

**UNIVERSIDADE FEDERAL DE VIÇOSA**

**Modelagem da produção da palma de óleo sob condições atípicas de precipitação**

Pedro Arthur de Azevedo Silva  
*Doctor Scientiae*

**VIÇOSA - MINAS GERAIS  
2025**

**PEDRO ARTHUR DE AZEVEDO SILVA**

**Modelagem da produção da palma de óleo sob condições atípicas de precipitação**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Doctor Scientiae*.

Orientadora: Hewlley M. A. Imbuzeiro

Coorientadores: Santiago Vianna Cuadra  
Victor Hugo Benezoli

**VIÇOSA - MINAS GERAIS  
2025**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

S586m  
2025  
Silva, Pedro Arthur de Azevedo, 1991-  
Modelagem da produção da palma de óleo sob condições  
atípicas de precipitação / Pedro Arthur de Azevedo Silva. –  
Viçosa, MG, 2025.

1 tese eletrônica (125 f.): il. (algumas color.).

Orientador: Hewlley Maria Acioli Imbuzeiro.

Tese (doutorado) - Universidade Federal de Viçosa,  
Departamento de Engenharia Agrícola, 2025.

Referências bibliográficas: f. 104-125.

DOI: <https://doi.org/10.47328/ufvbbt.2025.283>

Modo de acesso: World Wide Web.

1. *Elaeis guineensis*. 2. Plantas - Relações hídricas -  
Modelos matemáticos. 3. Aprendizado do computador.  
4. Precipitação (Meteorologia) - Variabilidade. I. Imbuzeiro,  
Hewlley Maria Acioli, 1980-. II. Universidade Federal de  
Viçosa. Departamento de Engenharia Agrícola. Programa de  
Pós-Graduação em Meteorologia Aplicada. III. Título.

CDD 22. ed. 633.851

**PEDRO ARTHUR DE AZEVEDO SILVA**

**Modelagem da produção da palma de óleo sob condições atípicas de precipitação**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Doctor Scientiae*.

APROVADA: 28 de fevereiro de 2025.

Assentimento:

---

Pedro Arthur de Azevedo Silva  
Autor

---

Hewlley Maria Acioli Imbuzeiro  
Orientadora

Essa tese foi assinada digitalmente pelo autor em 13/05/2025 às 17:42:49 e pela orientadora em 19/05/2025 às 08:59:40. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **C8PX.UE7Z.DSAP** e clique no botão 'Validar documento'.

## AGRADECIMENTOS

Agradeço aos meus familiares, minha mãe Eva Geralda, meu pai Jaques José, minha irmã Mariana, meu padrinho Eliomar e minha companheira Ludmilla por todo auxílio, paciência, acolhimento e companheirismo incondicionais.

Aos meus amigos Adriane Duarte, Carlos Machado, Gabriel Peterle, Leandro Campos, Vinícius Augusto, dentre tantos outros que permaneceram ao meu lado, construindo e compartilhando momentos únicos.

Expresso agradecimento especial à Karen Caroline Acerbi Garcia (*in memoriam*), uma amiga ímpar que sempre me apoiou, motivou e comemorou cada vitória pessoal e acadêmica até o início da minha jornada rumo aos frutos deste presente trabalho.

À orientadora Dra. Hewlley M. A. Imbuzeiro e coorientadores, Dr. Santiago V. Cuadra e Dr. Victor H. Benezoli, pela orientação, paciência e disposição para ajudar, mas também pela amizade e por acreditar em minha capacidade acadêmica, sempre estimulando meu crescimento pessoal e profissional.

A todos os colegas do grupo MICROMET e demais integrantes e docentes do POSMET, sempre presentes em momentos de dúvidas e responsáveis pelo meu encanto pelo meio acadêmico.

A todos os funcionários da Universidade Federal de Viçosa por sua contribuição diária para o funcionamento e desenvolvimento da instituição e, em especial, à Graça Freitas, sempre nos acolhendo com ternura e prestando total apoio demonstrando empatia incomparável.

À Universidade Federal de Viçosa, especialmente ao Departamento de Engenharia Agrícola, pela oportunidade de realizar a pós-graduação.

À toda equipe da Agropalma, ao Dr. Gilson S. Chia e à Dra. Raiza M. Faria pelo apoio técnico na aquisição e fornecimento dos dados necessários.

Este trabalho foi realizado com o apoio das seguintes agências de pesquisa brasileiras: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

*“A natureza é a fonte de todo conhecimento verdadeiro.  
Tem a sua própria lógica, as suas próprias leis, não tem  
efeito sem causa nem invenção sem necessidade”.*

(Leonardo da Vinci)

## RESUMO

SILVA, Pedro Arthur de Azevedo, D.Sc., Universidade Federal de Viçosa, fevereiro de 2025. **Modelagem da produção da palma de óleo sob condições atípicas de precipitação**. Orientadora: Hewlley Maria Acioli Imbuzeiro. Coorientadores: Santiago Vianna Cuadra e Victor Hugo Benezoli.

As mudanças climáticas já afetam a produção agrícola e, caso seus efeitos sejam intensificados no futuro, a elevação da temperatura e escassez hídrica podem tornar regiões inteiras inaptas para cultivos ou, caso ainda sejam parcialmente aptas, isso pode se traduzir em aumento do custo de produção. A palma de óleo se tornou foco de preocupação ao considerar sua sensibilidade à disponibilidade hídrica, resultando em baixas expressivas na produção, pela irregularidade do fornecimento hídrico. Diante do desafio de monitorar e proteger a produção agrícola, técnicas de modelagem agrícola podem colaborar com a definição de um manejo preventivo mais eficiente, garantindo a produção esperada. O principal objetivo deste estudo foi avaliar como ocorrências atípicas nos padrões de precipitação podem influenciar na produção total esperada da palma de óleo. Foram obtidos dados de clima, solo e produção a partir de observações realizadas na propriedade Agropalma, situada no estado do Pará, Brasil. Os dados de clima e solo foram utilizados como entradas dos modelos, enquanto a produção dos talhões de palma de óleo foi utilizada nas etapas de treinamento, teste e validação dos modelos. Dois modelos foram utilizados para o estudo, sendo o primeiro o modelo ECOSMOS-Palm que é um modelo biofísico baseado em processos, e o segundo foi uma rede neural artificial, que é um modelo inspirado no funcionamento sináptico do sistema nervoso biológico. As simulações realizadas por meio da modelagem baseada em processos se mostraram mais adequadas para a realização deste estudo, obtendo resultados consistentes e mais precisos considerando os dados observados em campo. A maioria das simulações realizadas indicaram redução da produção da palma de óleo, entretanto, as penalidades produtivas se destacaram nas condições de redução do total precipitado, onde foi possível observar reduções mais intensas na produção estimada, se comparadas às simulações para as condições de aumento ou distribuição da precipitação. Apenas as simulações considerando o atraso na ocorrência da estação chuvosa registraram o aumento da produtividade da palma de óleo, o que foi associado à sua ocorrência durante os meses mais quentes e originalmente mais secos. Os resultados demonstraram como o fornecimento hídrico complementar em períodos críticos de redução de chuvas, associada a maior disponibilidade energética em condições

ótimas, tem considerável potencial em elevar a produção esperada. Há um consenso literário quanto a irrigação ser o principal método para mitigar os efeitos das mudanças climáticas nos cultivos agrícolas, contudo, é um método que deve ser utilizado preferencialmente englobando diferentes vertentes do meio agrícola-ambiental, partindo de um manejo integrando a interface solo-água-vegetação-atmosfera. Demonstrou-se como a integração dos dados de campo em um modelo biodinâmico é capaz de simular precisamente a produção esperada da palma de óleo, apresentando grande potencial em apoiar gestores agrícolas no planejamento, definição, aplicação e avaliação de ações preventivas mitigadores dos efeitos das mudanças climáticas.

Palavras-chave: *Elaeis guineensis* Jacq.; Modelo ECOSMOS; Aprendizado de máquina

## ABSTRACT

SILVA, Pedro Arthur de Azevedo, D.Sc., Universidade Federal de Viçosa, February, 2025. **Modeling of oil palm yield under atypical precipitation conditions.** Adviser: Hewlley Maria Acioli Imbuzeiro. Co-advisers: Santiago Vianna Cuadra and Victor Hugo Benezoli.

Climate change is already affecting agricultural production, and if its effects intensify in the future, rising temperatures and water shortages could make entire regions unsuitable for cultivation or, if they are still partially suitable, this could translate into increased production costs. Oil palm has become a focus of concern due to its sensitivity to water availability, in which its production can suffer significant declines due to irregular water supplies. Faced with the challenge of monitoring and protecting agricultural production, agricultural modeling techniques can help define more efficient preventive management, ensuring expected production. The main objective of this study was to evaluate how atypical occurrences in precipitation patterns can influence the total expected oil palm production. Climate, soil and yield data were obtained from observations made at the Agropalma property, located in the state of Pará, Brazil. Climate and soil data were used as inputs for the models, while the yield of the oil palm plots was used in the training, testing and validation stages of the models. Two models were used for the study, the first being the ECOSMOS-Palm model, a process-based biophysical model, and the second one is an artificial neural network, which is a model inspired by the synaptic functioning of the biological nervous system. The simulations performed through process-based modeling proved to be more suitable for carrying out this study, obtaining consistent and more accurate results considering the data observed in the field. Most of the simulations performed indicated a reduction in palm oil production, from a more homogeneous distribution of precipitation to changes in total precipitation. The yield penalties stood out in the reduction of total precipitation, which is expected for the study region, where even the smallest rate of significant reduction was higher than the modified conditions for increased precipitation or distribution homogenization. Only the simulations considering the delay in the occurrence of the rainy season recorded an increase in palm productivity, which was associated with its occurrence during the warmer and originally drier months. The results demonstrated how the supply of supplementary water during critical periods of reduced rainfall, and associated with greater availability of energy under optimal conditions, has considerable potential to increase expected yields. There is consensus in the literature that irrigation is the main method to mitigate

the effects of climate change on agricultural crops, as long as it is used preferentially covering different aspects of the agriculture-environment interactions, basing on a soil-water-vegetation-atmosphere integrated management. It was demonstrated how the integration of field data into a biodynamic model is capable of accurately simulating expected oil palm production, presenting great potential to support agricultural managers in the planning, definition, application and evaluation of preventive actions to mitigate the effects of climate change.

Keywords: *Elaeis guineensis* Jacq.; ECOSMOS model; Machine learning

## LISTA DE ILUSTRAÇÕES

- Figura 1 – Mapa da região de estudo com enfoque na delimitação das fazendas e seus respectivos talhões pertencentes à Agropalma. .... 39
- Figura 2 – Fluxograma com as etapas do processo de análise de consistência e preenchimento do banco de dados climáticos..... 43
- Figura 3 – Gráfico da umidade relativa registrada pela na estação AGP. As faixas em tonalidade vermelha indicam períodos com aparente falha contínua do sensor..... 44
- Figura 4 – Mapa da classificação do solos e pontos de coleta amostral dos solos realizada na propriedade Agropalma. .... 46
- Figura 5 – Representação do processo de reclassificação dos talhões, com base no critério duplo de tipo de solo e área de influência das estações meteorológicas instaladas na propriedade da Agropalma. .... 49
- Figura 6 – Representação da estrutura hierárquica do modelo Agro-IBIS..... 51
- Figura 7 – Representação da estrutura de um neurônio artificial simples empregado em técnicas de Redes Neurais Artificiais. .... 56
- Figura 8 – Esquema estrutural de uma Rede Neural em topologia tipo *perceptron* em multicamadas com duas camadas ocultas em configuração *feedforward*. .... 58
- Figura 9 – Fluxo de processamento entre camadas da rede neural artificial de entradas múltiplas, utilizada para converter os dados de clima e solo em dados de produtividade. .... 59
- Figura 10 – ICP's calculados com base na precipitação registrada pelas estações meteorológicas instaladas na propriedade Agropalma. .... 68
- Figura 11 – Gráficos de anomalias acumuladas da precipitação para os anos registrados pelas estações meteorológicas instaladas na propriedade Agropalma. Para cada ano, os pontos vermelhos indicam o momento de início da estação seca, enquanto os pontos azuis indicam o momento de início da estação chuvosa. .... 69
- Figura 12 – Distribuição mensal e sazonal da precipitação na região da Agropalma. As barras azuis indicam a precipitação nos meses pertencentes ao período chuvoso, enquanto as barras vermelhas indicam a precipitação nos meses pertencentes ao período seco. .... 71
- Figura 13 – Distribuição relativa sazonal dos dias com precipitação e precipitação total acumulada na região da Agropalma..... 72
- Figura 14 – Dados de produtividade observada (t/ha) da palma de óleo, consolidados mensalmente para cada fazenda da Agropalma. .... 75

Figura 15 – Dados de produtividade geral (t/ha) da Agropalma, consolidados por ano e por fazenda, organizadas em ordem crescente do ano de implementação. ....	76
Figura 16 – Produtividade da palma de óleo, por idade, estimados pelos modelos ECOSMOS- <i>Palm</i> , em azul, e pela RNA, em vermelho.....	77
Figura 17 - Métricas de precisão e erro calculadas a partir dos valores de produtividade (t/ha) observados em campo e simulados pelos modelos para a palma de óleo. ....	78
Figura 18 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de distribuição ICP10. ....	86
Figura 19 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando a modificação da distribuição anual da precipitação. ....	87
Figura 20 - Balanço hídrico para a série de dados de precipitação original e para a condições de mudança na precipitação, considerando a distribuição ICP10.....	88
Figura 21 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de defasagem D+2, D+3, D+4, D+5 e D+6.....	89
Figura 22 – Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando as defasagens temporais D+2, D+3, D+4, D+5 e D+6. ....	90
Figura 23 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando as modificações na defasagem temporal da precipitação. ....	91
Figura 24 – Assinaturas anuais de temperatura e radiação solar incidente para a região da propriedade da Agropalma.....	92
Figura 25 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de total T-70, T-80, T-90 e T-100. ....	93
Figura 26 - Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando as reduções no total precipitado T-70, T-80, T-90 e T-100. ....	94
Figura 27 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando as modificações na redução do total da precipitação anual. ....	95
Figura 28 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de total T+100. ....	96
Figura 29 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando a modificação do aumento no total da precipitação anual. ....	97

Figura 30 - Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando aumento no total precipitado t+100..... 98

## LISTA DE TABELAS

Tabela 1 – Detalhamento dos talhões produtivos inseridos em cada fazenda da propriedade Agropalma.....	40
Tabela 2 – Dados posicionais das estações meteorológicas instaladas dentro da propriedade da Agropalma.....	41
Tabela 3 – Descrição dos dados disponibilizados pelo conjunto <i>Brazilian Daily Weather Gridded Data</i> . ....	42
Tabela 4 – Lista de identificação para todas as simulações realizadas considerando as condições únicas observadas em campo. ....	50
Tabela 5 – Descrição dos parâmetros modificados para aplicação do modelo ECOSMOS- <i>Palm</i> . ....	54
Tabela 6 – Classificação da distribuição do total precipitado em relação aos valores de ICP.....	62
Tabela 7 – Síntese das datas extraídas a partir da definição dos momentos de mudança de estação, apontados pela análise de anomalia acumulada. ....	70
Tabela 8 – Síntese dos dados granulométricos e de classificação do solo das áreas amostradas na Agropalma. ....	74
Tabela 9 - Resultados obtidos a partir dos testes de normalidade de Shapiro-Wilk, da análise de variância de Kruskal-Wallis e do teste <i>post-hoc</i> de Dunn para comparação entre a produção observada e a produção estimada pelos modelos ECOSMOS e RNA. ....	79
Tabela 10 – Resultados obtidos a partir do teste de normalidade de Shapiro-Wilk para os conjuntos de dados de produção observados e simulados, considerando as condições de mudança na distribuição e defasagem temporal da precipitação. ....	80
Tabela 11 – Resultados obtidos a partir do teste de normalidade de Shapiro-Wilk para os conjuntos de dados de produção observados e simulados, considerando as condições de mudança no total da precipitação. ....	81
Tabela 12 – Resultados obtidos a partir da análise de variância de Kruskal-Wallis, considerando as condições de mudança na distribuição, defasagem temporal e do total precipitado.....	82
Tabela 13 – Resultados obtidos a partir do teste <i>post-hoc</i> de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações na distribuição da precipitação.....	83
Tabela 14 – Resultados obtidos a partir do teste <i>post-hoc</i> de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações na defasagem temporal da precipitação. ....	84

Tabela 15 – Resultados obtidos a partir do teste *post-hoc* de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações no total anual da precipitação. .... 85

## LISTA DE SIGLAS E ABREVIATURAS

ANA	Agência Nacional de Águas
ANOVA	<i>Analysis Of Variance</i> / Análise De Variância
BHC	Balanço Hídrico Climatológico
BR-DWGD	<i>Brazilian Daily Weather Gridded Data</i>
ECOSMOS	<i>Ecosystem Model Simulator</i> / Modelo Simulador de Ecossistema
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ENSO	<i>El Niño-Southern Oscillation</i> / El Niño-Oscilação do Sul
IBIS	<i>Integrated Biosphere Simulator</i> / Simulador Integrado da Biosfera
ICP	Índice de Concentração da Precipitação
INMET	Instituto Nacional de Meteorologia
IPCC	<i>Intergovernmental Panel on Climate Change</i> / Painel Intergovernamental sobre Mudanças Climáticas
LI	Linhas de Instabilidade
MRGTA	Microrregião de Tomé-Açu
NEE	<i>Net Ecosystem Exchange</i> / Troca líquida de CO <sub>2</sub> no ecossistema
N-NE	Norte-Nordeste
NPP	<i>Net Primary Productivity</i> / Produtividade primária líquida
PFT	<i>Plant Functional Type</i> / Tipos Funcionais de Plantas
PTF	<i>Pedotransfer Functions</i> / Funções de Pedotransferência
ReLU	<i>Rectified Linear Unit</i>
RMSE	<i>Root Mean Squared Error</i> / Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial
SiBCS	Sistema Brasileiro de Classificação de Solos
VPD	<i>Vapor Pressure Deficit</i> / Déficit de Pressão de Vapor
ZCIT	Zona de Convergência Intertropical

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	17
<b>2. REVISÃO DE LITERATURA</b> .....	21
2.1. Modelos baseados em processos .....	21
2.2. Modelos de aprendizado de máquina .....	23
2.3. Precisão dos modelos em suas aplicações .....	24
2.4. Aplicações em relação ao agroecossistema .....	25
2.4.1. Condições atmosféricas.....	26
2.4.2. Influência das propriedades do solo.....	30
2.4.3. Relação com os recursos hídricos .....	32
2.4.4. Impactos da modelagem no aspecto socioecômico .....	34
2.5. Considerações sobre a revisão.....	38
<b>3. MATERIAL E MÉTODOS</b> .....	39
3.1. Área de estudo.....	39
3.2. Banco de dados .....	41
3.2.1. Dados climáticos.....	41
3.2.2. Dados de produção e do solo .....	45
3.2.3. Pré-processamento dos dados para as simulações .....	48
3.3. Modelos .....	50
3.3.1. ECOSMOS - <i>Palm</i> .....	50
3.3.2. Rede Neural Artificial .....	55
3.4. Análise de sensibilidade.....	61
3.5. Análises estatísticas.....	64
3.5.1. Comparação entre modelos .....	64
3.5.2. Identificação das mudanças significativas da estação chuvosa .....	65
<b>4. RESULTADOS E DISCUSSÃO</b> .....	68
4.1. Reconhecimento da área de estudo.....	68
4.1.1. Caracterização da precipitação.....	68
4.1.2. Características do solo .....	72
4.1.3. Produção da palma de óleo .....	74
4.2. Escolha do modelo para simulações.....	77
4.3. Simulações das condições atípicas de estação chuvosa .....	80
4.3.1. Teste de normalidade .....	80
4.3.2. Análise de variância.....	82

4.3.3. Testes <i>post-hoc</i> de Dunn .....	82
4.3.4. Distribuição anual .....	85
4.3.4. Defasagem temporal.....	88
4.3.4. Total precipitado .....	93
4.4. Perspectivas futuras para a região em relação as simulações .....	99
<b>5. CONCLUSÕES</b> .....	103
<b>REFERÊNCIAS</b> .....	104

## 1. INTRODUÇÃO

A segurança alimentar é uma preocupação crescente e presente em escala global, especialmente ao avaliar estudos preditivos focados nas mudanças climáticas. A necessidade de atender a demanda do setor alimentício em decorrência das projeções do aumento populacional e das instabilidades climáticas, tem elevado a tensão sobre os pesquisadores e profissionais técnicos na busca de formas para amenizar seus impactos na disponibilidade de recursos naturais e, conseqüentemente, evitar possíveis colapsos socioeconômicos (KELLY-YONG et al., 2007; RAY et al., 2019; REYNOLDS et al., 2015; SAGAR et al., 2019; TABI; MUKI, 2009).

De modo geral, as mudanças previstas no clima podem tornar regiões inviáveis para os principais cultivos utilizados tanto no abastecimento local, quanto para o comércio mundial. Desde mudanças mais diretas, como o aumento da temperatura, até mudanças mais indiretas, como a recarga hídrica do solo sendo influenciada por alterações sutis no período chuvoso, apresentam potencial de impactar drasticamente nas características agronômicas de uma região, exibindo enorme potencial de promover a instabilidade das políticas agrícolas locais (KELLY-YONG et al., 2007; RAY et al., 2019; SAGAR et al., 2019).

Entre as diferentes culturas agrícolas sob preocupação e atenção dos pesquisadores em relação as mudanças climáticas, a palma de óleo (*Elaeis guineensis* Jacq.) tem se destacado considerando as alterações nas estações chuvosas. A palma de óleo, uma das culturas mais importantes do mundo, tem maior parte de sua produção mundial concentrada no sudeste asiático e representa pelo menos 30% do consumo total mundial de óleo vegetal, demonstrando elevada relevância no setor alimentício e energético (BENEZOLI et al., 2021; HASHEMVAND KHIABANI; TAKEUCHI, 2020; HUTH et al., 2014; MONTEIRO DE CARVALHO et al., 2015; TENG et al., 2015; XU et al., 2021).

A palma de óleo, uma palmeira originária da Costa Ocidental da África (Golfo da Guiné), é uma cultura perene de produção contínua partir do terceiro ano de plantio, possui ciclo produtivo de aproximadamente 30 anos e é cultivada em diferentes regiões das latitudes inseridas na faixa tropical (CORLEY; TINKER, 2015; KELLY-YONG et al., 2007). No Brasil, sua produção se concentra na região

norte do país e, apesar de não apresentar uma produção tão expressiva em relação a produção mundial, seu setor produtivo nacional vem crescendo a cada ano, especialmente pela implementação de programas governamentais de incentivo à produção e extração de óleo vegetal (BENEZOLI et al., 2021; MONTEIRO DE CARVALHO et al., 2015).

Além do óleo vegetal, diferentes subprodutos podem ser derivados a partir de outros constituintes da cultura, como detergentes processados a partir do caroço, cosméticos, fármacos e até sua própria biomassa em geral, que apresenta considerável valor agregado em subprocessos industriais (CHONG et al., 2017; HASHEMVAND KHIABANI; TAKEUCHI, 2020; KELLY-YONG et al., 2007; POHL; LOONG, 2016; SAGAR et al., 2019; TENG et al., 2015). Observando a capacidade de alto aproveitamento da palma de óleo, torna-se notável sua versatilidade em atender diferentes níveis de demandas produtivas, reforçando seu importante papel no desenvolvimento econômico regional (BENEZOLI et al., 2021; CHONG et al., 2017; CORLEY; TINKER, 2015; HOFFMANN et al., 2014; HUTH et al., 2014; LI et al., 2015; RÖLL et al., 2015; XU et al., 2021).

A principal preocupação quanto a resposta produtiva da palma de óleo em relação às mudanças climáticas, se justifica principalmente ao considerar sua sensibilidade à disponibilidade hídrica ao longo do seu ciclo produtivo, onde estudos demonstram que chuvas fora da média histórica, tanto acima quanto abaixo, reduzem significativamente a média de produção (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; COCK et al., 2016; SAGAR et al., 2019). A palma de óleo é uma cultura com alta demanda hídrica, necessitando de aproximadamente 2000 milímetros por ano (mm/ano), porém, alguns autores chamam atenção para a distribuição da precipitação, que pode ser um fator ainda mais determinante se comparado ao total precipitado, uma vez que a sua região típica de cultivo é a faixa tropical, especialmente em regiões equatoriais, onde a precipitação anual se caracteriza por uma distribuição relativamente uniforme devido à atuação da Zona de Convergência Intertropical (ZCIT), com baixa incidência de dias consecutivos sem chuvas mesmo em períodos mais secos (BENEZOLI et al., 2021; CHONG et al., 2017; COCK et al., 2016; HOFFMANN et al., 2014; RÖLL et al., 2015; SAGAR et al., 2019).

Diversos estudos demonstram que a produção da palma de óleo pode sofrer baixas expressivas pela irregularidade do fornecimento hídrico, pois ocasionam a redução da proporção entre flores femininas e masculinas em sua inflorescência. Tal efeito impacta diretamente no número de frutos gerados e, em menor intensidade, nos pesos dos frutos que ainda assim conseguem ser formados (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; BENEZOLI et al., 2021; COMBRES et al., 2013; RÖLL et al., 2015).

