Ecology and Evolution**, v. 9, 26 maio 2021.
- JUSTICE, C. O. *et al.* **The Moderate Resolution Imaging Spectroradiometer (MODIS): Land Remote Sensing for Global Change ResearchIEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING.** [s.l: s.n.]. Disponível em: <<http://eosps0.gsfc.>>.
- KARGAS, G.; LONDRA, P. A.; SOTIRAKOGLU, K. Saturated Hydraulic Conductivity Measurements in a Loam Soil Covered by Native Vegetation: Spatial and Temporal Variability in the Upper Soil Layer. **Geosciences**, v. 11, n. 2, p. 105, 22 fev. 2021.

- KELISHADI, H.; MOSADDEGHI, M. R.; HAJABBASI, M. A.; AYOUBI, S. Near-saturated soil hydraulic properties as influenced by land use management systems in Koohrang region of central Zagros, Iran. **Geoderma**, v. 213, p. 426–434, jan. 2014.
- KIILL, L. H. P. **Bioma Caatinga**. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/bioma-caatinga/introducao>>. Acesso em: 18 jun. 2023.
- KUHN, M.; WING, J.; WILLIAMS, A.; KEEFER, C.; ENGELHARDT, A.; COOPER, T.; MAYER, Z.; KENKEL, B.; R CORE TEAM; BENESTY, M. **Classification and Regression Training**, 10 dez. 2024. Disponível em: <<https://github.com/topepo/caret/>>. Acesso em: 23 jan. 2025
- KUPKOVÁ, L.; ČERVENÁ, L.; POTŮČKOVÁ, M.; LYSÁK, J.; ROUBALOVÁ, M.; HRÁZSKÝ, Z.; BŘEZINA, S.; EPSTEIN, H. E.; MÜLLEROVÁ, J. Towards reliable monitoring of grass species in nature conservation: Evaluation of the potential of UAV and PlanetScope multi-temporal data in the Central European tundra. **Remote Sensing of Environment**, v. 294, p. 113645, 15 ago. 2023.
- LASSABATÈRE, L.; ANGULO-JARAMILLO, R.; SORIA UGALDE, J. M.; CUENCA, R.; BRAUD, I.; HAVERKAMP, R. Beerkan Estimation of Soil Transfer Parameters through Infiltration Experiments—BEST. **Soil Science Society of America Journal**, v. 70, n. 2, p. 521–532, mar. 2006.
- LI, W.; LIU, C.; YANG, Y.; AWAIS, M.; LI, W.; YING, P.; RU, W.; CHEEMA, M. J. M. A UAV-aided prediction system of soil moisture content relying on thermal infrared remote sensing. **International Journal of Environmental Science and Technology**, v. 19, n. 10, p. 9587–9600, 9 out. 2022.
- LIBARDI, P. L. **Dinâmica da Água no Solo**. 3. ed. São Paulo: Edusp, 2018.
- LIU, Q.; WU, Z.; CUI, N.; ZHENG, S.; ZHU, S.; JIANG, S.; WANG, Z.; GONG, D.; WANG, Y.; ZHAO, L. Soil moisture content estimation of drip-irrigated citrus orchard based on UAV images and machine learning algorithm in Southwest China. **Agricultural Water Management**, v. 303, p. 109069, out. 2024.
- LIU, Y.; LIN, J.; YUE, H. Soil respiration estimation in desertified mining areas based on UAV remote sensing and machine learning. **Earth Science Informatics**, v. 16, n. 4, p. 3433–3448, 11 dez. 2023.
- LOZANO-PARRA, J.; PULIDO, M.; LOZANO-FONDÓN, C.; SCHNABEL, S. How do Soil Moisture and Vegetation Covers Influence Soil Temperature in Drylands of Mediterranean Regions? **Water**, v. 10, n. 12, p. 1747, 28 nov. 2018.
- LV, W.; LIU, X.; DING, H. Characteristics, Sources, and Mechanisms of Soil Respiration under Simulated Rainfall in a Native Karst Forest in Southwestern China. **Forests**, v. 15, n. 6, p. 945, 30 maio 2024.
- MAESTRE, F. T.; CORTINA, J. Small-scale spatial variation in soil CO₂ efflux in a Mediterranean semiarid steppe. **Applied Soil Ecology**, v. 23, n. 3, p. 199–209, jul. 2003.
- MARCÉ, R.; OBRADOR, B.; GÓMEZ-GENER, L.; CATALÁN, N.; KOSCHORRECK, M.; ARCE, M. I.; SINGER, G.; SCHILLER, D. VON. Emissions from dry inland waters are a blind spot in the global carbon cycle. **Earth-Science Reviews**, v. 188, p. 240–248, jan. 2019.