Devido sua característica de produção contínua, em que as suas folhas passam por um processo de diferenciação até desenvolverem estruturas reprodutivas ao longo dos meses, todo distúrbio ocorrido desde sua formação até sua total diferenciação pode influenciar na produção obtida, como pode ser verificado em estudos que registraram produção reduzida como reflexos de estresses ocorridos até 29 meses antes da colheita (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; COCK et al., 2016; SAGAR et al., 2019; TABI; MUKI, 2009).

Estudos focados no monitoramento da palma de óleo, trazem a discussão quanto à importância de tentar descrever e prever como as condições climáticas podem afetar a palma de óleo, permitindo que os produtores possam intervir em tempo hábil, visando mitigar possíveis perdas na produção esperada e melhor se posicionarem comercialmente (HOFFMANN et al., 2014; POHL; LOONG, 2016). Técnicas de aprendizado de máquina e modelos dinâmicos se mostram como poderosas ferramentas em contrastar uma relação da produção da palma de óleo com o clima, entretanto, a resposta direta de sua produção em relação as alterações do padrão de ocorrência da estação chuvosa, ainda não foi amplamente explorada (HUTH et al., 2014; XU et al., 2021).

Técnicas de aprendizado de máquina têm sido propostas como ferramentas promissoras para obtenção de estimativas e previsões de safra em diferentes culturas, especialmente por sua característica de identificação de padrões e generalização da estimativa de eventos observados, o que contribui consideravelmente para sistemas automatizados com alimentação dinâmica de banco dados (CHONG et al., 2017; XU et al., 2021). Por outro lado, o uso de modelos dinâmicos de superfície e ecossistema também se mostram adequados para estimar o desenvolvimento e a produção da palma de óleo, pois consideram

as diferentes formas de interações entre variáveis agronômicas e climáticas de modo determinístico, permitindo uma melhor avaliação da sensibilidade de resposta da cultura às mudanças ambientais e manejo, contribuindo de forma positiva na acurácia das estimativas de produtividade (BENEZOLI et al., 2021; COCK et al., 2016; COMBRES et al., 2013; FAN et al., 2015; HOFFMANN et al., 2014; HUTH et al., 2014; VAN KRAALINGEN; BREURE; SPITTERS, 1989).

Diante do desafio de realizar o devido monitoramento e previsão acurada da produção agrícola, modelos que produzem simulações, estimativas e previsões em cenários específicos, porém plausíveis, podem colaborar com a definição de um manejo mais adequado e eficiente, visando garantir a produção esperada (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; HUTH et al., 2014; TABI; MUKI, 2009). Utilizar modelos computacionais para verificar os impactos dessas mudanças esperadas na produção da palma de óleo é de elevada importância comercial, uma vez que o setor produtivo pode melhor se preparar no estabelecimento de acordos comerciais desde estádios iniciais do desenvolvimento da cultura (COCK et al., 2016; HUTH et al., 2014; LI et al., 2015; RAY et al., 2019).

Explorar como integrar dados climáticos em um sistema automatizado de processamento, convertendo-os diretamente em produção esperada da palma de óleo, e estabelecendo um método de monitoramento prático, dinâmico e acessível, pode apoiar não apenas no escalonamento da produção em nível de propriedade, mas também na estruturação de políticas de produção e comercialização mais adequadas para a cultura, o que é essencial para o devido estabelecimento de subsídios agrícolas. De forma alinhada ao panorama apresentado, o presente estudo teve o objetivo de avaliar a aplicabilidade da modelagem agrometeorológica para determinar como ocorrências atípicas nos padrões de precipitação podem influenciar na produção esperada da palma de óleo e, por meio de análise de sensibilidade, destacar os limiares que implicarem em alteração significativa da produção esperada.

## **2. REVISÃO DE LITERATURA**

Descrever e modelar um ecossistema complexo como o sistema agrícola ainda é um desafio para os pesquisadores que buscam entender como a implementação, condução e expansão da palma de óleo impacta dinamicamente no domínio espaço-temporal das características regionais dos polos produtivos (PIRKER et al., 2016; TENG et al., 2015; XIN; SUN; HANSEN, 2021). Para que tais objetivos sejam alcançados, é indispensável que o sistema agrícola seja compreendido em suas diferentes vertentes, e que seja descrito como suas características bióticas e abióticas podem interagir entre si (PARDON et al., 2016; PEREZ et al., 2016; VIJAY et al., 2018).

Diferentes técnicas de modelagem podem auxiliar os produtores nas etapas de planejamento, implementação e condução do cultivo, pois possibilitam simular o desenvolvimento da cultura, prever sua produção total e suas perdas esperadas, além de identificar potenciais fatores causadores de prejuízos, fornecendo assim, relatórios que podem auxiliar na otimização de manejo, estimulando uma produção mais sustentável, por meio de um sistema específico de orientação para tomada de decisão (CHAPMAN et al., 2018; CULMAN et al., 2019; MANOLI et al., 2018; PARDON et al., 2017; RIVAL, 2017).

Essa revisão buscou entender e sumarizar o uso da modelagem baseada em processos, e por aprendizado de máquina, que se mostram inclinados ao avanço da fronteira tecnológica no âmbito dos sistemas de produção da palma de óleo. Aqui se destacam as aplicações da modelagem nos componentes principais do agroecossistema, com foco para os conhecimentos gerados nos últimos anos e, conseqüentemente, transferidos a comunidade, resultando no desenvolvimento da cadeia produtiva.

### **2.1. Modelos baseados em processos**

Os modelos baseados em processos são compostos por um conjunto de equações que descrevem, de forma determinística, os processos em sistemas complexos a partir da definição prévia das interações atuantes nas diferentes

componentes do sistema, explicitando dinamicamente suas relações de causa e efeito (FAN et al., 2015; IBRAGIMOV; SIDIQUE; TEY, 2019). Esses modelos são amplamente utilizados em estudos que envolvem simular sistemas ambientais ou sistemas agrícolas e, nesses casos, apesar de cada modelo existente apresentar seu próprio fluxo de processamento único, eles costumam apresentar uma lógica central comum.

Usualmente, o fluxo de processamento desses modelos se inicia com entradas de forçantes atmosféricas abastecendo um módulo que simula os processos da superfície terrestre, incluindo estimativas de balanço de massa, balanço de energia, física do solo e fisiologia da cobertura vegetal. A partir dessa etapa, as informações podem ser propagadas para módulos de processos mais específicos, a depender do modelo, que pode ser um módulo responsável por simular a dinâmica da vegetação, ou um módulo para processos biogeoquímicos, ou até mesmo um módulo para simulação de práticas do manejo agrícola (BENEZOLI et al., 2021; BERINGER et al., 2023; FAN et al., 2019; MANOLI et al., 2018; MEIJIDE et al., 2017; XU et al., 2020).

Esses modelos permitem estimar os efeitos diretos das variações das forçantes meteorológicas nos sistemas, simulando processos biogeoquímicos na componente do solo e calculando o particionamento dos fluxos de massa e energia, o que permite prever o crescimento e desenvolvimento vegetal, além da produção em casos de culturas agrícolas. Tais aplicações tem grande potencial em apoiar produtores na implementação de novas áreas de cultivo e orientar melhores formas de conduzir áreas já estabelecidas, a partir de avaliações sobre a adequabilidade local, e a partir de simulações quanto aos impactos das práticas agrícolas no agroecossistema matriz (BENEZOLI et al., 2021; CHAPMAN et al., 2018; CULMAN et al., 2019; FAN et al., 2015; HUTH et al., 2014; MEIJIDE et al., 2017; PARDON et al., 2017; PEREZ et al., 2016; SWAILS et al., 2022).

Apesar de serem modelos que, após parametrização, tendem a apresentar uma baixa variabilidade dada sua natureza determinística, essa classe de modelos pode apresentar limitações em relação a disponibilidade de informações. Essa limitação é destacada na literatura, pois esse tipo de modelo depende de uma grande quantidade de dados sobre o estado do sistema observado, além da necessidade de parâmetros, que nem sempre estão disponíveis, e o processo de

obtenção desses parâmetros tende a ser demorado e/ou financeiramente caro (CHAPMAN et al., 2018; EULER et al., 2016; HOFFMANN et al., 2014; PARDON et al., 2016).

## 2.2. Modelos de aprendizado de máquina

Modelos de aprendizado de máquina são amplamente conhecidos pela sua capacidade de aprender com os próprios dados de entrada, reconhecer seus padrões, suas relações e, de forma quase autônoma, realizar os ajustes necessários para minimizar seus erros de estimativas e aproximar funções complexas (LI et al., 2019; MOHD NAJIB et al., 2020). Existem diversos modelos e técnicas baseados no conceito do aprendizado de máquina, contudo, três tipos principais foram os mais encontrados na literatura, considerando as versões base e suas variantes, sendo eles as máquinas de vetores de suporte, as árvores de decisão / floresta aleatória e a rede neural artificial, sendo o último um dos focos desse estudo.

As redes neurais artificiais são amplamente conhecidas por ter seu funcionamento diretamente baseado no comportamento do neurônio biológico, aqui denominado como *perceptron*, o qual recebe sinais de entrada que são ponderados por pesos numéricos e propagados até uma junção somatória, que soma todos os sinais recebidos e envia pra uma função de ativação e, a depender se o valor recebido atingiu o limiar de ativação, propaga o sinal. A rede neural artificial é estruturada quando esses *perceptrons* são interligados e organizados em camadas, sendo a camada de entrada a que recebe os dados de entrada e fazem um primeiro processamento das informações, as camadas ocultas são as que realizam as interações cruzadas entre os diferentes *perceptrons* da camada anterior, e a camada de saída realiza a última etapa de processamento, geralmente aplicando alguma transformação e resultando na saída do modelo (CHAPMAN et al., 2018; JARAYEE et al., 2022; KHALED et al., 2018; KHALID; SHAHROL, 2022; KHAN et al., 2022; LI et al., 2016; RUSLAN et al., 2019).

A principal vantagem associada as diferentes técnicas de aprendizado de máquina, é que os modelos são capazes de aproximar e ajustar a qualquer sistema

apresentado, linear ou não, desde que exista uma relação considerável entre as variáveis de entrada e de saída. Essa característica é considerada extremamente relevante para aplicações em sistemas agrícolas, pois é um cenário onde esses modelos tem elevada confiabilidade em prever padrões climáticos, identificar ocorrência de espécies, determinar plano de irrigação, estimar teor nutricional no solo, além da ocorrência de pragas e intensidade de doenças, entre outras aplicações que modelos mais clássicos apresentam dificuldade em representar (AKHTAR et al., 2023; CHUNGCHAROEN et al., 2022; EZZATZADEGAN et al., 2021; JARAYEE et al., 2022; KHALED et al., 2018; KIPLI et al., 2023; LI et al., 2015, 2019; OKORO et al., 2016; RIZEEI et al., 2018; XU et al., 2021).

Independentemente do método, as principais limitações das técnicas de aprendizado de máquina estão relacionadas aos dados de entrada, como casos em que se utilizam dados de baixa qualidade, dados não representativos ao conjunto amostral, dados relacionados a variáveis irrelevantes (baixa correlação) em relação a variável saída do modelo. Adicionalmente, existem limitações relacionadas a baixa aquisição de dados em relação a complexidade do modelo, onde analistas se preocupam em adicionar cada vez mais variáveis à entrada da rede, sem elevar proporcionalmente o volume amostral, o que eleva seu custo computacional sem implicar necessariamente em uma melhoria proporcional do modelo.

### **2.3. Precisão dos modelos em suas aplicações**

Avaliando a acurácia relatada pelos artigos, observou-se que as técnicas de aprendizado de máquina tendem a alcançar ótimos níveis de precisão em estudos de diferentes naturezas, desde interpretação de imagens, estimativa de componentes químicos, até a previsão da ocorrência de doenças em campo (CHAPMAN et al., 2018; EZZATZADEGAN et al., 2021; PUTRA; WIJAYANTO, 2023). Considerando o aprendizado de máquina com foco nas técnicas de rede neural artificial e suas variantes, foi possível observar resultados com acurácia de 84,81% a 99,35% para detecção da cultura e contagem de árvores (JARAYEE et al., 2022; LI et al., 2019; ZHENG et al., 2020), de 98% para simulação da fenologia da palma de óleo (HERNAWATI; WIKANTIKA; DARMAWAN, 2022), de 92% para

detecção de doença na cultura (VÁZQUEZ-RAMÍREZ et al., 2023) e 91% para estimar produção (ANG et al., 2022).

No caso dos modelos baseados em processos, dada sua natureza de simular os subprocessos e interações do ambiente, foi possível observar que tais modelos permitem estimar de forma mais precisa do sistema agrícola, quantificar seus *trade-offs* e obter uma simulação mais exata de componentes do biosistema. As informações geradas a partir dessas simulações podem ser utilizadas para etapas subsequentes, que vão desde a previsão direta da produção, até a avaliação das melhores práticas de manejo para auxiliar no planejamento socioecológico regional (FAN et al., 2019; MEIJIDE et al., 2017; PARDON et al., 2017; PATERSON, 2020).

Nos estudos que utilizaram da abordagem baseada em processos, foi possível observar boa taxa de sucesso das simulações, com acurácia de 85% a 99% para simular saldo de radiação (BENEZOLI et al., 2021; ELLSÄSSER et al., 2021), 78% para estimar o saldo da troca líquida de CO<sub>2</sub> do ecossistema (NEE) (BENEZOLI et al., 2021), 90% para estimar a produtividade primária líquida (NPP) (XU et al., 2020). Também foi possível observar erros de estimativas relativamente baixos, com viés relativo em torno de 8% para simulação de área foliar (PEREZ et al., 2016), 10% para estimar biomassa (XU et al., 2020) e 2,3% para estimar a produção (FAN et al., 2015).

#### **2.4. Aplicações em relação ao agroecossistema**

Os subtópicos seguintes apresentam resumos temáticos, quanto às principais conclusões e recomendações apontadas pelo avanço dos estudos no contexto da modelagem aplicada com foco nas interações solo-planta-atmosfera. Os tópicos dão destaque para as componentes do clima, solo e água no sistema produtivo, além de demonstrar como a modelagem também possibilita orientar intervenções na esfera socioeconômica, apoiando gestores e produtores afim de evitar conflitos, otimizar o manejo de sua produção e garantir sua viabilidade econômica.

### 2.4.1. Condições atmosféricas

A palma de óleo é geralmente cultivada na faixa equatorial, mas também existem registros de seu cultivo em latitudes maiores, desde que a região seja quente e úmida, apresentando condições adequadas como temperatura do ar idealmente entre 24°C e 28°C, não ultrapassando a mínima de 15°C ou máxima de 40°C, e precipitação superior a 2.000 mm anuais bem distribuídas ao longo dos meses. Além das condições climáticas diretamente requeridas pela planta, as condições climáticas da região também influenciam nas propriedades do solo, afetando sua taxa de intemperismo, sua disponibilidade de água e seu particionamento energético, o que influencia nas propriedades da cobertura vegetal do solo, resultando em modificações nas condições microclimáticas a nível de talhão (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; DO AMARAL TELES et al., 2016; HASHEMVAND KHIABANI; TAKEUCHI, 2020; OFEM; KEFAS; GARJILA, 2023; PIRKER et al., 2016; RAMDANI; MOFFIET; HINO, 2014; RHEBERGEN et al., 2016; SABAJO et al., 2017; SASIRAT et al., 2019).

Alguns autores demonstraram, com o apoio de simulações, como variações climáticas ocorridas temporalmente próximas aos períodos de colheita tem baixo poder de influenciar a produção da palma de óleo, porém, outros autores explicitaram como tais variações podem aumentar a lacuna de rendimento da palma de óleo a partir de danos cumulativos ocorridos desde o período de desenvolvimento vegetativo, até a fase reprodutiva (ABUBAKAR et al., 2022; AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; KHOR et al., 2023). A lacuna de rendimento é uma métrica obtida pela diferença do rendimento observado ou real, em relação ao rendimento teórico ou potencial, sendo o último obtido simulando a produção com zero limitações em todo o desenvolvimento da cultura (APICHATMETA; SUDSIRI; RITCHIE, 2017; WOITTIEZ et al., 2017).

A literatura aponta que a temperatura do ar é a segunda variável climática mais relevante para a palma de óleo com alta capacidade preditiva nos modelos, ficando atrás apenas da precipitação, pois apresenta influencia na produção com uma defasagem de até seis meses, enquanto a precipitação apresenta defasagens que podem alcançar até 36 meses (PATERSON; LIMA, 2018; RHEBERGEN et al., 2016; TANI et al., 2020). Apesar de alguns estudos demonstraram que a produção

da palma de óleo responde positivamente quanto maior a temperatura do ar, eventos extremos penalizam drasticamente a produção, tanto pelo efeito direto do estresse térmico, quanto por sua capacidade de elevar regionalmente o Déficit de Pressão de Vapor (VPD), causando prejuízos de até 40% a cada 4°C além da faixa ótima de desenvolvimento (ABUBAKAR; ISHAK; MAKMOM, 2022; FLEISS et al., 2022).

Considerando o particionamento de energia nos sistemas agrícolas de palma de óleo, foi possível verificar que a cultura tende a utilizar a energia prioritariamente para a evapotranspiração, reduzindo a parcela da energia direcionada para os fluxos de calor sensível e do solo. Contudo, deve-se atentar que essa constatação é relativa, visto que as proporções do particionamento podem se modificar a depender do estágio da cultura (MEIJIDE et al., 2017; RÖLL et al., 2015; TAN; KANNIAH; CRACKNELL, 2014).

Variações no VPD elevando a taxa de evapotranspiração podem causar fechamento dos estômatos, que é a estrutura responsável pela troca gasosa, afetando a atividade fotossintética que responderá aos efeitos do déficit hídrico. O déficit hídrico é a diferença negativa entre a demanda hídrica da cultura e o efetivo fornecimento de água por parte do sistema agrícola. Esse déficit pode ocorrer tanto por temperaturas extremas, quanto por condições severas e prolongadas de seca, que podem ser reflexos de anomalias climáticas, baixa disponibilidade de água no solo ou manejo inadequado do cultivo (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; RHEBERGEN et al., 2016, 2019; WAITE et al., 2019).

É dito que o estresse hídrico na palma de óleo acontece de forma mais acentuada quando há déficit hídrico por um período que dure, pelo menos, dois meses, e esse evento de estresse pode apresentar reflexos até dois anos após seu início, pois induz o fechamento dos estômatos, conseqüentemente reduzindo a transpiração e demais processos fotossintéticos. O déficit hídrico ocorrendo durante os estágios vegetativos, pode promover efeitos de deficiência nutricional, além do desequilíbrio entre reguladores de crescimento, o que implica na má formação ou até inibição de novas folhas, que são essenciais na manutenção do ciclo produtivo (HOFFMANN et al., 2017; TANI et al., 2020; WAITE et al., 2019).

O estresse hídrico também impacta consideravelmente na produção quando ocorre durante o estágio reprodutivo da palma de óleo, que é um período

que se inicia a partir de dois anos de idade e compreende quatro fases: (I) iniciação floral, (II) determinação do sexo da flor, (III) antese e (IV) colheita, sendo a segunda fase o período crítico para os efeitos da deficiência hídrica. Estima-se que o déficit hídrico pode resultar em reflexos significativos na produção quando ocorre durante a fase de determinação do sexo e durante o período que pode ocorrer a etapa de aborto floral, em outras palavras, respectivamente em torno de 29 e 10 meses de antecedência em relação a colheita (OETTLI; BEHERA; YAMAGATA, 2018; RHEBERGEN et al., 2019).

Durante a fase de frutificação da palma de óleo, foi possível verificar que meses isolados de déficit hídrico influenciaram na produção obtida cinco a seis meses após o evento, enquanto reflexos de estresse hídricos ocorridos por dois meses seguidos foram observados na produção obtida 11 meses após o evento. Entretanto, esse não é o período máximo de influência da precipitação na produção e estudos que envolveram correlacionar todo o período produtivo da palma de óleo concluíram que essa defasagem pode alcançar 24 a 36 meses, a depender das propriedades físicas do solo, práticas de manejo adotadas, além da frequência e intensidade de anomalias climáticas (BAYONA-RODRIGUEZ; ROMERO, 2019; HOFFMANN et al., 2017).

Simulações também demonstraram como condições atípicas na qualidade do ar podem influenciar drasticamente o cultivo da palma de óleo, potencialmente afetando seu desenvolvimento em qualquer fase do ciclo de vida da planta. Concentrações de ozônio, compostos nitrogenados e até mesmo ocorrência de fumaça, proveniente de incêndios que podem se intensificar com as mudanças climáticas, impactaram na relação do VPD, no fluxo de dióxido de carbono e, conseqüentemente, no acúmulo de biomassa da planta (STIEGLER et al., 2019, 2023).

De modo mais generalista, alguns estudos simularam como as áreas de cultivo da palma de óleo podem se expandir e migrar em direção às regiões subtropicais que se tornarão aptas em consequência das mudanças climáticas, entretanto, tais resultados não devem ser tomados como vantajosos para o setor agrícola. Os cenários apresentados indicam também problemas mais complexos em relação ao agroecossistema, como a redução da biodiversidade em escala global, elevação na intensidade e frequência de eventos extremos de secas, além

das possibilidades de ocorrências de *feedbacks* intensificadores das mudanças climáticas, visto que o aumento da demanda evaporativa da atmosfera influenciará na cobertura do solo, o que, por sua vez, influencia de volta no ciclo hidrológico regional (ELLSÄSSER et al., 2021; MCCALMONT et al., 2023; PATERSON; LIMA, 2018; WATSON-HERNÁNDEZ et al., 2022).

Mesmo avaliando exclusivamente do ponto de vista do cultivo da palma de óleo se tornando viável em novas regiões, estima-se que essas mudanças ainda dependerão fortemente do material genético das palmas de óleo e das condições dos solos nas novas regiões. Tais condições, em conjunto, ditarão as interações solo-planta-atmosfera, que muito provavelmente não serão receptivas para um cultivo ambientalmente amigável e/ou economicamente viável, mesmo intensificando as boas práticas de manejo que tendem a mitigar efeitos de eventos extremos (ELLSÄSSER et al., 2021; MCCALMONT et al., 2023; PATERSON; LIMA, 2018; RHEBERGEN et al., 2019; WATSON-HERNÁNDEZ et al., 2022).

As condições edafoclimáticas das novas regiões podem não ser adequadas em diferentes intensidades e de forma integrada como, por exemplo, uma maior amplitude térmica ou fotoperíodo incompatível, ocorrendo concomitantemente com características físico-químicas dos solos que não sejam recomendadas para o cultivo da palma de óleo. Nesse panorama, haveria uma forte dependência pelo desenvolvimento rápido de um material genético altamente adaptado, o que não necessariamente eliminaria a elevação dos custos de implementação e manejo, podendo tornar o cultivo economicamente inviável especialmente para os pequenos produtores (OISHY et al., 2025; PIRKER et al., 2016; QAIM et al., 2020).

Adicionalmente, mesmo que a introdução da palma de óleo em novas regiões seja viável, essa prática poderia impactar nas interações ecossistêmicas, causando um desbalanço no ciclo hidrológico, biogeoquímico e nas relações fauna-flora de toda matriz ambiental da região (OISHY et al., 2025; PIRKER et al., 2016). Dessa forma, não há uma expectativa positiva quanto à produção viável no cenário supracitado, tanto por motivos econômicos, no qual o faturamento dificilmente compensaria os custos e os riscos produtivos, quanto por motivos ambientais, onde a sustentabilidade estaria ameaçada mesmo com adoção rigorosa das melhores práticas de manejo.

#### 2.4.2. Influência das propriedades do solo

As propriedades granulométricas foram consideradas as variáveis mais importantes ao avaliar a aptidão dos solos para o cultivo da palma de óleo, pois elas estão diretamente relacionadas com a capacidade do solo de nutrir a planta ao longo do tempo, amenizar efeitos de períodos de estiagem e influenciar o crescimento radicular. A proporção de silte, argila e areia determinam características essenciais para o planejamento do manejo do cultivo, como Capacidade de Troca de Cátions (CTC), grau de intemperismo e porosidade, que influenciam, por exemplo, na capacidade de retenção e liberação dos nutrientes, além da capacidade de infiltração e retenção da água na profundidade efetiva do solo (PIRKER et al., 2016; SASIRAT et al., 2019; WAITE et al., 2019).

Anualmente a palma de óleo demanda volume considerável de macro e micronutrientes para a manutenção de sua produtividade média, que varia em torno de 20 toneladas de cachos de frutos frescos por hectare (t.FFB/ha), considerando a médias dos plantios comerciais. Entretanto, planejamento prévio do manejo da fertilidade deve ser realizado, pois a aplicação de nutrientes de modo indiscriminado e em altas dosagens pode acarretar em sérios desequilíbrios bióticos e abióticos na área de cultivo, potencialmente resultando em penalidades produtivas severas, ameaçando a viabilidade da produção (BEHERA et al., 2020; CHARLOQ et al., 2023; THOMPSON-MORRISON et al., 2023).

No aspecto abiótico, pesquisas demonstraram que o desequilíbrio nutricional no solo, resultante de aplicações não adequadas para local, promoveram mudanças na acidez (pH) do solo, influenciando na disponibilidade dos demais nutrientes e afetando os estoques de carbono orgânico presente no solo. Além dos efeitos diretos de eventuais deficiências nutricionais na planta, o desequilíbrio devido ao excesso de aplicação dos adubos minerais afeta a condutividade elétrica dos solos, elevando sua salinidade (BEHERA et al., 2020; SWAILS et al., 2022).