- MINASNY, B.; MCBRATNEY, A. B. Estimating the Water Retention Shape Parameter from Sand and Clay Content. **Soil Science Society of America Journal**, v. 71, n. 4, p. 1105–1110, jul. 2007.
- MOUAFIK, M.; MOUNIR, F.; ABOUDI, A. EL. Integrating multi-source remote sensing data and machine learning for predicting tree density and cover in *Argania spinosa*. **Smart Agricultural Technology**, v. 11, p. 100911, ago. 2025.
- MUBARAK, I.; MAILHOL, J. C.; ANGULO-JARAMILLO, R.; RUELLE, P.; BOIVIN, P.; KHALEDIAN, M. Temporal variability in soil hydraulic properties under drip irrigation. **Geoderma**, v. 150, n. 1–2, p. 158–165, abr. 2009.

- NASA. POWER Data Access Viewer. NASA Langley Research Center, 19 abr. 2024. Disponível em: <https://power.larc.nasa.gov/>. Acesso em: 21 abr. 2025.
- OLIVEIRA, F. C. C.; FERREIRA, G. W. D.; SANTOS, R. S.; AUBREY, D. P.; ARAÚJO, E. F.; SILVA, I. R. Soil CO₂ concentration, efflux, and partitioning in a recently afforested grassland. **New Forests**, v. 52, n. 5, p. 737–757, 4 set. 2021.
- ORESCA, D. *et al.* Impact of Conversion of the Caatinga Forest to Different Land Uses on Soil and Root Respiration Dynamics in the Brazilian Semiarid Region. **Sustainability**, v. 16, n. 23, p. 10652, 5 dez. 2024.
- OZALP, M.; ERDOGAN YUKSEL, E.; YUKSEK, T. Soil Property Changes After Conversion from FOrest to Pasture in Mount Sacinka, Artvin, Turkey. **Land Degradation & Development**, v. 27, n. 4, p. 1007–1017, 11 maio 2016.
- PEKEL, J.-F.; COTTAM, A.; GORELICK, N.; BELWARD, A. S. High-resolution mapping of global surface water and its long-term changes. **Nature**, v. 540, n. 7633, p. 418–422, 15 dez. 2016.
- PIERI, C. J. M. G. **Fertility of soils: A future for farming in the West African savannah**. Berlin: [s.n.].
- POTT, C. A.; ZERBIELLI, L. C.; MARTINS, P. J.; GARDIN, E.; GARCIA, M. L. Qualidade física do solo em sistemas florestais, pecuários e integrados de produção. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 10, n. 2, 2017.
- POULOS, M. J.; SMITH, T. J.; BENNER, S. G.; PIERCE, J. L.; FLORES, A. N.; SEYFRIED, M. S.; MCNAMARA, J. P. Topographically moderated soil water seasons impact vegetation dynamics in semiarid mountain catchments: Illustrations from the Dry Creek Experimental Watershed, Idaho, <sc>USA</sc>. **Hydrological Processes**, v. 35, n. 12, 14 dez. 2021.
- RAMOS, M. B.; MACIEL, M. G. R.; CUNHA, S. S. DA; SOUZA, S. M. DE; PEDROSA, K. M.; SOUZA, J. J. L. L. DE; GONZÁLEZ, E. J.; MEAVE, J. A.; LOPES, S. DE F. The role of chronic anthropogenic disturbances in plant community assembly along a water availability gradient in Brazil's semiarid Caatinga region. **Forest Ecology and Management**, v. 538, 15 jun. 2023.
- REYNOLDS, W. D.; DRURY, C. F.; TAN, C. S.; FOX, C. A.; YANG, X. M. Use of indicators and pore volume-function characteristics to quantify soil physical quality. **Geoderma**, v. 152, n. 3–4, p. 252–263, set. 2009.
- REYNOLDS, W. D.; DRURY, C. F.; YANG, X. M.; FOX, C. A.; TAN, C. S.; ZHANG, T. Q. Land management effects on the near-surface physical quality of a clay loam soil. **Soil and Tillage Research**, v. 96, n. 1–2, p. 316–330, out. 2007.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **I OF NATURAL VEGETATION**. [s.l.: s.n.].
- RULEV, A. S.; PUGACHEVA, A. M. Formation of a New Agroforestry Paradigm. **Herald of the Russian Academy of Sciences**, v. 89, n. 5, p. 495–501, 20 set. 2019.
- SANTOS, H. G. DOS. **Sistema brasileiro de classificação de solos**. [s.l.] Embrapa, 2018.