As propriedades físico-químicas dos solos podem sofrer alterações em relação as condições da matriz ecossistêmica em que se encontram, a depender de suas variações climáticas em escala regional ou local, nas quais a sensibilidade à essas mudanças têm relação direta com o uso da terra e tipo de cobertura do solo

em questão. Alterações na cobertura do solo podem implicar em modificação da emissividades da superfície, modificando o balanço de energia do sistema, influenciando no modo e intensidade dos processos biofísicos e biogeoquímicos relacionados a evapotranspiração, decomposição da matéria orgânica, emissão de nitrogênio e dióxido de carbono, entre outros processos (SABAJO et al., 2017; SWAILS et al., 2019).

Estudos indicaram como temperatura, umidade, disponibilidade de oxigênio e qualidade da matéria orgânica depositada sobre o solo são condicionantes para o equilíbrio dinâmico da composição do solo, especialmente em relação ao carbono. Climas diferentes influenciam na capacidade de decomposição da matéria orgânica pois, em climas temperados, onde baixas temperaturas são comuns, a taxa de decomposição é reduzidas, enquanto, sob o clima tropical a decomposição da matéria orgânica é acelerada (SABAJO et al., 2017; SWAILS et al., 2019).

Apesar da temperatura ter forte influência sobre a ciclagem do carbono nos sistemas agrícolas, a precipitação e a umidade são consideradas os principais fatores responsivos quanto ao balanço de carbono no solo. A partir da decomposição da matéria orgânica depositada sob o solo e presente em suas camadas inferiores, o carbono integra a fração solo do sistema onde seu saldo é balanceado principalmente pela sua saída do sistema via respiração, que é intensificada durante períodos de secas intensas e prolongadas (KHASANAH et al., 2015; MARWANTO; AGUS, 2014; SABAJO et al., 2017; SWAILS et al., 2019).

A conversão de classes naturais de cobertura vegetal e uso da terra para uma classe de sistema agrícola, usualmente implica em efeito negativo quanto à relação entre o carbono emitido, sequestrado e fixado no local de implementação da cultura. Isso se deve, em partes, pela simplificação da matriz natural influenciando nas condições climáticas, além da intensificação da liberação de carbono durante o processo de conversão da cobertura e uso da terra, que dificilmente atinge a equivalência ecossistêmica em relação a classe natural predecessora (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; KHASANAH et al., 2015).

Por outro lado, alguns estudos indicaram que não há alteração prática entre a quantidade de carbono armazenado no solo sob uma área de cultivo de palma de

óleo e outras classes florestais, contudo ressaltam que é importante considerar dois pontos principais ao avaliar tal perturbação numa matriz natural. Em primeiro lugar, um “empobrecimento” considerável do solo ocorre durante o processo de implementação do cultivo agrícola e, por último, há uma defasagem quanto a causa-efeito do estresse ambiental, onde uma floresta antiga pode apresentar uma capacidade de armazenamento de carbono superior se comparado ao tempo total do ciclo produtivo da palma de óleo, que necessita de perturbações ambientais recorrentes para sua renovação (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020; KHASANAH et al., 2015).

Há possibilidade de utilizar palma de óleo como mudança benéfica da cobertura do solo, propiciando melhores condições de clima, captação de água e sequestro de carbono, tomando como exemplo grandes pastagens abandonadas e demais áreas degradadas. Nessas áreas, o cultivo da palma de óleo pode se tornar uma opção ambientalmente e economicamente viável, desde que sua implementação priorize a recuperação, preservação e conservação do ecossistema em que será inserida e, dessa forma, reduza as emissões carbono, potencialmente revertendo o quadro de degradação, além de estimular o desenvolvimento socioeconômico regional, isto é, com o apoio de políticas públicas para garantir suporte aos produtores e comerciantes locais envolvidos em sua cadeia produtiva (KHASANAH et al., 2015; PATERSON; LIMA, 2018).

#### 2.4.3. Relação com os recursos hídricos

Alguns estudos mostraram que, apesar de um senso comum quanto à expansão da palma de óleo afetar drasticamente a qualidade e disponibilidade dos recursos hídricos de uma determinada região, na verdade, tais problemas ocorrem quando há uma redução da complexidade e cobertura vegetal do solo, o que não ocorre quando a palma de óleo substitui áreas antropizadas, degradadas ou de pastagens. A conversão de áreas naturais para plantios de palma de óleo pode ter impacto em escala de bacias, pois sua conversão frequentemente está associada a degradação de vegetação ribeirinha, incremento de produção de sedimentos e assoreamento de rios, afetando a qualidade de cursos d'água, com alteração do

pH entre outros compostos químicos, conseqüentemente afligindo a fauna e a flora toda região (DE PAIVA et al., 2017; SHEAVES et al., 2018; SILVA et al., 2018).

Os impactos do cultivo da palma de óleo vão além da redução da biodiversidade regional, afetando também o ciclo hidrológico em intensidade que pode variar dependendo do seu manejo do solo, do espaçamento adotado no talhão ou até mesmo idade da planta. Simulações demonstraram que mesmo em idades diferentes, a densidade de planto de até 150 plantas por hectare resultou em intensificação de até 29% do desenvolvimento sem acarretar em redução significativa da vazão na bacia hidrográfica, contudo, tal conclusão de efeito nulo da vazão foi condicionado simultaneamente ao elevado índice de precipitação observado na região (HEIDARI et al., 2020; RÖLL et al., 2015).

Como mencionado anteriormente, a palma de óleo é bastante sensível ao déficit hídrico, podendo ter sua produtividade penalizada cumulativamente para cada mês de insuficiência no seu abastecimento, contudo, é importante ressaltar que o estresse hídrico pode ocorrer não apenas pela interrupção da atividade estomática, devido a condições climáticas inadequadas, mas também pelo baixo armazenamento de água no solo (CULMAN et al., 2019; SASIRAT et al., 2019; WATSON-HERNÁNDEZ et al., 2022; WATSON-HERNÁNDEZ; GÓMEZ-CALDERÓN; DA SILVA, 2022).

Modelos baseados em processos se mostraram capazes de auxiliar no entendimento da penalização do déficit hídrico na palma de óleo a nível produtivo, utilizando os resultados obtidos a partir de simulações de penalização da produção potencial. Alguns estudos demonstraram que ao garantir um rendimento mínimo, limitado pelas condições hídricas, de pelo menos 80% do rendimento potencial, a gestão agrícola e ambiental foram beneficiadas, pois a produção ainda se mostrou economicamente viável, sem elevar a pressão pela expansão de áreas de cultivo (BRUM et al., 2021; RHEBERGEN et al., 2018; WOITTIEZ et al., 2017).

A irrigação deve ser planejada e aplicada com total rigor técnico e de forma integrada aos demais processos de manejo, visando estabelecer o momento ideal para irrigar, além de definir, de modo adaptável, a quantidade necessária para garantir o melhor desenvolvimento vegetal possível, sem promover o desperdício dos recursos naturais (BRUM et al., 2021; CORLEY; TINKER, 2015; CULMAN et al., 2019; RHEBERGEN et al., 2019). Como exemplo, existem registros na literatura

em que a irrigação consegue reestabelecer o pleno desenvolvimento vegetativo a partir da reposição de 75% da evapotranspiração total da planta, apontando uma possível recomendação otimizada para o uso da água (BRUM et al., 2021; NAJIHAH et al., 2019; RHEBERGEN et al., 2019).

A adoção da irrigação como um padrão de recomendação pode ser uma boa estratégia tanto para a proteção do cultivo, quanto para atender a demanda crescente pelo óleo da palma. Entretanto, simulações elucidaram que apenas a irrigação não é suficiente para garantir a viabilidade econômica da produção, sendo extremamente necessário que os produtores implementem estratégias que visem não apenas a proteção do plantio mas, também, a manutenção do ambiente circundante, conservando as interações ecossistemas de toda região (DE PAIVA et al., 2017; HEIDARI et al., 2020; SAGAR et al., 2019).

#### 2.4.4. Impactos da modelagem no aspecto socioeconômico

A palma de óleo é enaltecida por alguns autores devido seu potencial em estimular o desenvolvimento social como um todo, muitas vezes com essa característica associada à sua relevância econômica global. Contudo, o outro lado dos impactos sociais da palma de óleo é frequentemente associado a conflitos entre empresas buscando pela expansão do seu cultivo para extração de recursos, e comunidades locais que formam oposição em decorrência de direitos à terra distorcidos, condições de trabalho precárias, além da percepção negativa quanto aos impactos do cultivo da palma de óleo no meio ambiental local (ABRAM et al., 2017; AUSTIN et al., 2015; PURNOMO et al., 2020).

A literatura indicou uma forte concentração de esforços em determinar metodologias para obter informações sobre onde esses conflitos ocorrem, contudo, considerar as motivações desses conflitos pode ser ainda mais importante e relevante na elaboração de medidas que impeçam ou mitiguem novos eventos, independentemente de onde possam acontecer. Para que tais motivações sejam identificadas, é necessário descrever não apenas a região e os períodos típicos de ocorrência mas, também, identificar os perfis que mais necessitem de apoio técnico e intervenções governamentais, para que o combate à conflitos seja

adequadamente definido, adotado em tempo hábil e de modo mais eficiente possível (ABRAM et al., 2017).

Dentre os perfis dos produtores da palma de óleo apontados na literatura, os pequenos produtores apresentam considerável participação na produção global, tanto em relação a produção somada, quanto às suas capacidades de responder aos eventos penalizadores da produção. Apesar de conseguirem se adaptar relativamente bem as condições adversas do campo, os estudos demonstraram que a oferta de assistência técnica comunitária para uma tomada de decisão eficiente ainda é precária até o presente momento (ABUBAKAR; ISHAK, 2022; ABUBAKAR; ISHAK; MAKMOM, 2022; AFRIZAL; ELFITRA; ZULDESNI, 2023; MIDDELBERG et al., 2019; NURLIZA et al., 2022)

Visando uma assistência mais adequada aos pequenos produtores, em primeira instância é necessário reconhecer, quantificar e avaliar a heterogeneidade encontrada nesse grupo social. Tal estratégia é necessária para que a transferência de tecnologia ocorra da forma mais eficaz possível, auxiliando na estruturação de uma gestão adaptável e garantindo que o trabalho dos extensionistas atinja o maior nível de impacto na comunidade produtora, potencialmente minimizando seus conflitos (BRANDÃO et al., 2021; MARTÍNEZ-ARTEAGA et al., 2023).

Estimativas apoiadas por modelos da cadeia produtiva permitiram demonstrar como o apoio aos pequenos produtores eleva a qualidade de vida regional como um todo. Além do estímulo direto ao comércio local reduzindo os índices de pobreza, o apoio tecnológico fornecido aos produtores, em associação à já existente consciência da importância de um cultivo sustentável, permite que maiores rendimentos sejam alcançados sem a necessidade de expandir a área e ameaçar o tão importante equilíbrio do ecossistema com o sistema agrícola em questão (LEE et al., 2014).

No aspecto econômico, a palma de óleo desempenha um importante papel no desenvolvimento de todos países aptos para seu cultivo, seja em escala local ou nacional, especialmente pelo seu potencial econômico advindo da extração do óleo vegetal e subsequente direcionamento para os setores energético e alimentício. A produção da palma de óleo possui elevada influência não apenas diretamente e exclusivamente no comércio global mas, também, estimula o desenvolvimento de comunidades e pequenos comércios locais, apoiando a

agricultura familiar e promovendo a participação de pequenos produtores na cadeia produtiva e de abastecimento (ABDULRAZIK et al., 2017; LAGUNES-ESPINOZA et al., 2022; SIBHATU et al., 2022; SUSANTI; MARYUDI, 2016; VILLELA et al., 2014; ZHENG et al., 2021).

Modelos focados na previsão da produção mensal em função do clima tem apresentaram elevado potencial em apoiar a decisão dos gestores agrícolas, seja no intuito de proteger a produção, mitigar efeitos negativos devastadores ou até mesmo justificar, por meio de relatórios técnicos, eventuais quebras de contratos de venda prévia. Associado à esses modelos preditivos, integrar modelos de otimização de cadeia produtiva, permitiu determinar, de modo mais adequado, as prioridades de investimentos e intervenções comerciais, orientando os produtores quanto as melhores decisões para a redução de danos econômicos ao longo de um ciclo produtivo que tenha sido penalizado por condições adversas ocorridas durante seu desenvolvimento (ABDULRAZIK et al., 2017; RHEBERGEN et al., 2019).

A literatura destacou como é importante entender as relações entre ambiente, produção e mercado pois, dessa forma, é possível visualizar todos os fatores que influenciam na cadeia produtiva da palma de óleo e identificar as lacunas de produção, o que, por sua vez, permite otimizar o seu rendimento, reduzindo a pressão pela expansão das áreas de cultivo. Entretanto, alguns estudos demonstraram que elevar o rendimento produtivo da palma de óleo não necessariamente reduz a pressão pela expansão agrícola e desmatamento, especialmente pela atratividade financeira e, portanto, a implementação de incentivos à produção visando atender a demanda e a adoção de novas tecnologias otimizadoras de produção, devem sempre estar associadas às boas práticas do cultivo sustentável, apoiadas por políticas regularizadoras e fiscalização efetiva e contínua (LIM et al., 2024; NOURQOLIPOUR et al., 2015; PATERSON; LIMA, 2018; PIRKER et al., 2016; PURNOMO et al., 2020; SUSANTI; MARYUDI, 2016; VIJAY et al., 2018; XIN; SUN; HANSEN, 2021; YU et al., 2023).

É importante destacar que não há uma convergência para que o cultivo da palma de óleo seja inibido ou extinto, porém, há um consenso sobre como seu cultivo deve ser mais sustentável, protegendo áreas naturais e que sua expansão seja estrategicamente utilizada na recuperação de área degradadas. O sistema agrícola da palma de óleo é um sistema dinâmico e complexo, e a adoção de

modelos baseados em processos possibilita entender as relações entre seus diferentes componentes, o que é a base para garantir diretrizes para o planejamento de boas práticas do manejo sustentável e para garantir a viabilidade do cultivo, desde os trabalhos de campo até o desenvolvimento de políticas públicas (BENAMI et al., 2018; CIFUENTES-ESPINOSA et al., 2023; FURUMO; AIDE, 2017; KANIAPAN et al., 2021; MARIN-BURGOS; CLANCY, 2017; MOREIRA; GOLDEMBERG, 2015).

É interessante que a adoção de políticas nacionais para mercados sustentáveis desenvolva e implemente programas de incentivo que não se concentrem apenas na produção total, mas também incentivem o vínculo com a biodiversidade e a integração dos serviços ecossistêmicos locais (ABRAM et al., 2017; BRANDÃO et al., 2021; VIJAY et al., 2018). Considerando esse cenário, de um modo geral, para que o cultivo da palma de óleo prossiga garantindo a harmonia no campo socioeconômico, a literatura recomenda que tais políticas e programas estimulem (1) a intensificação na integração das esferas acadêmica-empresarial, (2) adoção de apoio técnico contínuo de biólogos, em parceria com agrônomos e gestores agrícolas, para auxiliar na coordenação de atividades agrícolas, sempre considerando os possíveis impactos no ecossistema local, (3) adoção de melhores práticas sustentáveis de desenvolvimento e manejo, (4) adoção de uma gestão adaptativa em relação aos produtores, (5) intensificação na execução de *workshops* para divulgação de relatórios técnicos e capacitação dos produtores e, não menos importante, (6) integração dos pequenos agricultores em processos de tomada de decisões (ABUBAKAR; ISHAK, 2022; BRANDÃO et al., 2021; FURUMO et al., 2019).

A atenção nos aspectos ambiental e social é algo que tanto o governo quanto a indústria concordam que deve ser a prioridade em determinar diretrizes para o desenvolvimento da produção e mercado nacional. Contudo, uma gestão inteligente, adaptável e sempre atualizada se faz necessária, onde tais requisitos podem ser atendidos por meio de modelos baseados em processos ou estatísticos, os quais a literatura, demonstra estarem aptos e em constante evolução para apoiar sistemas de tomada de decisão com elevada confiabilidade (AUSTIN et al., 2015; FURUMO; AIDE, 2017; WISENA et al., 2014; YU et al., 2023).

## 2.5. Considerações sobre a revisão

As aplicações das técnicas de modelagem para o desenvolvimento da cadeia produtiva da palma de óleo apresentam enorme versatilidade, podendo ser adotadas desde simulações diretas para descrever as relações de causa e efeito em biosistemas complexos, até mesmo detalhar sua influência em diferentes aspectos regionais, incluindo a esfera social. O levantamento literário demonstrou como modelos de naturezas diferentes permitem integrar diferentes tipos de informações e, ainda assim, podem ser aplicados com objetivos semelhantes, mesmo que o modo de processamento seja distinto.

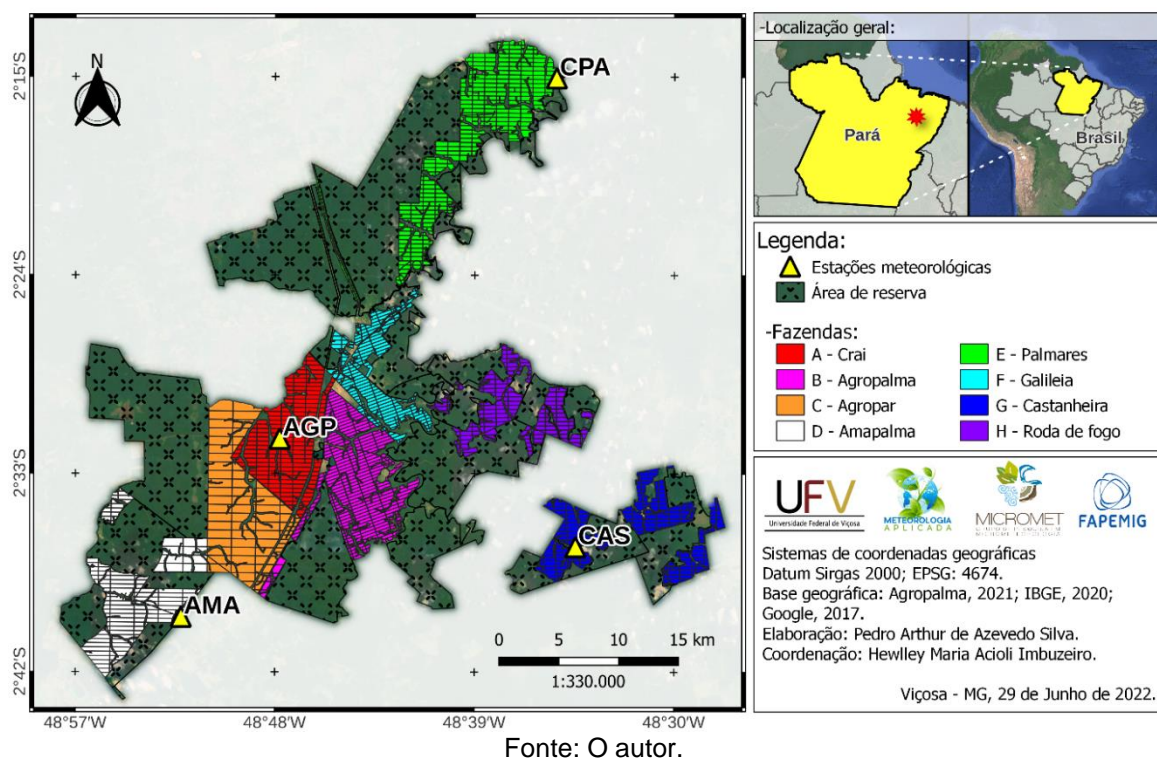
De um modo geral, é possível deduzir que a natureza do modelo não é um fator único e determinante para se obter alto nível de precisão das estimativas e, conseqüentemente, garantir sucesso do estudo. A forma como o modelo é aplicado, respeitando as premissas de cada abordagem e os objetivos do estudo, além da seleção dos dados pela melhor qualidade disponível, por muitas vezes é o principal fator limitante para o potencial do modelo adotado, uma vez que a qualidade das informações geradas pelo modelo dificilmente superará a qualidade dos dados utilizados para abastecê-lo.

### 3. MATERIAL E MÉTODOS

#### 3.1. Área de estudo

O estudo foi realizado com base em observações realizadas nas áreas produtivas inseridas na propriedade da Agropalma, que possui comprimento aproximado de 55 km para sua extensão máxima latitudinal e longitudinal em referencial plano, com coordenadas geográficas centrais em 02°29'37" latitude sul e 48°44'41" longitude oeste, localizada na microrregião de Tomé-Açu (MRGTA), região nordeste do estado do Pará, Brasil (Figura 1).

Figura 1 – Mapa da região de estudo com enfoque na delimitação das fazendas e seus respectivos talhões pertencentes à Agropalma.



O local de estudo está inserido na classe climática descrita como clima tropical úmido sem estação seca definida, identificada pelas letras “Af” conforme classificação climática apresentada por Köppen-Geiger, apresentando chuvas durante todo o ano, porém com ocorrências de distribuição irregular do total precipitado (ALVARES et al., 2013; BOLFE; BATISTELLA, 2011; KÖPPEN et al.,

1936; SANTOS et al., 2019). Suas características incluem temperatura média anual em torno de 26°C, precipitação acima de 2.000 mm/ano, com redução das chuvas no segundo semestre, porém sem longos períodos de estiagem.

A propriedade está organizada em oito fazendas principais que são utilizadas como uma referência de unidade de gestão, cada uma com suas próprias características em relação ao tipo de solo, número de talhões, tamanho médios dos talhões, ano de implementação (tabela 1). A propriedade também conta com quatro estações meteorológicas posicionadas estrategicamente para capturar as possíveis variações em relação a extensão da propriedade e, especialmente, sua posição latitudinal.

Tabela 1 – Detalhamento dos talhões produtivos inseridos em cada fazenda da propriedade Agropalma.

	Total de talhões	Área média dos talhões (ha)	Classificação do solo	Ano do primeiro plantio
A - Crai	176	27.99	LAd1 (100%)	1985
B - Agropalma	252	22.28	LAd1 (100%)	1991
C - Agropar	73	89.17	LAd1 (100%)	1995
D - Amapalma	100	49.72	LAd1 (100%)	1998
E - Palmares	281	26.13	LAd1 (33.85%) LAd10 (66.15%)	1989
F - Galileia	152	19.82	LAd1 (100%)	2001
G - Castanheira	192	22.18	LAd1 (79.39%) LAd10 (20.61%)	2006
H - Roda de fogo	156	20.56	LAd1 (99.80%) LAd10 (0.20%)	2007
Geral	1382	34.73	LAd1 (85.65%) LAd10 (14.35%)	1985

Fonte: O autor.

Devido ao fato de estar relativamente próxima à costa norte-nordeste (N-NE) da América do Sul, a Agropalma está susceptível aos efeitos provocados pela ocorrência de diferentes sistemas de precipitação atuantes na região como, por exemplo, a variação posicional da Zona de Convergência Intertropical (ZCIT), Linhas de Instabilidade (LI) e/ou a ocorrência simultânea de eventos ENOS, como

*El Niño / La Niña* (CAVALCANTI et al., 2009; SOUSA; CANDIDO; SATYAMURTY, 2021). É importante ressaltar que apesar de toda a região de interesse estar predisposta a sofrer influência direta da ocorrência desses sistemas, diferentes setores administrativos foram capazes de realizar registros de precipitação diferentes, especialmente devido a sua extensão em sentido latitudinal. Por esse motivo, as quatro estações meteorológicas foram utilizadas de modo independente para realizar as simulações, havendo um agrupamento médios dos dados pela propriedade apenas após o pré-processamento do banco de dados e após a obtenção dos dados simulados.

## 3.2. Banco de dados

### 3.2.1. Dados climáticos

Os dados climáticos foram obtidos a partir das quatro estações meteorológicas localizadas em quatro fazendas distintas da Agropalma (tabela 2) conforme demonstradas na figura 1, sendo as quatro estações da marca HOBO modelo U30-NRC-SYS-C (ONSET COMPUTER CORPORATION, 2021). Os dados coletados compreenderam um período de 01/01/2012 a 31/12/2021, com frequência de 15 minutos entre registros instantâneos, e foram obtidas informações sobre temperatura do ar, umidade relativa, radiação solar, velocidade do vento e precipitação.

Tabela 2 – Dados posicionais das estações meteorológicas instaladas dentro da propriedade da Agropalma.

	Nome	Tipo	Longitude (°)	Latitude (°)	Altitude (m)
AGP	Agropalma	Automática	-48.796	-2.524	27
AMA	Amapalma	Automática	-48.871	-2.658	30
CAS	Castanheira	Automática	-48.574	-2.605	28
CPA	Palmares	Automática	-48.589	-2.251	26

Fonte: O autor.

Também foram obtidas informações da base *Brazilian Daily Weather Gridded Data* (BR-DWGD) (XAVIER et al., 2022), especialmente pela necessidade

de inicialização do modelo e execução de simulações que ocorrem fora do período das observações obtidas pelas estações da Agropalma. O BR-DWGD foi escolhido por fornecer dados temporalmente consistentes e espacializados em grade (tabela 3), gerados a partir da interpolação de 11.473 pluviômetros e 1.252 estações meteorológicas, provenientes da Agência Nacional de Águas (ANA) e do Instituto Nacional de Meteorologia (INMET), além de terem sido rigorosamente validados para o território brasileiro, conseqüentemente, garantindo a alta qualidade das informações referentes à área de estudo.

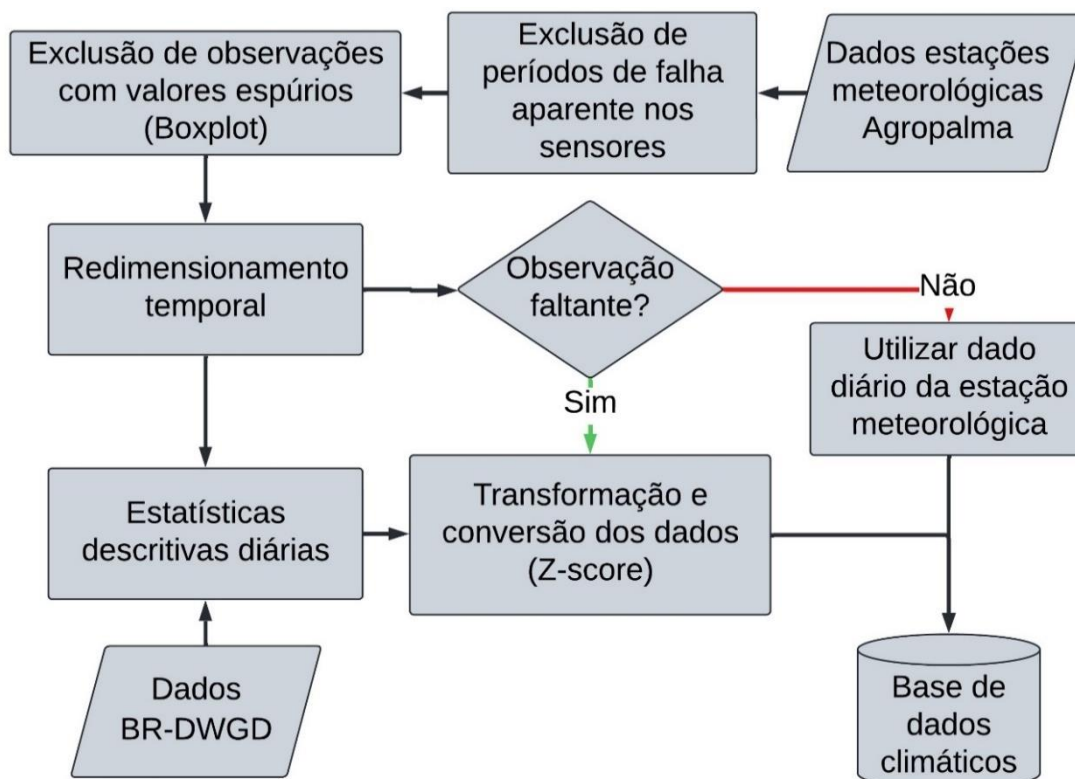
Tabela 3 – Descrição dos dados disponibilizados pelo conjunto *Brazilian Daily Weather Gridded Data*.

<i>Brazilian Daily Weather Gridded Data (BR-DWGD)</i>	
Tipo dos dados	Em grade
Projeção	Latitude e longitude em grade regular
Cobertura espacial	Território brasileiro
Resolução espacial	0.1° x 0.1°; Resolução nativa de 9 km.
Variáveis climáticas	Precipitação (mm)
	Radiação solar (MJ/m <sup>2</sup> /d)
	Temperatura mínima (°C)
	Temperatura máxima (°C)
	Umidade relativa (%)
	Velocidade do vento (m/s)
Cobertura temporal	01/01/1961 - 20/03/2024 (v3.2.3)
Resolução temporal	Diária
Formato do arquivo	<i>Network Common Data Form - NetCDF (.nc)</i>

Fonte: O autor.

O BR-DWGD também foi utilizado na etapa de preenchimento de falhas dos dados climáticos provenientes das estações da Agropalma (figura 2). Os dados das estações foram submetidos a um processo de análise de consistência para verificar e remover dados não confiáveis, o que gerou lacunas no banco de dados e, somadas as lacunas já existentes por falhas eventuais nos sensores, demandaram por um processo de preenchimento para restaurar a integridade das informações.

Figura 2 – Fluxograma com as etapas do processo de análise de consistência e preenchimento do banco de dados climáticos.




Fonte: O autor.

O processo de preenchimento do banco de dados iniciou por duas etapas distintas de limpeza dos dados. A primeira avaliou visualmente longos períodos com dados fora do comportamento típico da região, indicando falha prolongada do instrumento e, devido a alta complexidade associada para tentar distinguir quais observações eram confiáveis, todos os dados dentro da janela de baixa confiabilidade foram descartados (figura 3).

A segunda etapa de limpeza se baseou em detectar valores espúrios pontuais que podem ocorrer independentemente de falha contínua do sensor e, para essa etapa, foi adotada uma abordagem de análise de diagramas de caixa (*boxplots*) (TUKEY, 1977). Para iniciar essa análise, primeiro foi necessário modificar o índice temporal das observações, convertendo as informações de hora, minuto, dia e mês, para hora do ano, onde o índice temporal passou a ser número inteiro sequencial, iniciando no número 1 para as observações pertencentes à primeira hora do ano, isto é, de 00:00 a 00:45 do dia 1 de janeiro, e terminando no

número 8760 para as observações pertencentes à última hora do ano, ou seja, de 23:00 a 23:45 do dia 31 de dezembro, reiniciando a cada ano.

Figura 3 – Gráfico da umidade relativa registrada pela na estação AGP. As faixas em tonalidade vermelha indicam períodos com aparente falha contínua do sensor.



Fonte: O autor.

A partir da nova indexação temporal, foi possível gerar e analisar *boxplots* horários para cada variável e em cada estação meteorológica, o que permitiu avaliar a distribuição dos dados e sua assinatura horária para a região. Considerando que o *boxplot* indica a média, mediana e quartis, essa etapa de limpeza pontual utilizou os limites superiores e inferiores dos diagramas como limiares de aceitação, eliminando os dados cujos valores ultrapassassem os limites apontados pelos seus respectivos *boxplots*, ou seja, foram tratados como *outliers* horários e, conseqüentemente, categorizados como dados espúrios.

Após efetuada a limpeza, os dados das estações tiveram sua periodicidade reamostrada, passando de registros com 15 minutos de intervalo, para registros diários, tornando-os compatíveis com o BR-DWGD. Partindo dos dados em escala diária, foram extraídas as estatísticas de média e desvio padrão para cada variável, tanto para os conjuntos de dados das estações meteorológicas, quanto para o conjunto BR-DWGD. A média e o desvio-padrão dos dados das estações e do BR-DWGD, que foram extraídos na etapa anterior, foram utilizados para realizar a transformação *Z-score* (ALTMAN, 1968) de todos os dados climáticos.

A transformação dos dados foi realizada utilizando a equação 1 e resultou em sinais padronizados referentes aos conjuntos de dados originais que, neste estudo, permitiu equiparar os registros transformados das estações com os registros transformados do BR-DWGD, viabilizando o preenchimento das lacunas presentes no conjunto de dados das estações meteorológicas. Após o preenchimento das lacunas nos dados, a transformação *Z-score* foi revertida utilizando a equação 2, contudo, apenas as estatísticas dos dados das estações meteorológicas foram utilizadas nesse processo.

$$Z_{r,i} = \frac{X_{r,i} - \bar{X}_r}{DP_r}, \quad i = 1, 2, \dots, n \quad (1)$$

$$X_{e,i} = (Z_{r,i} * DP_e) + \bar{X}_e, \quad i = 1, 2, \dots, n \quad (2)$$

em que  $r$  é o índice referente aos dados BR-DWGD,  $e$  é o índice referente aos dados provenientes das estações meteorológicas,  $i$  é o índice referente à cada observação da série de dados,  $Z$  é o valor *Z-score*,  $X$  é a variável climática sob processo de preenchimento,  $\bar{X}$  é a média do conjunto de dados e  $DP$  é o desvio padrão do conjunto de dados.

Adotar as estatísticas extraídas apenas a partir dos dados das estações para aplicar a transformação reversa, resultou no ajuste dos dados originais do BR-DWGD aos padrões registrados pelas estações instalados no local de estudo. Ao final desse processo, foi possível observar que o conjunto de dados climáticos foi completamente preenchido, sem valores espúrios detectáveis, garantindo a adequabilidade do banco de dados para os modelos.

### 3.2.2. Dados de produção e do solo

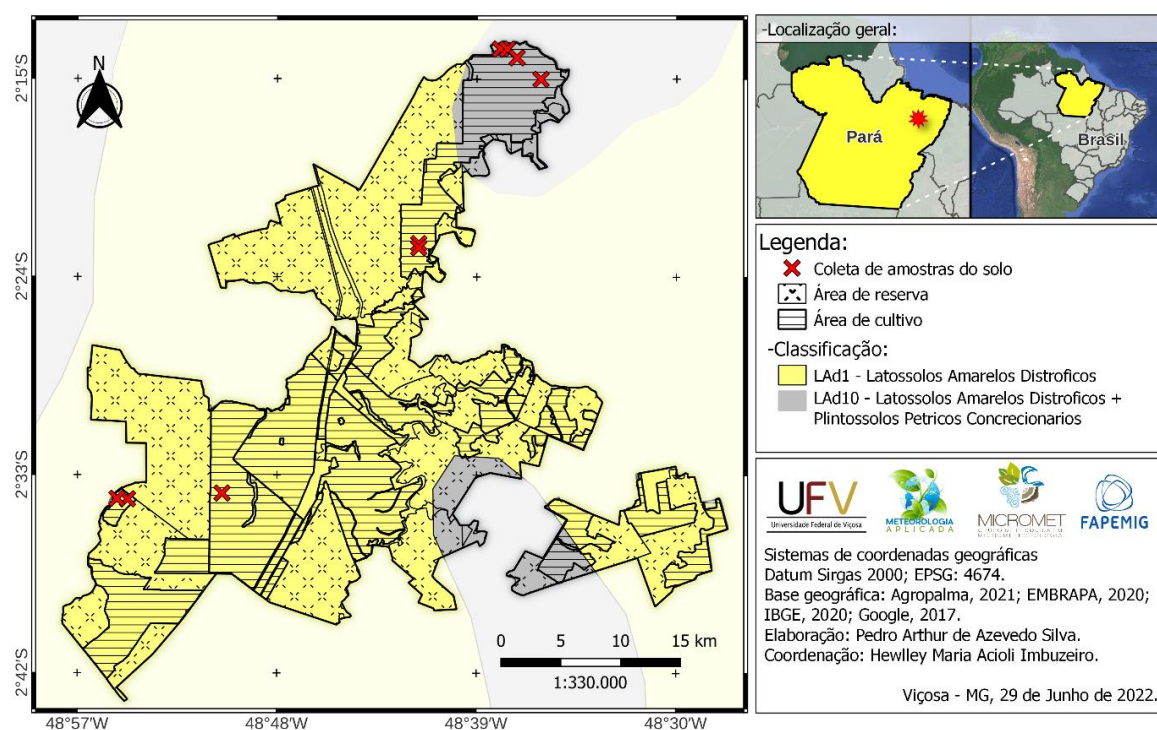
Os dados de campo foram obtidos com apoio da equipe técnica da Agropalma e o banco de dados foi abastecido com dados de produção dos talhões de palma de óleo, além dos dados sobre as propriedades físicas do solo nas áreas de cultivo. Os dados de produção, obtidos por meio de pesagem da colheita, foram disponibilizados em quilogramas (Kg) totais por talhão, consolidados mensalmente.

Esses dados foram convertidos em produtividade mensal em toneladas por hectares (t/ha), dividindo a produção total por 1000 e pela área de cada talhão em

hectares, o que resultou em uma informação ponderada quanto a produção obtida para toda a propriedade, independentemente do tamanho do talhão amostrado. Dessa forma, os dados de produtividade foram utilizados como referência para os procedimentos de treinamento, teste e validação dos modelos utilizados.

Para os dados da física do solo, foram realizadas análises conforme método EMBRAPA (CLAESSEN et al., 1997) para obtenção de informações quanto classificação textural, densidade aparente do solo, além do detalhamento quantitativo da granulometria (argila, silte e areia total). O processo de amostragem do solo ocorreu em seis talhões (figura 4), em que áreas homogêneas quanto a cor, topografia e manejo foram delimitadas e, realizando um caminhamento aleatório, foram coletadas amostras de solo em cada área com auxílio de um trado. As amostras coletadas foram subsequentemente misturadas em um balde limpo para a retirada de uma amostra composta final que, por sua vez, foi devidamente embalada e encaminhada para a realização das análises laboratoriais.

Figura 4 – Mapa da classificação dos solos e pontos de coleta amostral dos solos realizada na propriedade Agropalma.



Fonte: O autor.

As informações granulométricas obtidas a partir das análises de solo foram utilizadas para calcular as demais variáveis de solo requeridas como entradas pelo modelo baseado em processos, por meio da aplicação de funções de pedotransferência (PTF) (BOUMA, 1989). As PTF's aplicadas serviram para estimar as variáveis necessárias faltantes nas análises, sendo elas o parâmetro exponencial B (equação 3) da equação de retenção de água no solo (COSBY et al., 1984), saturação do solo (equação 4), condutividade hidráulica na saturação (equação 5), capacidade de campo (equação 6) e o ponto de murcha (equação 7).

$$BEXP = 3.1 + 15.7 \left( \frac{\%CL}{100} \right) - 0.3 \left( \frac{\%SA}{100} \right), \quad (3)$$

$$SSAT = \frac{50.5 - 3.7 \left( \frac{\%CL}{100} \right) - 14.2 \left( \frac{\%SA}{100} \right)}{100}, \quad (4)$$

$$SSKS = \left( 10^{-0.6 - 0.64 \left( \frac{\%CL}{100} \right) + 1.26 \left( \frac{\%SA}{100} \right)} \right) 7.0556e^{-6}, \quad (5)$$

$$SDUL = \left( \frac{1.157e^{-9}}{SSKS} \right)^{\frac{1}{2BEXP+3}}, \quad (6)$$

$$SLLL = \frac{SSAT}{100} \left( \frac{\left( 10^{2.17 - 0.63 \left( \frac{\%CL}{100} \right) - 1.58 \left( \frac{\%SA}{100} \right)} \right) 0.01}{152.9574} \right)^{\frac{1}{BEXP}}, \quad (7)$$

em que BEXP é a inclinação da curva de retenção de água no solo, SSAT é a saturação do solo, SSKS é a condutividade hidráulica na saturação, SDUL é a capacidade de campo, SLLL é o ponto de murcha, %CL é a porcentagem de argila do solo e %SA é a porcentagem de areia total do solo.

Considerando que a influência da precipitação na produção é o fator chave deste estudo, associados aos dados de clima, os dados calculados de capacidade de campo e de ponto de murcha foram utilizados para estimar o balanço hídrico do solo para as simulações realizadas. O balanço hídrico foi gerado com o auxílio da biblioteca "Bioclim" (SERRANO-NOTIVOLI, 2023), que se baseia no Balanço Hídrico Climatológico (BHC) de Thornthwaite e Mather (THORNTHWAITE; MATHER, 1955), e foi executado pelo *software* estatístico R (R CORE TEAM, 2014).

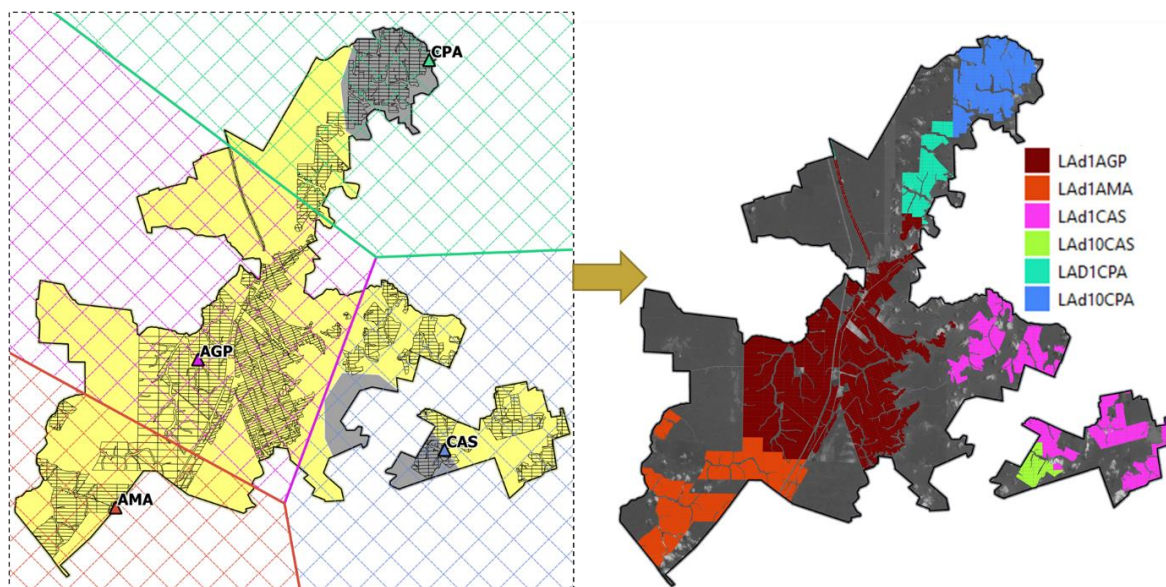
### 3.2.3. Pré-processamento dos dados para as simulações

Considerando que os dados de produção foram obtidos a nível de talhão, enquanto os demais dados referentes ao solo e ao clima foram pontuais, mesmo sendo representativos para a área, não apresentam grandes variações entre talhões. Baseando-se nessa observação e visando reduzir a redundância das simulações, foi necessário identificar quais talhões compartilhavam das mesmas condições de ambiente para simulação.

A primeira etapa desse processo consistiu em delimitar as áreas de influência de cada estação meteorológica da Agropalma, ou seja, definir os limites espaciais em que uma dada estação meteorológica realiza registros representativos para sua área. Dessa forma, foi utilizada a metodologia de delimitação de polígonos de Thiessen (THIESSEN, 1911), que consistiu em traçar linhas retas conectando todas as estações meteorológicas e, a partir dos segmentos de retas gerados, mediatrizes foram traçadas e estendidas até que tocassem umas às outras, ou até que tocassem os limites máximos da área de estudo, formando os polígonos das áreas de influência de cada estação.

Realizando a sobreposição dos arquivos vetoriais das classes de solo da propriedade, da delimitação dos talhões e das áreas de influência das estações meteorológicas obtidas no processamento anterior, foi possível verificar quais talhões podiam ser agrupados por similaridade das condições de campo (figura 5). Utilizando as coordenadas dos centroides dos talhões como referência, as informações dos demais vetores foram amostradas e atribuídas a cada talhão, atuando como uma classificação, que gerou seis combinações distintas.

Figura 5 – Representação do processo de reclassificação dos talhões, com base no critério duplo de tipo de solo e área de influência das estações meteorológicas instaladas na propriedade da Agropalma.



Fonte: O autor.

Associado à classificação das condições únicas de campo, foram derivadas combinações que também consideraram o ano de plantio no talhão, o que corroborou para que a simulação agrupasse os talhões por similaridade dos estágios de desenvolvimento da palma de óleo, assim como das condições climáticas ocorridas desde o momento de implementação de cada talhão. Dessa forma, para o modelo baseado em processos, foram realizadas 53 simulações distintas (tabela 4) cujos resultados foram comparados com os dados de produção observados em toda propriedade, onde essa informação foi previamente agrupada seguindo o mesmo critério de classificação combinada entre solo, estação e ano de plantio.

Essa classificação e reorganização das informações também foi utilizada na abordagem via rede neural artificial, porém, por não precisar realizar simulações independentes, essa classificação atuou de modo indireto. Nesse caso, a classificação gerada auxiliou na estruturação de uma tabela relacional sobre quais entradas de dados de clima e solo estariam associados a quais dados de produção observadas nos talhões e, assim, cada condição de campo atuou como uma das iterações de todo processo sequencial de treinamento.

Tabela 4 – Lista de identificação para todas as simulações realizadas considerando as condições únicas observadas em campo.

LAD10CAS2006	LAD1AGP1987	LAD1AGP2007	LAD1AMA2001
LAD10CAS2008	LAD1AGP1988	LAD1AGP2008	LAD1CAS2006
LAD10CAS2010	LAD1AGP1989	LAD1AGP2010	LAD1CAS2007
LAD10CPA1989	LAD1AGP1991	LAD1AGP2011	LAD1CAS2008
LAD10CPA1990	LAD1AGP1992	LAD1AGP2012	LAD1CAS2009
LAD10CPA1996	LAD1AGP1993	LAD1AGP2013	LAD1CAS2010
LAD10CPA2000	LAD1AGP1994	LAD1AGP2017	LAD1CPA2001
LAD10CPA2001	LAD1AGP1995	LAD1AGP2018	LAD1CPA2002
LAD10CPA2011	LAD1AGP1996	LAD1AMA1992	LAD1CPA2011
LAD10CPA2012	LAD1AGP1997	LAD1AMA1996	LAD1CPA2015
LAD10CPA2015	LAD1AGP1998	LAD1AMA1997	LAD1CPA2016
LAD10CPA2016	LAD1AGP2001	LAD1AMA1998	
	LAD1AGP1985	LAD1AGP2002	LAD1AMA1999
	LAD1AGP1986	LAD1AGP2004	LAD1AMA2000

Fonte: O autor.

### 3.3. Modelos

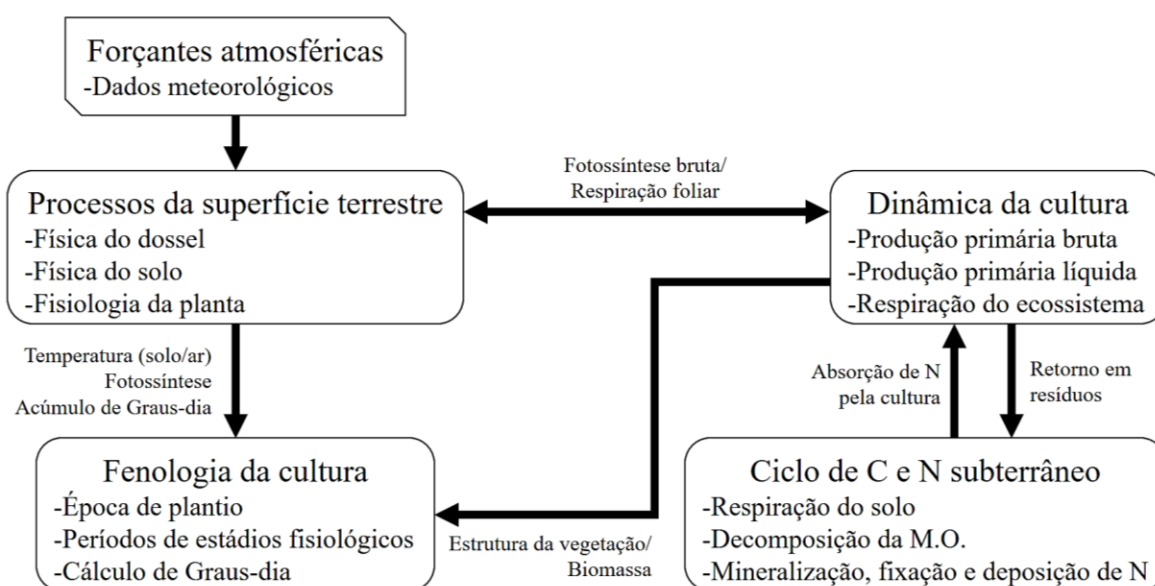
#### 3.3.1. ECOSMOS - *Palm*

O *ECOSystem MOdel Simulator* (ECOSMOS) é um modelo de simulação do crescimento e desenvolvimento vegetal, baseado em processos biofísicos que envolvem os mecanismos fotossintéticos, além dos balanços de energia e massa. É um modelo que pode ser executado em diferentes linguagens de programação e um de seus diferenciais em relação a muitos outros modelos biofísicos, é a possibilidade de adicionar submodelos de tipos funcionais de plantas (sub-PFT) sob demanda, tornando o modelo altamente maleável quanto a sua aplicação em culturas diversas, sendo esse recurso intensamente trabalhado por pesquisadores da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), no intuito de melhorar continuamente o modelo e incluir as culturas mais relevantes (BENEZOLI et al., 2021; COLMANETTI et al., 2022; DIAS et al., 2021).

O funcionamento do ECOSMOS é, em grande parte, baseado em outro modelo biofísico popularmente conhecido como Agro-IBIS (KUCHARIK; BRYE,

2003), que por sua vez é uma versão aprimorada e focada em aplicações agrícolas do modelo *Integrated Biosphere Simulator* (IBIS). Por se basear no Agro-IBIS, o modelo ECOSMOS apresenta uma estrutura semelhante que, de modo simplificado, pode ser dividida em quatro módulos (figura 6), sendo eles (I) módulo de processos da superfície terrestre, (II) módulo de dinâmica da cultura, (III) módulo de processos biogeoquímicos do solo e (IV) módulo da fenologia da cultura (AMUTI et al., 2018; BENEZOLI et al., 2021; DIAS et al., 2021).

Figura 6 – Representação da estrutura hierárquica do modelo Agro-IBIS.



Fonte: Adaptado de Foley et al. (1996) e Kucharik e Brye (2003).