- SANTOS, K. C.; MAGALHÃES, A. L. R.; SILVA, D. K. A. A. G. G. L.; FAGUNDES, G. M.; YBARRA, N. G.; ABDALLA, A. L. Potencial nutricional de espécies forrageiras encontradas no semiárido brasileiro. **Pecuária ciência**, v. 195, p. 118–119, 2017.
- SHAVER, T. M.; PETERSON, G. A.; AHUJA, L. R.; WESTFALL, D. G. Soil sorptivity enhancement with crop residue accumulation in semiarid dryland no-till agroecosystems. **Geoderma**, v. 192, p. 254–258, jan. 2013.
- SILVA, V. S. DA; SALAMI, G.; SILVA, M. I. O. DA; SILVA, E. A.; MONTEIRO JUNIOR, J. J.; ALBA, E. Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. **Geology, Ecology, and Landscapes**, v. 4, n. 2, p. 159–169, 2 abr. 2020.

- SIMÕES, V. P.; SOUZA, E.; LEITE, M. L.; SOUZA, R.; SILVA, J. R.; SALES, A.; TABOSA, J. N.; LIMA, J. R. DE; ANTONINO, A. C. D. **PHYSICAL-HYDRICAL ATTRIBUTES AND CO₂ EFFLUX FROM THE SOIL AS INDICATORS OF ENVIRONMENTAL SUSTAINABILITY IN PASTORAL SYSTEMS IN THE BRAZILIAN SEMI-ARID**, 18 dez. 2020.
- SODANGO, T.; SHA, J.; LI, X.; NOSZCZYK, T.; SHANG, J.; ANESEYEE, A.; BAO, Z. Modeling the Spatial Dynamics of Soil Organic Carbon Using Remotely-Sensed Predictors in Fuzhou City, China. **Remote Sensing**, v. 13, n. 9, p. 1682, 27 abr. 2021.
- SOUZA, E. S.; ANTONINO, A. C. D.; HECK, R. J.; MONTENEGRO, S. M. G. L.; LIMA, J. R. S.; SAMPAIO, E. V. S. B.; ANGULO-JARAMILLO, R.; VAUCLIN, M. Effect of crusting on the physical and hydraulic properties of a soil cropped with Castor beans (*Ricinus communis* L.) in the northeastern region of Brazil. **Soil and Tillage Research**, v. 141, p. 55–61, ago. 2014.
- SOUZA, E. S. DE; ANTONINO, A. C. D.; ANGULO-JARAMILLO, R.; NETTO, A. M. Caracterização hidrodinâmica de solos: aplicação do método Beerkan. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 2, p. 128–135, abr. 2008.
- SOUZA, L. C. DE; FERNANDES, C.; MOITINHO, M. R.; SILVA BICALHO, E. DA; SCALA, N. LA. Soil carbon dioxide emission associated with soil porosity after sugarcane field reform. **Mitigation and Adaptation Strategies for Global Change**, v. 24, n. 1, p. 113–127, 21 jan. 2019.
- SUKHOVEEVA, O.; KARELIN, D.; LEBEDEVA, T.; POCHIKALOV, A.; RYZHKOV, O.; SUVOROV, G.; ZOLOTUKHIN, A. Greenhouse gases fluxes and carbon cycle in agroecosystems under humid continental climate conditions. **Agriculture, Ecosystems & Environment**, v. 352, p. 108502, 15 ago. 2023.
- SUN, F.; LÜ, Y.; FU, B.; MA, Z.; YAO, X. Spatial explicit soil moisture analysis: pattern and its stability at small catchment scale in the loess hilly region of China. **Hydrological Processes**, v. 28, n. 13, p. 4091–4109, 30 jun. 2014.
- TOPP, G. C.; REYNOLDS, W. D.; COOK, F. J.; KIRBY, J. M.; CARTER, M. R. Chapter 2 Physical attributes of soil quality. *Em*: [s.l: s.n.]. p. 21–58.
- WATSON, K. W.; LUXMOORE, R. J. **Estimating Macroporosity in a Forest Watershed by use of a Tension Infiltrimeter 1**. [s.l: s.n.].
- ZHENG, H.; LI, W.; JIANG, J.; LIU, Y.; CHENG, T.; TIAN, Y.; ZHU, Y.; CAO, W.; ZHANG, Y.; YAO, X. A Comparative Assessment of Different Modeling Algorithms for Estimating Leaf Nitrogen Content in Winter Wheat Using Multispectral Images from an Unmanned Aerial Vehicle. **Remote Sensing**, v. 10, n. 12, p. 2026, 13 dez. 2018.