O módulo de processos da superfície terrestre é o módulo inicial, no qual há a entrada dos dados sobre temperatura do ar, radiação solar, umidade relativa, velocidade do vento e precipitação, que servirão como forçantes climáticas para iniciar as simulações. As simulações são realizadas numa resolução temporal horária ou diária, permitindo obter um melhor detalhamento dos processos biofísicos ao longo do tempo (AMUTI et al., 2018; BENEZOLI et al., 2021; COLMANETTI et al., 2022; FOLEY et al., 1996; KUCHARIK et al., 2000; KUCHARIK; BRYE, 2003; WEBLER et al., 2012).

Nesse módulo, três subprocessos são realizados. O primeiro é a estimativa dos processos físicos do dossel, que envolve simular o balanço de energia, de água e os fluxos de carbono da interface planta-atmosfera; O segundo é a estimativa dos

processos fisiológicos da planta, que envolve simular a condutância estomática, as respostas fotossintéticas e de respiração foliar; E o terceiro subprocesso corresponde as estimativas da física do solo, que envolve realizar simulações sobre o balanço de energia e água no solo (AMUTI et al., 2018; COLMANETTI et al., 2022).

Nessa etapa, por ser o modulo de entrada das forçantes, o clima afeta diretamente todas as simulações e seus efeitos serão propagados para os demais processos. Isso é observado pois é uma etapa em que temos estimativas da temperatura e da umidade dossel, balanço de radiação, estimativa da radiação fotossinteticamente ativa absorvida, cálculos de fluxos turbulentos, cálculo de evapotranspiração, cálculo do albedo superficial, cálculo do fluxo de calor e balanço de agua no solo, conferindo a utilização de todas as variáveis climáticas mencionadas anteriormente (AMUTI et al., 2018; COLMANETTI et al., 2022; FOLEY et al., 1996; KUCHARIK et al., 2000; KUCHARIK; BRYE, 2003; WEBLER et al., 2012).

Os resultados das simulações desse modulo são propagados em duas direções. Informações sobre a respiração foliar e fotossíntese bruta seguem para o módulo de dinâmica da cultura, enquanto informações de temperatura do ar e do solo, fotossíntese e graus-dias acumulados seguem para o módulo de fenologia da cultura.

O modulo de dinâmica da cultura é responsável por simular produtividade primária bruta, respiração total, produtividade primária líquida e, a partir desses cálculos, o modulo realiza a simulação da alocação de carbono e nitrogênio para os diferentes constituintes da planta (raízes, folhas, galhos, grãos...), conseqüentemente estimando o crescimento e senescência de cada um deles. Esse módulo resulta em informações sobre a estrutura da vegetação e produção da biomassa que, em seguida, são utilizadas como entrada no módulo de fenologia da cultura (AMUTI et al., 2018; BENEZOLI et al., 2021; WEBLER et al., 2012).

Durante as simulações, esse modulo pode ser afetado pelo clima de modo indireto e/ou direto. O modo indireto se refere aos efeitos do clima que ocorreram no módulo anterior e foram herdados até o presente módulo, como alterações nas taxas de respiração ou mudança no saldo fotossintético. O modo direto, é em relação as simulações que são realizadas neste módulo e dependem diretamente

das forçantes climáticas como, por exemplo, a diferença entre temperatura diária do ar e a temperatura basal de desenvolvimento da cultura regando a penalização no acúmulo e particionamento da matéria seca (FOLEY et al., 1996; KUCHARIK et al., 2000; KUCHARIK; BRYE, 2003). Os resultados das simulações desse módulo são propagados principalmente para o módulo de fenologia da cultura, o qual receberá as informações referentes ao acúmulo total de biomassa, além de informações sobre particionamento e estrutura da planta.

O módulo de processos biogeoquímicos do solo apresenta dois subprocessos relacionados aos ciclos do carbono e do nitrogênio, tanto em relação à adição de carbono no solo, quanto redução. Considerando o ciclo do carbono, são realizadas simulações sobre a decomposição da serapilheira, da quantidade de matéria orgânica no solo e da taxa de respiração do solo. Para o nitrogênio, são realizadas simulações sobre processos de mineralização do nitrogênio, fertilização, decomposição, fixação, lixiviação e absorção pela planta (BENEZOLI et al., 2021; WEBLER et al., 2012).

Neste módulo, como resultado temos as simulações da relação de disponibilidade dos nutrientes presentes no solo para a planta, ou seja, carbono e nitrogênio total do solo, carbono proveniente da deposição de matéria orgânica acima e abaixo do solo, fluxo de dióxido de carbono ( $\text{CO}_2$ ) do solo, mineralização/imobilização de nitrogênio e lixiviação de nitrogênio. Nesta etapa o clima afeta especialmente pelas condições de temperatura e umidade do solo, influenciando diretamente não apenas na quantidade desses nutrientes simulada, mas, também, no tempo necessário nos seus processos de decomposição e mineralização, influenciando a viabilidade da sua absorção durante o desenvolvimento da planta (FOLEY et al., 1996; KUCHARIK et al., 2000; KUCHARIK; BRYE, 2003). Os resultados desse módulo interagem diretamente com o módulo de dinâmica da cultura, permitindo uma simulação dinâmica entre a ciclagem dos nutrientes no solo e absorção pela planta para o desenvolvimento de suas estruturas.

O último módulo, de fenologia da cultura, é o módulo responsável em simular o desenvolvimento fenológico da cultura, indicando quando ocorrem as mudanças dos estágios fenológicos, além de suas durações em escala diária. Esse módulo recebe as informações de fotossíntese e temperatura do módulo de

processos da superfície terrestre, e recebe também as informações sobre a estrutura da vegetação e biomassa acumulada, resultantes das simulações realizadas no módulo de dinâmica da cultura. Como retorno, esse módulo fornece informações temporais quanto ao desenvolvimento da cultura e realimenta o primeiro módulo com atualizações sobre o índice de área foliar, o que dá início à uma nova iteração do modelo, e assim as simulações citadas anteriormente vão atualizando a cada dia do ciclo simulado (AMUTI et al., 2018; BENEZOLI et al., 2021; WEBLER et al., 2012).

Este estudo utiliza o PFT da palma de óleo e a versão aqui aplicada herdou praticamente os mesmos parâmetros ajustados por Benezoli *et al.* (2021), que desenvolveu esse PFT com base em observações realizadas na mesma área de estudo deste trabalho. Apenas três parâmetros foram alterados em relação ao estudo anteriormente mencionado (tabela 5), na qual essas modificações tiveram por objetivo melhorar as estimativas de modo generalista, corroborando com as informações apresentadas por Corley e Tinker (2015) além de alinhar ao manejo do cultivo adotado pela Agropalma.

Tabela 5 – Descrição dos parâmetros modificados para aplicação do modelo ECOSMOS-*Palm*.

	Descrição	Valor antigo	Valor novo	Referência
baset	Limiar de temperatura mínima, expressa em kelvin, para o crescimento do dendezeiro.	288.16	289.16	Corley e Tinker (2015)
mxtmp	Número máximo de graus-dia, expresso em graus celsius, que a planta pode acumular a partir da diferença entre temperatura observada e baset.	25	8	Corley e Tinker (2015)
mxage	Idade máxima de vida da planta.	35	33	Dados de produção

Fonte: O autor.

Considerando os parâmetros de temperatura, “baset” foi modificado para registrar desenvolvimento vegetal apenas a partir de 16°C, enquanto “mxtmp” foi

modificado para que o acúmulo máximo de unidades térmicas estabilize a partir dos 24°C, que é média da faixa ótima de desenvolvimento da palma de óleo, ambos de acordo com informações apresentadas por Corley e Tinker (2015). No caso do parâmetro “mxage”, a mudança foi baseada nos dados de produção apresentarem queda drástica após os 27 anos, anulando completamente a produção nos talhões com plantas de 33 anos de idade, apresentando replantio no ano seguinte.

Os dados de saída do ECOSMOS referentes a produção são apresentados em quilogramas de carbono por metro quadrado (Kg.C/m<sup>2</sup>). Para que fosse possível comparar o resultado dos modelos com a produção observada, foi necessário aplicar uma equação de transformação (equação 8) para converter a produção saída do modelo para toneladas de cachos de frutos frescos por hectare (t.FFB/ha).

$$Prod_{t.FFB/ha} = \frac{Y_{Kg.C/m^2} * 10}{FracC * FracDM}, \quad (8)$$

em que  $Y_{Kg.C/m^2}$  é a produção saída do modelo,  $FracC$  é a fração de carbono na massa seca (usualmente 0.5), e  $FracWM$  é a fração de massa seca em relação a massa fresca para os cachos de frutos frescos, onde se adota o valor de 0.5275 para a palma de óleo (CORLEY; HARDON; TAN, 1971).

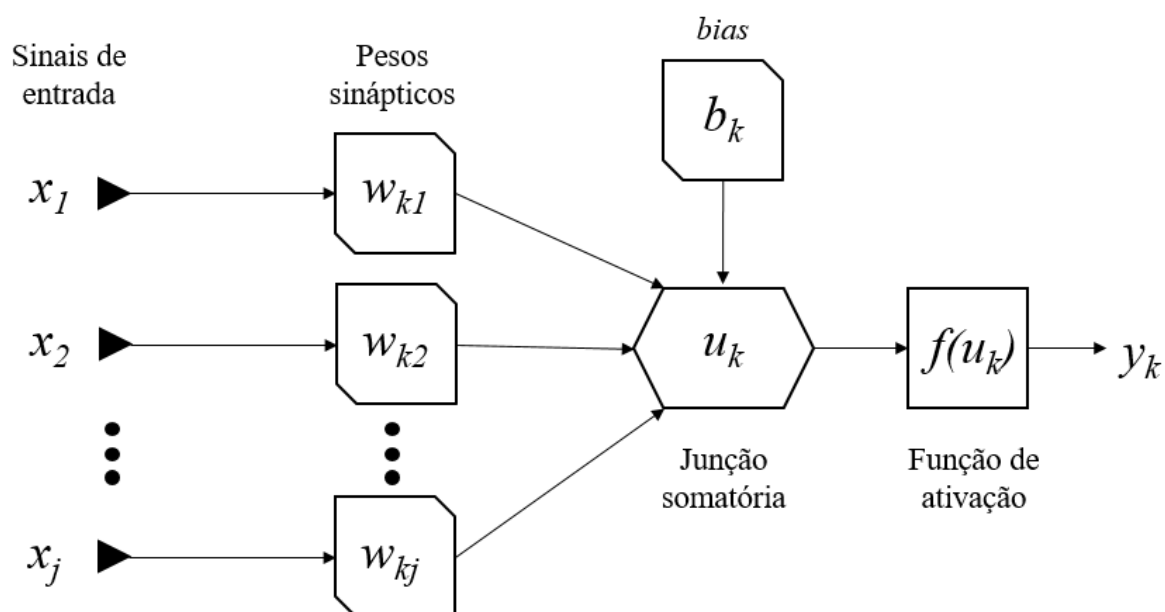
### 3.3.2. Rede Neural Artificial

A Rede Neural Artificial (RNA) é uma técnica inspirada no funcionamento sináptico do sistema nervoso biológico, sendo capaz de aprender com ocorrência de padrões observados e generalizá-los, permitindo apresentar soluções para problemas com aspecto semelhante, mesmo que não sejam ocorrências idênticas às apresentadas durante a fase de treinamento. De modo geral, RNA tem a capacidade de aproximar qualquer função contínua ou não contínua, apresentando considerável utilidade ao modelar sistemas não lineares (AMARATUNGA et al., 2020; BISHOP, 1995; CUNHA; SILVA, 2020).

Por se basear em um sistema composto por atividades de neurônios biológicos, a RNA tem seu funcionamento apoiado em subprocessamentos de sinais realizados por neurônios artificiais, também denominados de “*perceptrons*”, com estrutura semelhante à observada nos neurônios biológicos. Analogamente,

os sinais de entrada, semelhantes as sinapses, são associados os pesos que ponderam a propagação do sinal até a junção somatória, respectivamente similares às atividades dos dendritos e do corpo de neurônio, também chamado de soma (figura 7) (AMARATUNGA et al., 2020; BISHOP, 1995; KUWATA; SHIBASAKI, 2016).

Figura 7 – Representação da estrutura de um neurônio artificial simples empregado em técnicas de Redes Neurais Artificiais.



Fonte: O autor.

A partir da junção somatória, o sinal passa pela função de ativação que realiza uma transformação desse sinal, desde que atinja um limiar de ativação, resultando em um sinal de saída que pode ser levado a uma nova unidade de processamento sináptico, assim como ocorre nos axônios, ou entregar uma saída-solução de acordo com a estrutura definida pelo usuário (KEANE; NEAL, 2020). A saída computacional do neurônio artificial pode ser obtida conforme apresentada pela Equação 9.

$$y_k = f(u_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right), \quad (9)$$


em que  $y_k$  é o valor de saída do neurônio  $k$ , associado diretamente à  $f(u_k)$ , que é a função de ativação adotada pelo neurônio atuando sobre  $u$ , que é a junção somatória, que pondera cada observação  $j$  do sinal de entrada  $x_j$  utilizando os pesos associados  $w_{kj}$ , e  $b_k$  são os vieses (ou *bias*) de cada camada, que visa modificar a influência dos valores das entradas em cada etapa da propagação do sinal pela rede (GHAHARI et al., 2019; KEANE; NEAL, 2020).

É possível compor uma rede neural combinando várias unidades de processamento (*perceptrons*) conectando-os via canais de atribuição de pesos em arquiteturas variadas de camadas, sendo possível configurar a propagação do sinal em sentido cíclico, isto é, quando o sinal da camada de saída retorna como entrada da rede (recorrente), ou não cíclica, quando a propagação ocorre em avanço linear pela rede (*feedforward*) (BISHOP, 1995; KEANE; NEAL, 2020; MA et al., 2019). De um modo geral, uma RNA estruturada possui camada de entrada, onde os sinais observados são apresentados à rede, camadas intermediárias ou ocultas, onde o processamento é realizado a partir de ponderações do sinal propagado, e camada de saída, onde o sinal processado pela rede é emitido para uma nova unidade de processamento ou para o usuário (Figura 8).

Para que uma RNA consiga aprender um padrão observado, ela deve ser submetida a um processo de treinamento que pode ser não-supervisionado ou supervisionado. Durante um treinamento não-supervisionado, os dados de resposta dependentes das entradas, isto é, dados de referência, não são apresentados para a rede.

No treinamento supervisionado, esses dados referenciais, também identificados como “professor”, são apresentados à rede como forma de quantificação dos erros das estimativas, que são posteriormente propagados em sentido oposto (*backpropagation*), da camada de saída até a camada de entrada, realizando ajustes nos pesos sinápticos, reiniciando assim o ciclo de treinamento com os novos pesos ajustados, de modo a reduzir o erro obtido na saída da rede (AMARATUNGA et al., 2020; BISHOP, 1995; KEANE; NEAL, 2020). Dessa forma, o aprendizado é alcançado a partir da repetição do ciclo de treinamento e ajuste de pesos, até que seja satisfeito um critério de parada, como por exemplo, erro médio das estimativas.

Figura 8 – Esquema estrutural de uma Rede Neural em topologia tipo *perceptron* em multicamadas com duas camadas ocultas em configuração *feedforward*.

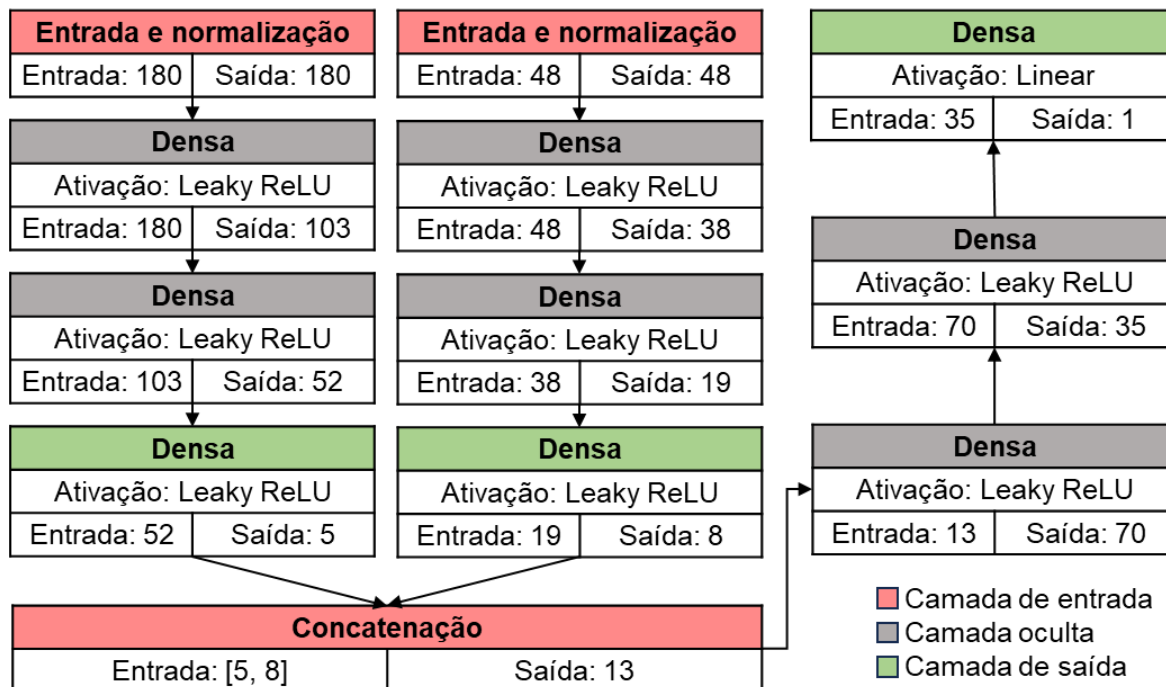


Fonte: O autor.

Para o presente trabalho, cada nó da camada de entrada representa uma das variáveis constituintes do banco de dados, as quais foram submetidas ao processo de normalização, visto que as variáveis utilizadas apresentam diferentes escalas e tipos de dados. Uma parte dos nós apresentou à rede um lote com as variáveis climáticas e seus registros de até 36 meses de antecedência, enquanto outra parte dos nós apresentou à rede um lote com as variáveis do solo, e suas variações por camadas até um metro de profundidade. Os dados referentes a produção da palma de óleo foram utilizados na camada de saída, onde foram diretamente comparados às estimativas obtidas pela rede e o erro calculado foi utilizado como parâmetro de ajuste dos pesos sinápticos durante a fase de treinamento.

Visando uma maior coerência na comparação dos modelos, todos os dados utilizados de entrada no modelo ECOSMOS também foram utilizados na RNA, porém em ramificações de entrada independentes que se baseou na fonte da informação, emulando módulos específicos para a interpretação dos dados de clima e solo. Dessa forma, a RNA aplicada foi estruturada com uma arquitetura em *feedforward*, com configuração de entradas de dados mistos, que isola cada tipo de entrada de sinal em uma rede menor, com um ponto de convergência dos sinais para a rede principal (figura 9).

Figura 9 – Fluxo de processamento entre camadas da rede neural artificial de entradas múltiplas, utilizada para converter os dados de clima e solo em dados de produtividade.



Fonte: O autor.

A configuração da RNA adotada neste estudo, seguiu recomendações de boas práticas para o ajuste de redes neurais em geral, nas quais se assume que redes com duas a três camadas ocultas são suficientes para aproximar sistemas contínuos com elevada precisão e confiabilidade (GÉRON, 2019; HAGAN et al., 2014; HAYKIN, 2017). Como a rede utilizada apresenta uma configuração de entrada mista, atuando como sub-redes, cada uma delas seguiu um padrão de ter uma camada de entrada, duas camadas ocultas completamente conectadas (densas) e uma camada de saída, além de uma camada extra unindo cada sub-rede.

Foram definidas um total de doze camadas, sendo duas de entrada dos dados, seis ocultas, uma de concatenação atuante como entrada para o último segmento da rede, e três camadas de saída. As camadas de saída internas propagaram ao último segmento da rede um número de sinais correspondente as variáveis de entrada de suas respectivas redes, enquanto apenas a última camada de saída apresentou a estimativa da produção da palma de óleo.

Foram adotadas duas funções de ativação para toda a rede, sendo a “*Leaky Rectified Linear Unit*” (Leaky ReLU) para as camadas ocultas e, considerando a natureza regressora da rede estruturada, foi utilizada uma função de ativação “Linear” para a última camada de saída. A função Leaky ReLU é amplamente utilizada por apresentar uma convergência rápida, auxiliando o algoritmo otimizador a encontrar um conjunto de pesos com menor erro possível, além impedir que o nó acabe se tornando nulo na etapa de *backpropagation*, devido sua característica de não se saturar quando o sinal recebido é inferior a zero, permitindo a correção durante o retorno do sinal entre as iterações do modelo (MAAS; HANNUN; NG, 2013; XU et al., 2015).

Outro parâmetro importante para um ajuste adequado das redes neurais, é definir um número ideal de nós de processamento, pois é interessante que a rede utilize um menor número de nós possível para que não ocorra o sobreajuste da rede, penalizando sua capacidade de generalização (GÉRON, 2019; HAYKIN, 2017). Também é necessário tomar cuidado para não utilizar um número baixo de nós, pois isso dificultaria a convergência do modelo, impedindo que as estimativas alcançassem o menor erro aceitável. A equação 10 (HAGAN et al., 2014) foi utilizada para um número ideal aproximado de nós fosse definido para toda a rede.

$$N = \frac{n_{obs}}{((n_{var} + n_{est}) * g)}, \quad (10)$$

em que  $n_{obs}$  é número total de observações que serão utilizadas na rede,  $n_{var}$  é o número total de variáveis de entrada da rede,  $n_{est}$  é o número de variáveis que serão estimadas e  $g$  é um coeficiente de generalização que varia de 2 a 10, sendo 2 recomendado para minimizar a ocorrência de sobreajuste no modelo.

Recomenda-se que a distribuição de nós siga um padrão decrescente nas camadas ocultas da rede, seguindo um padrão de funil entre os sinais de entrada e o de saída (GÉRON, 2019; HAGAN et al., 2014). Para a rede apresentada, os nós foram divididos para cada camada da rede considerando os diferentes estágios de sub-redes e a quantidade de informações que cada uma delas precisou processar.

A partir do cálculo de nós realizado pela equação 10, 33% do total obtido foi utilizado na sub-rede após concatenação, enquanto os 66% restantes foram distribuídos entre as duas primeiras sub-redes que receberam os dados de clima e

solo. Dessa fração de 66% distribuído entre as primeiras sub-redes, 73% foi distribuído entre as camadas da sub-rede que processou os dados climáticos, enquanto 27% foi distribuído entre as camadas da sub-rede que processou os dados de solo, o que corresponde a proporção de entradas entre as duas sub-redes.

### **3.4. Análise de sensibilidade**

Visando avaliar os impactos das mudanças do padrão da estação chuvosa da região na produção da palma de óleo, foram realizadas alterações do padrão observado nos dados de precipitação, simulando mudanças graduais em suas médias e períodos de ocorrência. Foram consideradas alterações no total precipitado anual, no período em que a estação chuvosa ocorreu e no modo em que a chuva foi distribuída ao longo do ano.

Para avaliar o total precipitado anual, foram realizadas alterações nas médias mantendo o mesmo perfil de ocorrência observado, com modificações graduais de 10% acima ou abaixo da média observada. O fator de modificação que variou de 0 a 2, com passos de 0.1, foi utilizado multiplicando os dados de precipitação a nível de observações diárias, o que garantiu que a assinatura pluviométrica não fosse perdida, respeitando a intensidade e momento de ocorrência das chuvas na série histórica. Essa variação foi identificada por  $T \pm n$ , sendo  $n$  variando de 10 a 100 para 10% de alteração até 100% de alteração, respectivamente.

No caso da defasagem temporal, a avaliação se baseou na alteração da data típica de início do período chuvoso, com modificações graduais de um mês de adiantamento ou atraso da entrada da estação chuvosa de cada ano. Esse efeito foi obtido realizando uma espécie de “rolagem” mensal na série de dados da precipitação, onde toda a chuva precipitada em um determinado mês, foi movida  $n$  meses para frente ou para trás, sendo  $n$  a amplitude da defasagem temporal simulada, variando de -6 a 6. Essa variação foi identificada por  $D \pm n$ , sendo  $n$  variando de 1 a 6 para um mês de alteração até seis meses de alteração, respectivamente.

Para não haver uma influência mista pela modificação do total anual precipitado, a rolagem foi realizada obedecendo um subconjunto anual, no qual, por exemplo, dados de dezembro que foram movidos em um mês para frente, foram colocados em janeiro do mesmo ano, não do ano seguinte.

Por último, para avaliar diferentes assinaturas de distribuição do total precipitado, foram realizadas alterações da concentração do total precipitado ao longo do ano, com modificações graduais entre as classes de Índice de Concentração de Precipitação (ICP). O ICP é comumente utilizado para a caracterização geral da série temporal de precipitação mensal observada em uma dada região, no qual quanto menor o seu valor, maior a uniformidade da distribuição da precipitação ao longo do ano (DE LUIS et al., 2011; GONÇALVES; BACK; SUTIL, 2018; MICHIELS; GABRIELS; HARTMANN, 1992; OLIVER, 1980). Esse índice pode ser calculado pela Equação 11.

$$ICP = 100 * \frac{\sum_{i=1}^{12} P_i^2}{(\sum_{i=1}^{12} P_i)^2}, \quad i = 1, 2, \dots, n \quad (11)$$

em que P é a precipitação correspondente a observação mensal i do ano em avaliação e ICP é o Índice de Concentração de Precipitação, adimensional, classificado conforme tabela 6.

Tabela 6 – Classificação da distribuição do total precipitado em relação aos valores de ICP.

ICP	Distribuição
<10	Uniforme
Entre 10 e 16	Moderadamente concentrada
Entre 16 e 20	Concentrada
>20	Fortemente concentrada

Fonte: Adaptado de Michiels, Gabriels e Hartmann (1992).

Antes de realizar as modificações no ICP da região, foi necessário identificar o momento em que se iniciam e terminam os períodos secos e chuvosos da região. Para identificar esses momentos, a análise de anomalia acumulada (LIEBMANN et al., 2007) foi realizada na série histórica de precipitação diária, onde o acúmulo pode ser obtido pela equação 12.

$$A_D = \sum_{n=1}^D [P_n - \bar{P}] , \quad D = 1, 2, \dots, n \quad (12)$$

em que D é o dia atual em que o acúmulo está sendo realizado, n é cada observação da série de dados sob processo de iteração,  $A_D$  é o acúmulo da anomalia de precipitação até o dia D,  $P_n$  é a precipitação total (mm) do dia n e  $\bar{P}$  é a precipitação média (mm) do ano em análise.

A identificação dos meses de entrada do período chuvoso e período seco serviu para que a modificação do ICP fosse realizada reduzindo a precipitação ocorrida durante os meses da estação mais chuvosa e adicionando proporcionalmente nos meses da estação menos chuvosa. Inicialmente foi necessário contabilizar o total precipitado durante toda a estação seca e chuvosa e, partindo dessa informação, a redução foi realizada gradualmente seguindo passos de 10% e o ICP foi recalculado a cada iteração. O processamento se encerrou ao obter os padrões de precipitação para as quatro classes de ICP para cada estação meteorológica.

Visando garantir a proporcionalidade das modificações no regime de precipitação, foram calculados para todos os dias da série seus respectivos percentuais de contribuição de precipitação para a temporada em que está inserido. Essa informação serviu para guiar a quantidade de chuva retirada e adicionada a cada iteração do processo de modificação do ICP, onde cada dia teria a redução ou aumento da precipitação igual ao total modificado na estação, ponderado pela sua própria contribuição. Esse método permitiu alterar a distribuição das chuvas mensais na região, porém preservando sua assinatura de precipitação diária, não afetando indiscriminadamente os períodos característicos de esgotamento e recarga hídrica do solo.

### 3.5. Análises estatísticas

#### 3.5.1. Comparação entre modelos

Métricas de precisão e erro foram utilizadas nesta etapa de comparação entre modelos, sendo elas o coeficiente de correlação de Pearson (PEARSON, 1893), índice de concordância de Willmott (WILLMOTT, 1981), Raiz do Erro Quadrático Médio (PINDYCK; RUBINFELD; RUBINFELD, 1991) e o viés (COLE, 1981). Tais medidas possibilitaram realizar comparações diretas entre os conjuntos de dados observados e simulados, permitindo verificar qual das duas abordagens apresentou maior acurácia em relação aos dados observados.

O coeficiente de correlação de Pearson ( $r$ ) (Equação 13) quantificou a relação estatística entre as séries pareadas de dados, de forma que fosse possível verificar, mesmo que de forma simplificada, como as variabilidades dos diferentes conjuntos estão relacionadas.

$$r = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}}, \quad i = 1, 2, \dots, n \quad (13)$$

em que  $x$  são os dados de produção observados, tomados como referência,  $y$ , os dados de produção obtidos dos modelos,  $n$  é o número de observações do banco de dados e  $r$  é o índice de correlação, variando de -1 a 1, onde valores próximos a 0 conotam uma relação fraca entre os conjuntos de dados avaliados, enquanto valores próximos de 1 e -1 conotam uma relação forte entre os conjuntos de dados avaliados, sendo valores positivos indicadores de uma relação diretamente proporcional e valores negativos uma relação inversamente proporcional.

O índice de concordância de Willmott ( $d$ ) (Equação 14) é usualmente foi utilizado para medir o nível de similaridade entre dois conjuntos de dados, permitindo verificar quando as séries apresentam ou não exatidão entre si.

$$d = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (|y_i - \bar{x}| + |x_i - \bar{x}|)^2}, \quad i = 1, 2, \dots, n \quad (14)$$

em que  $x$  são os dados de produção observados, tomados como referência,  $y$ , os dados de produção obtidos dos modelos,  $n$  é o número de observações do banco

de dados e  $d$  é o índice de concordância, variando de 0 a 1, onde valores próximos a 1 conotam uma concordância perfeita entre os conjuntos de dados avaliados, enquanto valores próximos de 0 conotam uma relação totalmente discordante.

A Raiz do Erro Quadrático Médio (RMSE) (Equação 15) possibilitou verificar a magnitude do erro geral entre conjuntos de dados de mesma fonte ou em mesma escala, resultando em um erro global de mesma unidade dos dados de entrada que, por definição, sempre será maior ou igual a zero. Quanto menor o valor, isto é, quanto mais próximo de zero, maior a precisão e a similaridade entre os conjuntos de dados avaliados.

$$RMSE = \sqrt{\frac{\sum(y_i - x_i)^2}{n}}, \quad i = 1, 2, \dots, n \quad (15)$$

em que  $x$  são os dados de produção observados,  $y$  são os dados de produção obtidos dos modelos,  $n$  é o número de observações do banco de dados e o RMSE é o erro quadrático médio, expresso na mesma unidade da variável  $x$ .

O cálculo do Viés (*Bias*) foi realizado a partir da diferença entre o valor obtido pelo modelo e o valor de produção observada (Equação 16). É uma métrica que representa a tendência ao deslocamento sistemático das estimativas para a direita (positiva) ou para a esquerda (negativa) em torno de um valor central considerado como verdadeiro.

$$Bias = \frac{\sum(y_i - x_i)}{n}, \quad i = 1, 2, \dots, n \quad (16)$$

em que  $x$  são os dados de produção observados, tomados como referência,  $y$ , os dados de produção obtidos dos modelos,  $n$  é o número de observações do banco de dados e o BIAS é o viés total das estimativas, expresso na mesma unidade da variável  $x$ , e quanto mais próximo de zero, menos tendenciosas são as estimativas do modelo, contribuindo para uma maior acurácia.

### 3.5.2. Identificação das mudanças significativas da estação chuvosa

O primeiro passo na etapa de definição sobre quais alterações da estação chuvosa realmente apresentaram influência sobre o comportamento produtivo da

palma, foi verificar a normalidade dos conjuntos de dados de produção observados e simulados. Essa etapa foi realizada com a aplicação do teste de normalidade de Shapiro-Wilk (SHAPIRO; WILK, 1965), e serviu para confirmar ou rejeitar a suposição de normalidade dos dados avaliados, guiando a escolha dos testes paramétricos ou não paramétricos para realizar a análise de variância e o teste de hipótese em sequência. A estatística  $W$  pode ser calculada pela equação 17.

$$W = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad i = 1, 2, \dots, n \quad (17)$$

em que  $x_i$  são as observações dos conjuntos de dados de produção ou simulados e  $a_i$  são coeficientes obtidos baseando-se em valores esperados de estatísticas aleatoriamente amostradas a partir da distribuição normal padrão.

A estatística  $W$ , que indica um grau de similaridade com uma distribuição normal variando de 0 a 1, foi então comparada com um valor crítico tabelado ( $W_c$ ) de rejeição da hipótese nula, que se baseia no número observações que o conjunto apresenta. As comparações que resultarem em  $W \leq W_c$  rejeitam a hipótese nula ( $H_0$ ) e indicam que o conjunto de dados testado não apresenta uma distribuição normal, demandando a aplicação de um teste não-paramétrico para realizar análise de variância do conjunto.

Baseando-se no resultado do teste de normalidade, a análise de variância de Kruskal-Wallis (KRUSKAL; WALLIS, 1952) foi aplicada nos resultados obtidos para cada cenário proposto da análise de sensibilidade, afim de verificar a existência de alguma simulação que distinguisse estatisticamente do grupo de referência. A análise de variância (ANOVA) de Kruskal-Wallis é um teste não-paramétrico equivalente a ANOVA paramétrica de um critério, que visa comparar três ou mais amostras independentes por meio de seus escores. A estatística  $H$  pode ser calculada a partir da equação 18.

$$H = (N - 1) \frac{\sum_{i=1}^g n_i (\bar{r}_i - \bar{r})^2}{\sum_{i=1}^g \sum_{j=1}^{n_i} (r_{ij} - \bar{r})^2}, \quad i, j = 1, 2, \dots, n \quad (18)$$

em que  $N$  é o número total de observações independente do grupo,  $g$  é o número de grupos,  $n_i$  é o número de observações no grupo  $i$ ,  $r_{ij}$  é o ranque geral,

independente do grupo, da observação  $j$  pertencente ao grupo  $i$ ,  $\bar{r}_i$  é o ranque médio de todas as observações do grupo  $i$  e  $\bar{r}$  é a média do  $r_{ij}$ .

A estatística  $H$  foi então comparada com um valor crítico tabelado ( $H_c$ ) de rejeição da hipótese nula, que se baseia no número de grupos comparados e em quantas observações cada grupo tem. As comparações que resultarem em  $H \geq H_c$  indicaram que pelo menos um grupo comparado foi estatisticamente diferentes dos demais, demandando a aplicação de um teste *post-hoc*.

No caso deste estudo, o teste *post-hoc* aplicado foi o teste de Dunn (DUNN, 1964) que realiza uma retificação do nível alfa conforme o número de amostras e, por isso, é considerado um teste mais conservador e robusto. A estatística  $Z$  de Dunn pode ser calculada a partir da equação 19.

$$Z = \frac{|\bar{R}_i - \bar{R}_j|}{\sqrt{\frac{n(n+1)}{12} \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}}, \quad i, j = 1, 2, \dots, n \quad (19)$$

em que  $R_i$  e  $R_j$  é a soma dos postos das amostras comparadas  $i$  e  $j$ ,  $n$  é o tamanho total das amostras comparadas,  $n_i$  e  $n_j$  são o tamanho dos grupos  $i$  e  $j$  que estão sendo comparados.

A estatística  $Z$  foi então comparada com um valor crítico tabelado ( $Z_c$ ) de rejeição da hipótese nula, que se baseia na diferença total entre os conjuntos comparados, a partir das distancias dos dados pareados. As comparações que resultarem em  $Z \geq Z_c$  indicaram que o grupo comparado foi estatisticamente diferente do grupo de referência.


## 4. RESULTADOS E DISCUSSÃO

### 4.1. Reconhecimento da área de estudo

#### 4.1.1. Caracterização da precipitação

O ICP foi calculado ao longo dos dez anos de registros obtidos a partir das estações meteorológicas localizadas na propriedade da Agropalma. Foi possível verificar que, apesar de haver uma variação anual, a região foi classificada com ICP entre 10 e 16 (ICP1016) para todos os anos, indicando uma precipitação moderadamente concentrada entre 2012 e 2021 (figura 10).

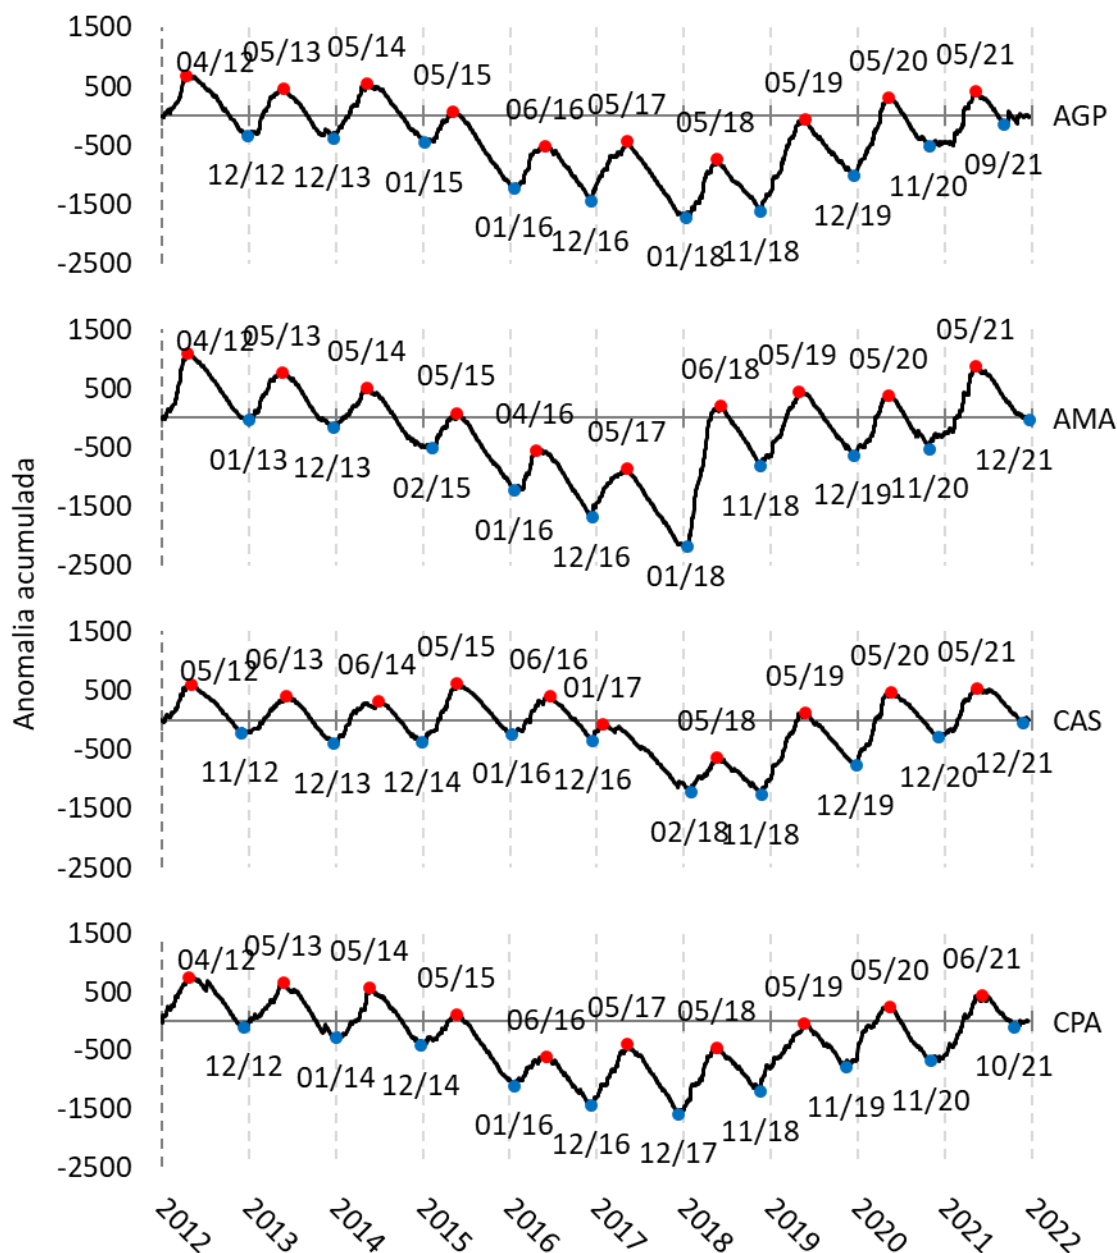
Figura 10 – ICP's calculados com base na precipitação registrada pelas estações meteorológicas instaladas na propriedade Agropalma.



Fonte: O autor.

A anomalia acumulada também foi calculada com sucesso para os registros de precipitação das quatro estações meteorológicas da Agropalma. A figura 11 apresenta os gráficos resultantes desse cálculo, que foram submetidos a uma etapa de identificação de picos e vales, os quais auxiliaram na identificação dos momentos em que as estações seca e úmida se iniciaram na região, sendo marcadas pelos pontos vermelhos e azuis, respectivamente.

Figura 11 – Gráficos de anomalias acumuladas da precipitação para os anos registrados pelas estações meteorológicas instaladas na propriedade Agropalma. Para cada ano, os pontos vermelhos indicam o momento de início da estação seca, enquanto os pontos azuis indicam o momento de início da estação chuvosa.



Fonte: O autor.

Após a marcação dos pontos, foram extraídas as datas de ocorrência desses momentos de interesse, os quais foram subsequentemente tabelados e analisados para definir os períodos mais e menos chuvosos da região. A tabela 7 resume os dados extraídos da figura 11, indicando quais meses ocorreram os momentos de mudança de temporada para cada ano e, com base nos meses de

maior frequência (moda) para cada estação meteorológica, foram determinados os meses característicos para o início da estação seca e da estação chuvosa na área de estudo, sendo maio e dezembro, respectivamente.


Tabela 7 – Síntese das datas extraídas a partir da definição dos momentos de mudança de estação, apontados pela análise de anomalia acumulada.

	Estação meteorológica	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	Moda Estação
Estação seca	AGP	4	5	5	5	6	5	5	5	5	5	5
	AMA	4	5	5	5	4	5	6	5	5	5	5
	CAS	5	6	6	5	6	1	5	5	5	5	6
	CPA	4	5	5	5	6	5	5	5	5	6	5
	Moda ano	4	5	5	5	6	5	5	5	5	5	5
Estação chuvosa	AGP	12	12	1	1	12	1	11	12	11	9	12
	AMA	1	12	2	1	12	1	11	12	11	12	12
	CAS	11	12	12	1	12	2	11	12	12	12	12
	CPA	12	1	12	1	12	12	11	11	11	10	12
	Moda ano	12	12	12	1	12	1	11	12	11	12	12

Fonte: O autor.

A definição do momento de mudança das estações seca e úmidas permitiu determinar quais meses são pertencentes a cada temporada (figura 12), mesmo que a região não tenha uma temporada seca bem definida no calendário por padrão. A partir dessa separação, foi possível observar os níveis de precipitação de cada mês, além de destacar seu nível de contribuição para o total sazonal e suas variações de ano para ano, demonstrando, por exemplo, comportamentos atípicos na precipitação de 2017, onde o mês de março não teve o maior volume de chuvas e, adicionalmente, o mês de novembro não registrou chuvas significativas.

Figura 12 – Distribuição mensal e sazonal da precipitação na região da Agropalma. As barras azuis indicam a precipitação nos meses pertencentes ao período chuvoso, enquanto as barras vermelhas indicam a precipitação nos meses pertencentes ao período seco.




Fonte: O autor.

A distribuição relativa da precipitação foi verificada considerando paralelamente o número de dias em que houve precipitação e o total precipitado em cada ano (figura 13). Para os dias com precipitação, foi possível observar que apesar da proporção de contribuição entre as temporadas seca e úmida não ter se alterado drasticamente entre os anos, houveram reduções graduais no total anual de dias com precipitação até 2017, normalizando gradualmente após esse ano.

Avaliando os totais anuais, as análises da distribuição sazonal da precipitação destacaram a redução drástica no total precipitado ocorrida em 2017, com indícios de ter sido influenciada pela redução do número total de dias com precipitação, pela redução da participação relativa do período seco na precipitação total anual, pelo mês mais chuvoso (março) com níveis reduzidos e pelo mês de novembro sem quaisquer registro de chuvas. Tais condições promovem forte instabilidade na regularidade do regime pluviométrico da região, influenciando não apenas no total precipitado, como também na distribuição dessa precipitação ao longo do desenvolvimento da palma de óleo, potencialmente afetando o balanço hídrico do solo e, conseqüente, podendo refletir negativamente na produção de até 36 meses após esse distúrbio.

Figura 13 – Distribuição relativa sazonal dos dias com precipitação e precipitação total acumulada na região da Agropalma.



Em contraste, a partir de 2018 a precipitação demonstrou um aumento em seus totais, com os últimos quatro anos superando a marca de 2400 mm anuais. Associado ao retorno de número de dias chuvosos aos padrões antes observados, esse efeito oposto ao observado em 2017 evidenciou a tendência de intensificação das chuvas na região de estudo, o que pode ser outro fator capaz que resultar em penalidade produtivas, a depender do solo, manejo e a própria matriz do ecossistema local.

#### 4.1.2. Características do solo

Observou-se que a propriedade da Agropalma se posiciona completamente sobre um terreno com solos classificados como Latossolos Amarelo Distróficos (LAd-) conforme o Sistema Brasileiro de Classificação de Solos (SiBCS) (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA), 2013), com uma baixa porção de sua área apresentando uma variação dessa classificação, sendo ela a combinação do LAd com plintossolos pétricos concrecionários (LAd10). Os Latossolos Amarelos Distróficos (LAd1) são solos desenvolvidos de materiais argilosos ou areno-argilosos sedimentares, caracterizados por possuir cor amarelada uniforme em profundidade, apresentam

boas condições físicas de retenção de umidade e boa permeabilidade(EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA), 2013).

Os LAd1 também são solos muito duros ou extremamente duros no estado seco, tendendo a apresentar problemas de compactação, levando ao enraizamento limitado em profundidade, especialmente pela elevada coesão dos agregados e também por ser distrófico, indicando uma baixa fertilidade natural. A subclassificação LAd10 indica a presença de concreções de óxido de ferro (plintita endurecida e consolidada), podendo formar camadas de compactação ou obstáculos pontuais, dificultando ainda mais a penetração de raízes e, potencialmente, atrapalhando a percolação do excesso de água no solo, além de eventuais trabalhos de manejo do solo (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA), 2013).

Os dados obtidos a partir das amostras de solo demonstraram como o solo da propriedade Agropalma tem zonas tanto com textura arenosa, quanto argilosa (tabela 8), e foi possível observar o predomínio da textura argilosa entre as amostras e seus perfis, destacando a dominância dessa classe textural tanto em área total, quanto em profundidade. Diferente de texturas arenosas, as classes mais argilosas são caracterizadas pelo menor diâmetro dos grânulos, maior resistência à erosão, maior retenção de água, considerável impermeabilidade e, geralmente, apresentam grande concentração de nutrientes.

Realizando um paralelo enquanto as características típicas supracitadas e a área de estudo, a fertilidade e a disponibilidade de água no solo foram os fatores que guiaram a interpretação dos dados. Por se tratar de um solo classificado como distrófico, seus níveis nutricionais não são um destaque, porém, por se tratar de um plantio comercial, a adubação é realizada regularmente e, portanto, a fertilidade não é um problema recorrente.

Considerando a disponibilidade hídrica, a textura argilosa predominante na região tem considerável potencial na manutenção da reserva de água em períodos de estiagem, apoiando o desenvolvimento da palma de óleo nos poucos meses com precipitação abaixo do recomendado, sem penalidades produtivas significativas. Entretanto, acende-se um alerta quanto aos indícios de intensificação da precipitação na região associada à drenagem local prejudicada não apenas pela fração argilosa do solo mas, também, pela ocorrência de área com formação de

camadas de compactação pela presença de plintitas, o que poderia resultar em alagamentos por longos períodos e, dessa forma, promover o afogamento das raízes, além da intensificação da ocorrência de doenças e disfunções nutricionais.

Tabela 8 – Síntese dos dados granulométricos e de classificação do solo das áreas amostradas na Agropalma.

Amostra	Classe do solo	Perfil	Camada (cm)	Areia (%)	Argila (%)	Silte (%)	Classe textural
J32	LAd1		1 0-10	87.82	5.84	6.34	Arenosa média
			2 20-40	90.31	4.68	5.00	Muito arenosa
			3 80-100	90.78	3.96	5.26	Muito arenosa
O33	LAd1		1 0-10	80.17	15.60	4.23	Média arenosa
			2 20-40	77.15	17.16	5.69	Média arenosa
			3 80-100	12.49	53.22	34.28	Argilosa
B09	LAd1		1 0-10	74.80	19.46	5.75	Média arenosa
			2 20-40	54.98	38.33	6.69	Argilosa
			3 80-100	44.92	44.66	10.42	Argilosa
D04	LAd10		1 0 -10	72.59	21.84	5.57	Média argilosa
			2 20 - 40	62.11	30.71	7.18	Média argilosa
			3 100 -120	58.66	34.90	6.43	Média argilosa
E02	LAd10		1 0-10	79.55	14.44	6.01	Média arenosa
			2 20-40	57.78	34.73	7.49	Média argilosa
			3 80-100	55.18	38.38	6.45	Argilosa
M48	LAd10		1 20-40	34.17	56.01	9.82	Argilosa
			2 40-60	62.44	27.90	9.67	Média argilosa
			3 80-100	25.38	63.29	11.33	Muito argilosa

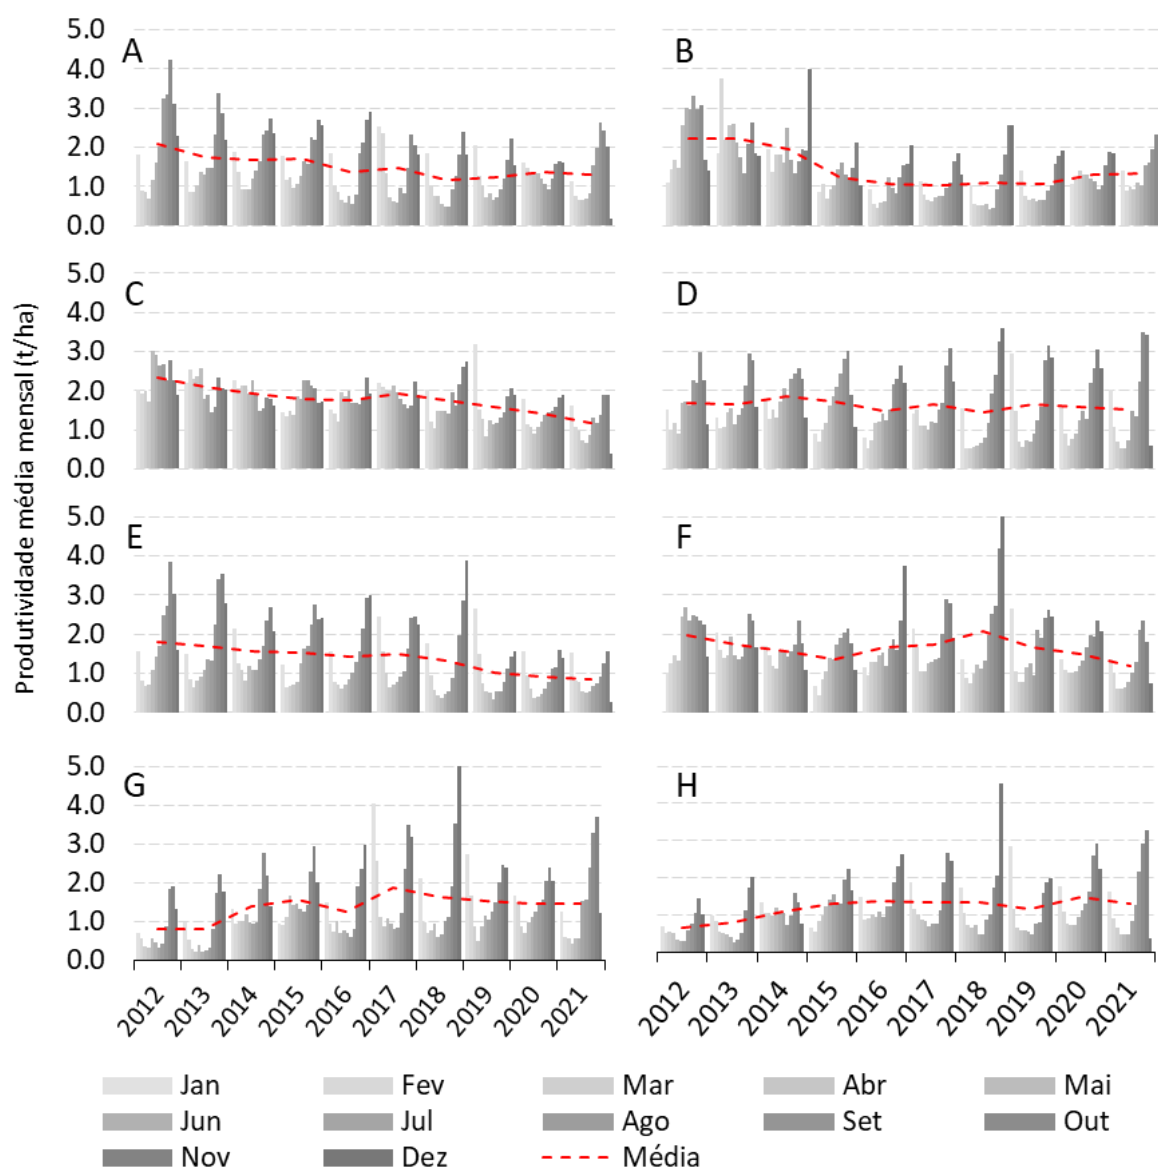
Fonte: O autor.

#### 4.1.3. Produção da palma de óleo

As informações quanto à produção mensal por talhão foram extraídas do banco de dados após sua classificação quanto a fazenda pertencente, o que permitiu traçar a dinâmica produtiva contínua ao longo dos anos em toda a propriedade (figura 14). A partir da assinatura temporal gerada, foi possível verificar como as fazendas da Agropalma apresentaram comportamentos diferentes ao longo tempo dentro de uma mesma região, principalmente devido a diferenças de

idade das plantas, porém, uma queda de produção se mostrou persistente em diferentes fazendas a partir do ano de 2018, o que não se refletiu por uma similaridade de idade das plantas ou de posicionamento geográfico.

Figura 14 – Dados de produtividade observada (t/ha) da palma de óleo, consolidados mensalmente para cada fazenda da Agropalma.




Fonte: O autor.

Após a avaliação da produção mensal os dados foram consolidados por ano e organizados pela idade de cada fazenda (figura 15), o que permitiu observar o padrão produtivo da propriedade e identificar eventos que impactaram de modo geral em toda área, demonstrando também como plantas com diferentes idades responderam a esses eventos. Foi possível observar que a média produtiva da

propriedade Agropalma flutua entre 25 e 30 t/ha, porém, após o ano de 2017, essa flutuação se tornou mais acentuada negativamente, alterando o patamar produtivo da propriedade nos anos seguintes.

Figura 15 – Dados de produtividade geral (t/ha) da Agropalma, consolidados por ano e por fazenda, organizadas em ordem crescente do ano de implementação.



Fonte: O autor.


A figura 15 destacou que houve uma queda notável da produção em praticamente toda propriedade em 2019, sendo um possível reflexo da ocorrência atípica de precipitação muito abaixo da média no ano de 2017, corroborando com estudos que apontaram tais efeitos com latência de até 36 meses. Após o ano de 2019, há uma aparente dificuldade para a retomada produtiva em cada fazenda e, ao avaliar o ano de implementação, foi possível notar que as plantas mais velhas apresentaram maior resiliência, indicando uma possível recuperação apesar de estarem em final de período produtivo, enquanto plantas mais novas demonstraram indícios de recuperação com desenvolvimento tendendo a um platô produtivo precoce.

Conseqüentemente, as plantas mais novas apresentaram sinais de que possivelmente não atingirão o máximo produtivo esperado, mas, para se ter certeza desta previsão, são necessárias mais informações de produtividade que estão além do limite temporal do banco de dados obtido e, portanto, maiores conclusões nesse aspecto não são possíveis no momento.

## 4.2. Escolha do modelo para simulações

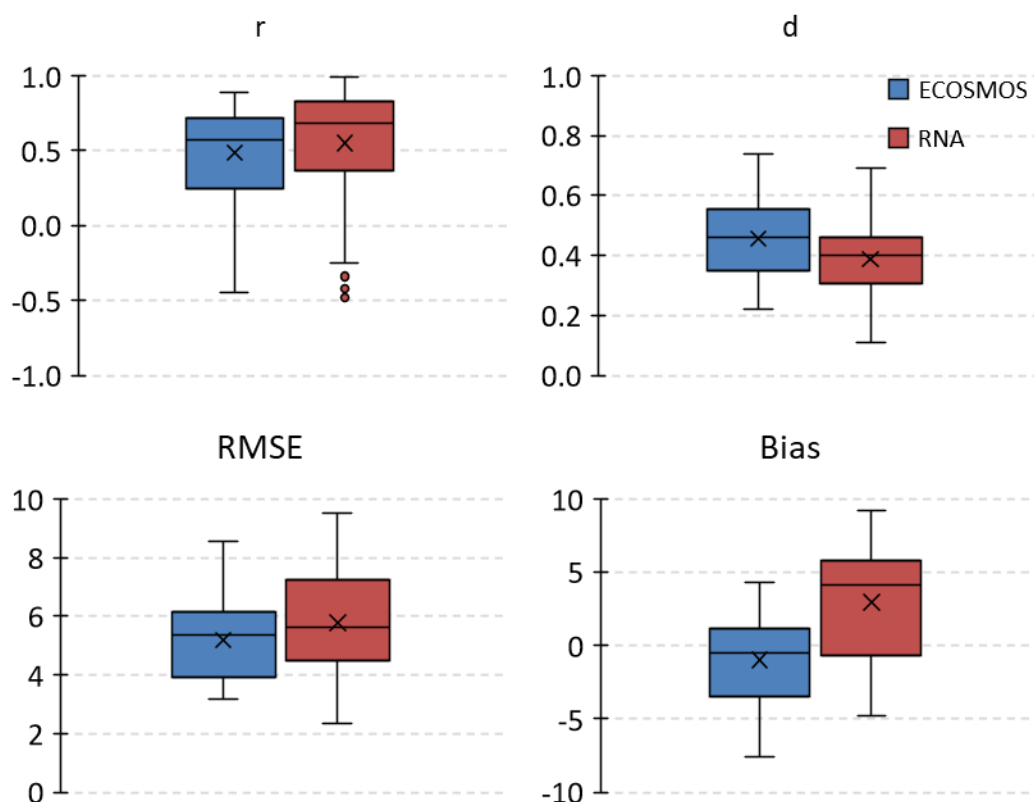
Ambos modelos conseguiram gerar informações quanto a produtividade média para as diferentes condições de combinação entre dados de clima, solo e idade das plantas para a área de estudo (figura 16). Foi possível notar que, apesar de ambas simulações apresentarem uma assinatura semelhante, a RNA apresentou um patamar inferior ao esperado, enquanto o ECOSMOS apresentou uma produtividade média em patamar semelhante os dados observados.

Figura 16 – Produtividade da palma de óleo, por idade, estimados pelos modelos ECOSMOS-*Palm*, em azul, e pela RNA, em vermelho.



Avaliando as métricas de precisão e erro, foi possível avaliar melhor como foi a performance de cada modelo em estimar os dados de produtividade observados (figura 15). A correlação ( $r$ ) foi a única medida a indicar vantagem para os dados obtidos a partir das simulações via RNA e, ainda assim, os dados gerados pelas simulações via ECOSMOS também obtiveram pontuações aproximadas, destacando com ambos modelos conseguiram simular consideravelmente bem a assinatura padrão de produção da palma de óleo.

Figura 17 - Métricas de precisão e erro calculadas a partir dos valores de produtividade (t/ha) observados em campo e simulados pelos modelos para a palma de óleo.



Fonte: O autor.

As demais métricas apontam uma leve vantagem para o ECOSMOS, indicando que o modelo apresentou maior concordância entre valores observados e estimados de modo pareados (d) e menor erro médio (RMSE), ambas métricas também com menor variação se comparadas às da RNA. Em especial para o viés (Bias), apesar de apresentar leve deslocamento negativo, o ECOSMOS apresentou valores menos variáveis e com ponto médio mais aproximado de zero, indicando baixo enviesamento das estimativas, reforçando um bom ajuste das simulações, mas ainda demandando testes estatísticos para confirmar sua validade para representar as condições observadas em campo.

Os testes estatísticos foram aplicados afim de comparar diferenças entre os dados de produção observados (Obs) e os dados de produção obtidos por ambos modelos (tabela 9). Foi constatado que todos os conjuntos de dados não

apresentam padrão de normalidade e que pelo menos um desses conjuntos se distinguia estatisticamente dos demais.

O teste *post-hoc* de Dunn apresentou um valor estatisticamente significativo para a comparação entre os dados de produção observados e os dados obtidos a partir do modelo RNA, indicando que os dois conjuntos de dados são estatisticamente divergentes e, portanto, concluindo que os dados obtidos dessa forma não podem ser considerados representativos para a área de estudo. Por outro lado, confirmou-se que o modelo ECOSMOS alcançou um nível de ajuste que não o distinguiu estatisticamente dos dados observados, reforçando que os resultados obtidos por esse modelo são válidos para representar uma situação real.

Tabela 9 - Resultados obtidos a partir dos testes de normalidade de Shapiro-Wilk, da análise de variância de Kruskal-Wallis e do teste *post-hoc* de Dunn para comparação entre a produção observada e a produção estimada pelos modelos ECOSMOS e RNA.

Shapiro-Wilk	n	Média	D.P.	W calculado	W crítico	Valor-p
Obs	34	15.147	6.645	0.806	0.933	0.009 **
ECOSMOS	34	15.823	6.079	0.639	0.933	0.007 **
RNA	34	12.371	3.555	0.709	0.933	0.008 **

Kruskal-Wallis	G.L.	H calculado	H crítico	Valor-p
Obs-Modelos	3	20.494	7.815	< 0.0001 ***

Teste de Dunn	Diferença	Z calculado	Z crítico	Valor-p
Obs-ECOSMOS	2.382	0.332	2.394	n.s.
Obs-RNA	26.868	3.744	2.394	< 0.05 *

Fonte: O autor.

É importante destacar que este estudo, de modo algum, conclui que modelos da classe de aprendizado de máquina, em especial as redes neurais artificiais, são incapazes de estimar a produção da palma de óleo com base nos dados do clima e do solo em uma área de cultivo. Entretanto, baseando-se nas estatísticas obtidas a partir dos processos de modelagem executados, o modelo baseado em processos ECOSMOS obteve melhor ajuste aos dados observados em campo e foi

o modelo adotado como referência para as etapas de análise de sensibilidade, enquanto a RNA foi desconsiderada partir deste ponto.

### 4.3. Simulações das condições atípicas de estação chuvosa

#### 4.3.1. Teste de normalidade

O teste de normalidade de Shapiro-Wilk foi aplicado em todas as simulações realizadas e também ao conjunto de dados observados (tabelas 10 e 11). Todos os conjuntos de dados para as condições de alteração da distribuição da precipitação e da defasagem temporal tiveram a não normalidade confirmada em alto nível de significância ( $p < 0.01$ ).

Tabela 10 – Resultados obtidos a partir do teste de normalidade de Shapiro-Wilk para os conjuntos de dados de produção observados e simulados, considerando as condições de mudança na distribuição e defasagem temporal da precipitação.

	n	Média	D.P.	W calculado	W crítico	Valor-p		
Obs	34	15.147	6.645	0.806	0.933	0.009	**	
Sim	34	15.823	6.079	0.639	0.933	0.007	**	
Distribuição	ICP10	34	14.319	5.490	0.614	0.933	0.007	**
	ICP1620	34	16.430	6.161	0.627	0.933	0.007	**
	ICP20	34	15.548	5.658	0.577	0.933	0.006	**
Defasagem temporal	D-1	34	17.717	6.904	0.596	0.933	0.007	**
	D-2	34	16.474	6.465	0.603	0.933	0.007	**
	D-3	34	15.697	6.203	0.608	0.933	0.007	**
	D-4	34	14.977	5.900	0.603	0.933	0.007	**
	D-5	34	15.177	5.898	0.601	0.933	0.007	**
	D-6	34	16.046	6.113	0.604	0.933	0.007	**
	D+1	34	16.798	6.277	0.588	0.933	0.007	**
	D+2	34	18.135	6.745	0.588	0.933	0.007	**
	D+3	34	19.403	7.265	0.593	0.933	0.007	**
	D+4	34	20.125	7.672	0.604	0.933	0.007	**
	D+5	34	19.844	7.652	0.598	0.933	0.007	**
	D+6	34	19.183	7.454	0.595	0.933	0.007	**

Fonte: O autor.

Para as condições de modificação do total precipitado (tabela 11), o teste confirmou em nível altamente significativo ( $p < 0.01$ ) a não normalidade para quase todas as simulações. Exceções ocorreram para a redução de 80% (T-80), cuja normalidade foi confirmada em nível significativo ( $p < 0.05$ ), e para a redução de 100% (T-100), na qual o teste não pode ser aplicado.

Tabela 11 – Resultados obtidos a partir do teste de normalidade de Shapiro-Wilk para os conjuntos de dados de produção observados e simulados, considerando as condições de mudança no total da precipitação.

	n	Média	D.P.	W calculado	W crítico	Valor-p	
T-10	34	16.125	6.122	0.607	0.933	0.007	**
T-20	34	16.338	6.192	0.615	0.933	0.007	**
T-30	34	16.402	6.190	0.623	0.933	0.007	**
T-40	34	16.218	6.093	0.630	0.933	0.007	**
T-50	34	15.904	5.958	0.639	0.933	0.007	**
T-60	34	15.056	5.688	0.662	0.933	0.007	**
T-70	34	12.659	5.043	0.774	0.933	0.009	**
T-80	34	6.652	3.212	0.927	0.933	0.016	*
T-90	34	0.433	0.443	0.845	0.933	0.009	**
T-100	34	0.000	-	-	0.933	-	
T+10	34	15.687	5.976	0.607	0.933	0.007	**
T+20	34	15.382	5.854	0.608	0.933	0.007	**
T+30	34	15.202	5.781	0.612	0.933	0.007	**
T+40	34	15.097	5.755	0.630	0.933	0.007	**
T+50	34	15.005	5.728	0.641	0.933	0.007	**
T+60	34	14.895	5.680	0.640	0.933	0.007	**
T+70	34	14.737	5.603	0.635	0.933	0.007	**
T+80	34	14.597	5.534	0.630	0.933	0.007	**
T+90	34	14.430	5.458	0.627	0.933	0.007	**
T+100	34	14.320	5.406	0.622	0.933	0.007	**

Fonte: O autor.

O caso da simulação com redução de 100% no total da precipitação (T-100), não foi possível calcular o W pois não houve produção, resultando em uma série de dados constantes em zero. Entretanto, dada a característica constante da série, a não normalidade foi assumida e a série foi incluída nas etapas seguintes para identificação das simulações estatisticamente significativas.

Dado o desempenho satisfatório do modelo em estimar a produção de referência (Sim) em comparação a produção observada (Obs), era esperado que as métricas dos testes estatísticos fossem semelhantes e que concordassem no resultado. Por esse motivo, a etapa de análise de variância pelo método de Kruskal-Wallis adotou o conjunto de dados simulados pelo ECOSMOS, sem modificações, como referência para comparar com as demais modificações.

#### 4.3.2. Análise de variância

A análise de Kruskal-Wallis foi empregada para todas as condições de mudança da precipitação, sendo cada uma delas analisada de modo independente (tabela 12). Cada nível de alteração foi considerado com um grupo de comparação e os dados simulados sem alteração foram utilizados como controle.

Tabela 12 – Resultados obtidos a partir da análise de variância de Kruskal-Wallis, considerando as condições de mudança na distribuição, defasagem temporal e do total precipitado.

	H calculado	H crítico	G.L.	Valor-p
Distribuição	24.306	9.488	4	< 0.0001 ***
Defasagem	155.102	22.362	13	< 0.0001 ***
Total	274.361	32.671	21	< 0.0001 ***

Fonte: O autor.

Foi possível verificar que todas as condições de mudanças da precipitação apresentaram a estatística H calculada expressivamente maior que a H crítica, obtida a partir de tabela de referência. Essa comparação resultou em um valor-p classificado como muito altamente significativo ( $p < 0.001$ ), confirmando a existência de pelo menos um grupo de dados estatisticamente diferente do grupo de controle em cada uma das condições específicas de alteração da precipitação.

#### 4.3.3. Testes *post-hoc* de Dunn

O teste de Dunn foi aplicado para cada condição de mudança, de forma independente das demais condições, para preservar a homogeneidade de cada

situação atípica de precipitação, evitando que um conjunto de alterações influenciasse no cálculo e análise das métricas estatísticas dos demais. O teste realizado para as condições de mudança na distribuição da precipitação (tabela 13), apontou que a comparação entre os conjunto de dados observados (Obs) e simulados sem alterações (Sim) não apresentaram diferença estatística entre si, reforçando que o modelo conseguiu simular a produção observada com acurácia satisfatória.

Tabela 13 – Resultados obtidos a partir do teste *post-hoc* de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações na distribuição da precipitação.

Comparação	Diferença	Z calculado	Z crítico	Valor-p
Obs - Sim	2.721	0.228	2.807	n.s.
Sim - ICP10	39.809	3.335	2.807	< 0.05 *
Sim - ICP1620	16.441	1.377	2.807	n.s.
Sim - ICP20	13.544	1.135	2.807	n.s.

Fonte: O autor.

Também foi possível observar que apenas a alteração da classe de distribuição da precipitação para ICP10 foi estatisticamente significativa. Considerando que o conjunto de dados da produção observada e, conseqüentemente, o conjunto de dados da produção simulada são classificados como ICP1016, indicando uma precipitação moderadamente concentrada no tempo, constatou-se que há mudança significativa na produção apenas quando a precipitação se tornou mais uniforme ao longo do ano.

Considerando as mudanças na defasagem temporal, a comparação entre os conjuntos de dados observados (Obs) e simulados sem alterações (Sim) continuou sem apresentar diferença estatística entre si e, para as demais alterações, foi possível verificar cinco situações com diferenças constatadas (tabela 14). Foram verificados valores-p significativos apenas na defasagem positiva desde D+2 a D+6, indicando que alterações significativas só foram encontradas quando a precipitação ocorreu com um atraso de dois a seis meses, tomando a assinatura original como referência.

Tabela 14 – Resultados obtidos a partir do teste *post-hoc* de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações na defasagem temporal da precipitação.

Comparação	Diferença	Z calculado	Z crítico	Valor-p
Obs - Sim	6.971	0.209	3.126	n.s.
Sim - D-1	99.838	2.993	3.126	n.s.
Sim - D-2	41.544	1.245	3.126	n.s.
Sim - D-3	2.838	0.085	3.126	n.s.
Sim - D-4	43.809	1.313	3.126	n.s.
Sim - D-5	34.382	1.031	3.126	n.s.
Sim - D-6	12.662	0.380	3.126	n.s.
Sim - D+1	53.868	1.615	3.126	n.s.
Sim - D+2	111.059	3.329	3.126	< 0.05 *
Sim - D+3	158.515	4.751	3.126	< 0.05 *
Sim - D+4	188.309	5.645	3.126	< 0.05 *
Sim - D+5	180.853	5.421	3.126	< 0.05 *
Sim - D+6	156.147	4.680	3.126	< 0.05 *

Fonte: O autor.

No caso das mudanças no total precipitado ao longo do ano, mais uma vez a comparação entre os conjuntos de dados observados (Obs) e simulados sem alterações (Sim) não apresentou diferença estatística entre si, garantindo que as simulações foram validadas para todas as condições avaliadas (tabela 15). Nesse grupo de avaliação, foi possível verificar que os valores-p significativos foram registradas tanto em condições negativas quanto numa situação positiva, contudo, há uma aparente sensibilidade maior às diferenças negativas, pois quatro alterações demonstraram diferença estatisticamente significativa, sendo as reduções de 70% (T-70), 80% (T-80), 90% (T-90) e 100% (T-100), enquanto a alteração positiva apresentou apenas uma situação significativa, sendo o aumento da chuva total em 100% (T+100).

Baseando-se nessas análises, apenas os resultados apontados como estatisticamente significativos pelo teste de Dunn foram analisados quanto as características das novas assinaturas de precipitação e seu impacto na produção. No caso da mudança da distribuição, apenas a assinatura de precipitação para ICP10 foi avaliada, para a defasagem foram avaliadas as alterações de D+2 a D+6

e, para o as mudanças no total precipitado, foram avaliadas as alterações T-70 a T-100 e T+100.

Tabela 15 – Resultados obtidos a partir do teste *post-hoc* de Dunn para os conjuntos de dados de produção observados e simulados, considerando as alterações no total anual da precipitação.

Comparação	Diferença	Z calculado	Z crítico	Valor-p
Obs - Sim	19.015	0.363	3.126	n.s.
Sim - T-10	31.794	0.607	3.126	n.s.
Sim - T-20	52.794	1.007	3.126	n.s.
Sim - T-30	55.588	1.061	3.126	n.s.
Sim - T-40	35.721	0.682	3.126	n.s.
Sim - T-50	2.221	0.042	3.126	n.s.
Sim - T-60	77.132	1.472	3.126	n.s.
Sim - T-70	231.515	4.418	3.126	< 0.05 *
Sim - T-80	316.456	6.039	3.126	< 0.05 *
Sim - T-90	370.677	7.073	3.126	< 0.05 *
Sim - T-100	428.868	8.184	3.126	< 0.05 *
Sim - T+10	16.059	0.306	3.126	n.s.
Sim - T+20	48.912	0.933	3.126	n.s.
Sim - T+30	69.397	1.324	3.126	n.s.
Sim - T+40	81.912	1.563	3.126	n.s.
Sim - T+50	93.103	1.777	3.126	n.s.
Sim - T+60	105.162	2.007	3.126	n.s.
Sim - T+70	122.824	2.344	3.126	n.s.
Sim - T+80	138.132	2.636	3.126	n.s.
Sim - T+90	155.441	2.966	3.126	n.s.
Sim - T+100	166.603	3.179	3.126	< 0.05 *

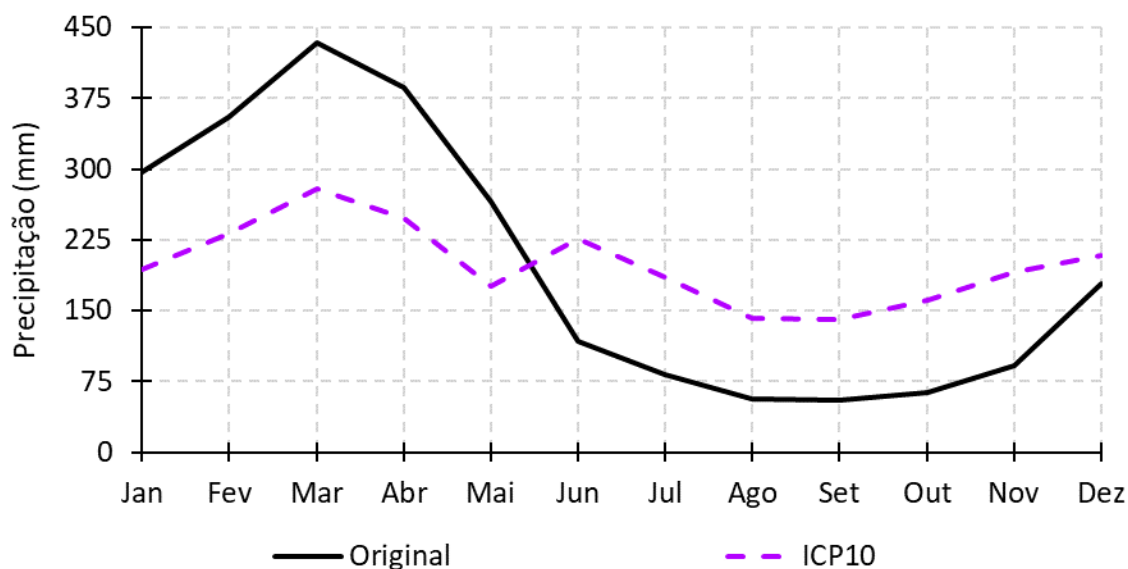
Fonte: O autor.

#### 4.3.4. Distribuição anual

Avaliando as mudanças na distribuição da precipitação, a figura 18 retrata a nova assinatura de precipitação mensal para a região de estudo, ajustados à distribuição de classe ICP10. O novo padrão de precipitação continuou exibindo maior volume de precipitação no primeiro semestre do ano, com redução no

segundo semestre, porém com um volume mensal mais alto e constante ao longo do ano, não havendo registros abaixo de 140 mm/mês.


Figura 18 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de distribuição ICP10.



Fonte: O autor.

Apesar a precipitação ter se tornado mais distribuída ao longo do ano, foi possível observar uma divergência negativa estatisticamente significativa entre a produtividade puramente estimada (Sim) pelo modelo e a produtividade simulada considerando nova assinatura de precipitação (ICP10). Verificando os gráficos sobrepostos de produtividade pela idade da planta (figura 19), foi possível notar que produção simulada começou a divergir das estimada a partir dos oitos anos de idade até o final da idade comercial, resultando em uma diferença de aproximadamente 5.46% (desvio-padrão de  $\pm 0.56\%$ ).

Figura 19 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando a modificação da distribuição anual da precipitação.



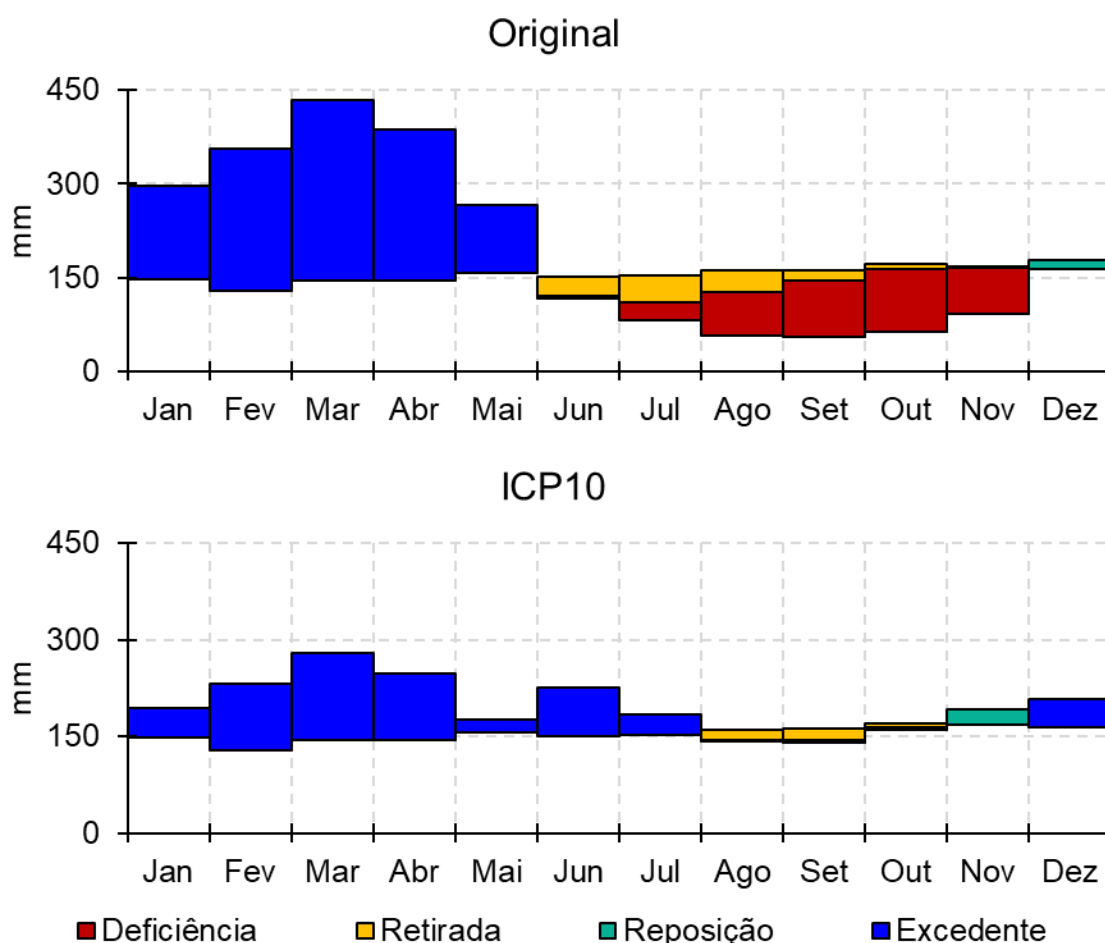
Fonte: O autor.

O balanço hídrico do solo para essa simulação apresentou mudanças tanto nos volumes totais, quanto na assinatura da precipitação padrão, que divergiu do padrão observado no balanço hídrico com base na precipitação original (figura 20). Foi possível observar que a redistribuição da precipitação mensal, para uma condição mais homogênea ao longo do ano, reduziu consideravelmente os meses em que se espera deficiência hídrica, assim como os níveis desse período de deficiência também foram consideravelmente reduzidos.

Avaliando o outro extremo, foi possível notar que a distribuição mais homogênea da precipitação reduziu as chuvas nos meses mais concentrados, contudo, o volume redistribuído foi suficiente para que mais meses apresentassem um estado de excedente hídrico, promovendo um excesso de água no solo por um período mais prolongado que o original. Tal situação pode resultar em penalidades produtivas, pois o fornecimento hídrico em excesso por longos períodos pode causar inundações prolongadas, especialmente em locais em que o solo apresente potenciais problemas de drenagem, afetando negativamente a respiração das raízes e sua capacidade de absorver nutrientes, além de promover a indisponibilidade de nitrogênio no solo, promovendo o amarelecimento de suas

fibras, podendo até mesmo elevar a mortalidade no caso das plantas mais jovens (ABUBAKAR; ISHAK; MAKMOM, 2021).

Figura 20 - Balanço hídrico para a série de dados de precipitação original e para a condições de mudança na precipitação, considerando a distribuição ICP10.




Fonte: O autor.

#### 4.3.4. Defasagem temporal

Avaliando as mudanças no domínio do tempo, a figura 21 retrata a nova assinatura de precipitação mensal para a região de estudo, ajustados às diferentes condições de defasagem temporal. O novo padrão de precipitação não demonstrou qualquer mudança em seus totais, modificando apenas o momento em que os volumes ocorreram, porém agora com o pico de precipitação ocorrendo durante os meses previamente classificados como pertencentes à estação seca.

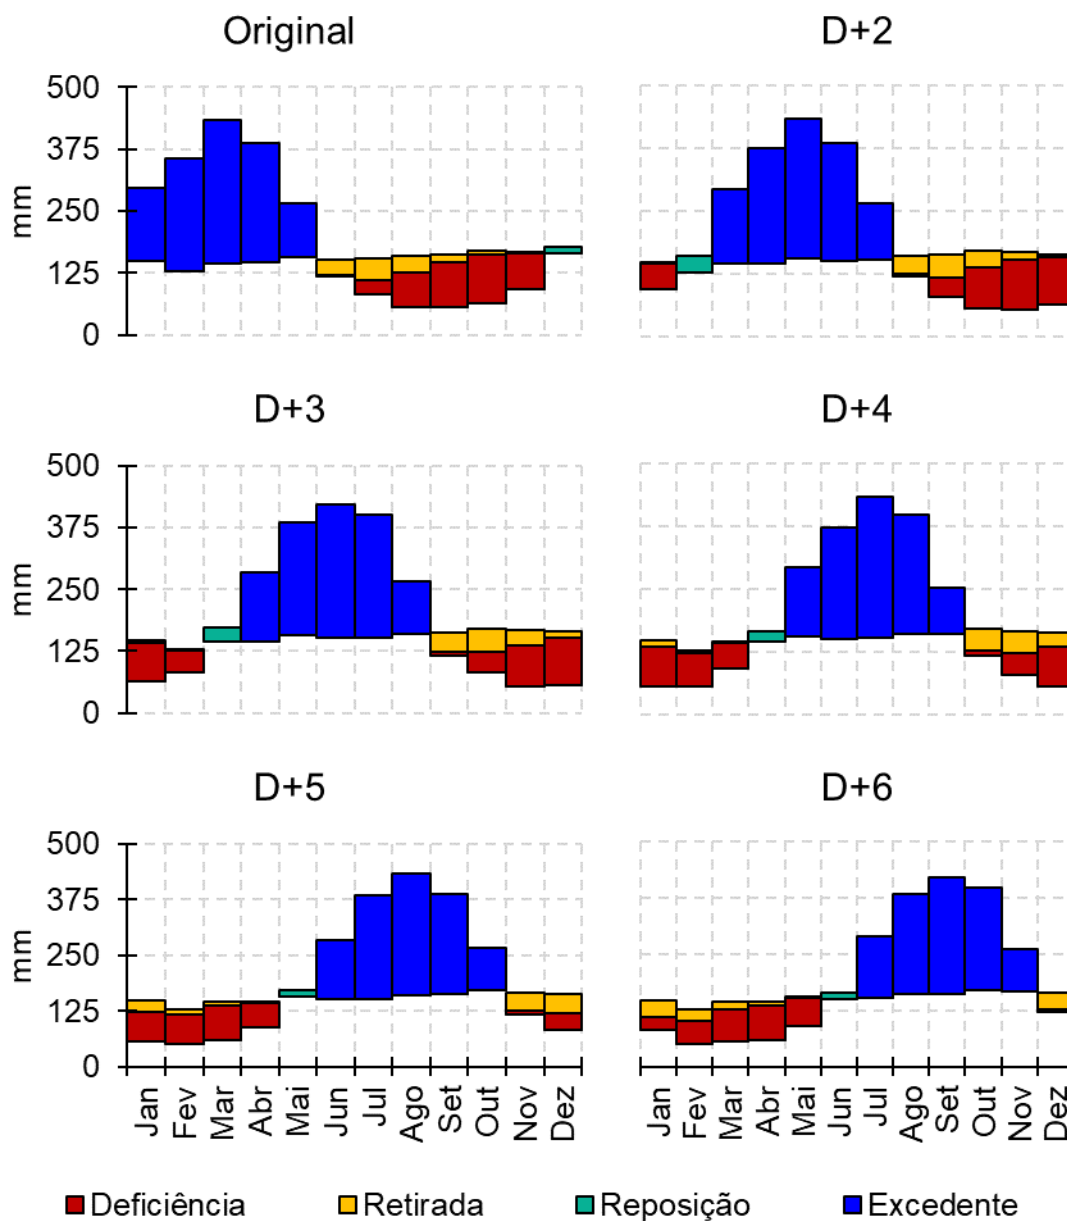
Figura 21 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de defasagem D+2, D+3, D+4, D+5 e D+6.



Fonte: O autor.

O balanço hídrico do solo para essas simulações também não apresentou grandes variações quando comparados ao balanço hídrico com base na precipitação original (figura 22). Devido a abordagem de Thornthwaite para calcular as componentes do balanço hídrico levar em conta a temperatura, é possível observar que há uma pequena variação em relação aos volumes com a mudança dos meses, porém são variações inferiores à 7%, não causando a mudança na classe do estado hídrico mensal.

Figura 22 – Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando as defasagens temporais D+2, D+3, D+4, D+5 e D+6.

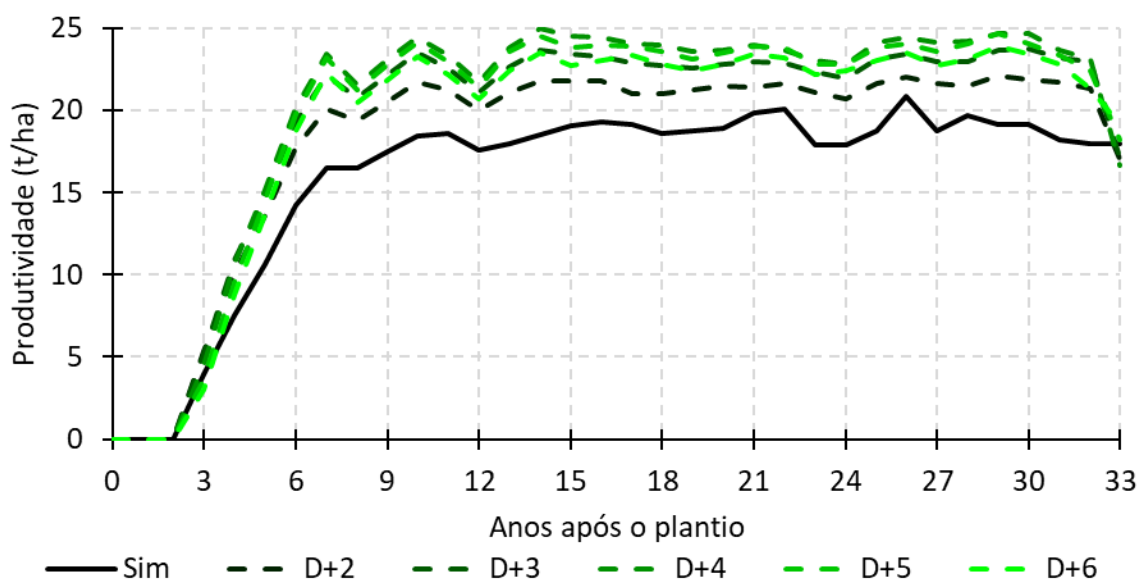


Fonte: O autor.

A produtividade obtida a partir das diferentes condições de defasagem temporal apresentou uma média superior se comparada a produtividade puramente estimada pelo modelo (figura 23). Todas as alterações apresentaram produtividade superior em níveis consideráveis, onde foi possível observar produções aproximadamente 19.72% ( $\pm 0.49\%$ ) superior para a alteração de D+2, 28.10%

( $\pm 0.53\%$ ) para D+3, 32.87% ( $\pm 0.54\%$ ) para D+4, 31.02% ( $\pm 0.53\%$ ) para D+5 e 26.65% ( $\pm 0.52\%$ ) para D+6.

Figura 23 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando as modificações na defasagem temporal da precipitação.




Fonte: O autor.

Considerando a característica de produção contínua da palma de óleo, os comportamentos observados para as produções simuladas não eram esperados apenas pela mudança do momento de ocorrência das chuvas, sem modificação dos volumes. Contudo, ao avaliar as condições que podem ter contribuído para o aumento da produção, foi possível verificar que o deslocamento da estação chuvosa no tempo fez com que os períodos de maiores chuvas coincidisse com os momentos de maior disponibilidade energética (figura 24), onde as maiores produtividades estão associadas aos períodos de intensificação da radiação.

O período supracitado, conseqüentemente, também é um período de elevação da temperatura média, mas não foi observada uma mudança drástica mesmo avaliando a diferença entre os meses mais frio e mais quente, onde a diferença entre suas temperaturas não superou 1.5°C. Dessa forma, em relação a disponibilidade energética, a radiação foi o principal fator aparente para a elevação da produtividade simulada, associada ao fornecimento hídrico atípico.

Figura 24 – Assinaturas anuais de temperatura e radiação solar incidente para a região da propriedade da Agropalma.



Fonte: O autor.


Partindo para um ponto de vista voltado para o manejo e considerando que o plantio em estudo está sob regime hídrico de sequeiro, esse resultado exemplifica como o fornecimento de lâmina d'água complementar em períodos menos chuvosos pode colaborar em aumentar a produtividade dos plantios comerciais. Dessa forma, a irrigação pode ser uma opção para suprir as necessidades dos produtores, não apenas protegendo a cultura de condições atípicas de precipitação, mas, também, potencializando a produtividade.

Os resultados obtidos nesse cenário de simulação corroboram com os dados registrados em trabalhos recentes, nos quais durante a quantificação da produção da palma de óleo, a irrigação se destacou nos resultados registrando aumento em torno de 20 a 30% na produção de frutos frescos por hectare. Este resultado foi obtido a partir da adoção de um sistema de irrigação com a aplicação de 5 mm diários, o que elevou a produção anual de 15 t/ha (sequeiro) para 22 t/ha (irrigado), sendo esse aumento associado à mitigação dos efeitos da estação seca durante o florescimento, garantindo a maior produção de inflorescências femininas e reduzindo as taxas de aborto floral (BRUM et al., 2021; CULMAN et al., 2019; EYCOTT et al., 2019; MENDOZA-HERNÁNDEZ et al., 2021; RHEBERGEN et al., 2019).

#### 4.3.4. Total precipitado

As novas assinaturas de precipitação geradas para as reduções no total precipitado (figura 25) demonstrou que é necessária uma redução drástica das chuvas locais para que a produção fosse significativamente afetada. O novo padrão de precipitação, por se basear numa percentagem aplicada de forma homogênea, não alterou o formato da assinatura de precipitação original, porém, o volume mensal de chuvas foi proporcionalmente reduzido, onde até os meses mais chuvosos não apresentaram registros médios acima de 140 mm/mês.

Figura 25 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de total T-70, T-80, T-90 e T-100.

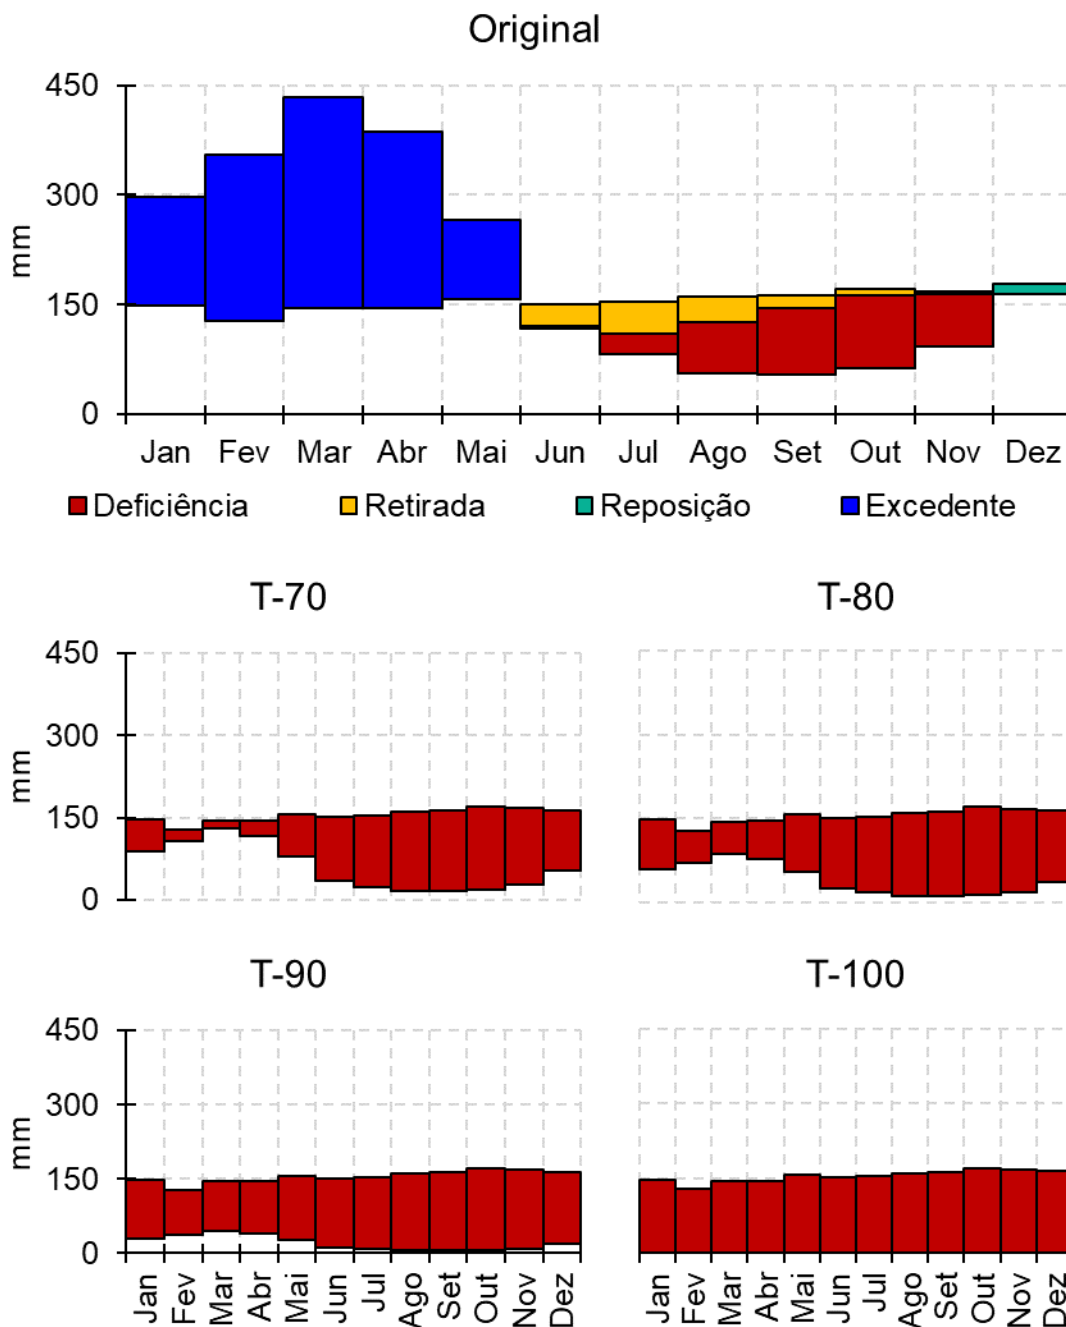


Fonte: O autor.

O balanço hídrico do solo para as simulações de redução do total precipitado, diferente do balanço hídrico da precipitação original, se destacou por apresentar apenas o estado de deficiência hídrica durante todos os meses (figura 26). Foi possível verificar que os primeiros meses do ano são os principais atuantes no fornecimento hídrico, e que o solo tem considerável capacidade de reter a água por vários meses da temporada mais seca, contudo, devido a redução progressiva da precipitação, eventualmente as condições de fornecimento e armazenamento

hídrico se tornaram cada vez mais sutis, até o completo secamento do solo em T-100.

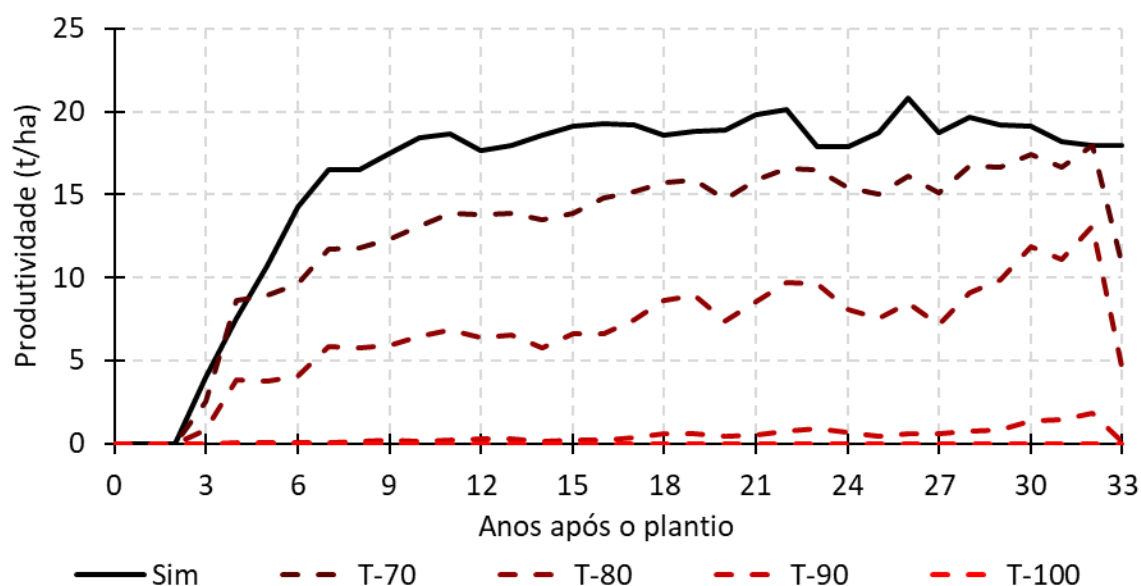
Figura 26 - Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando as reduções no total precipitado T-70, T-80, T-90 e T-100.



Fonte: O autor.

Intuitivamente, as produtividades obtidas a partir das simulações das diferentes condições de redução do total precipitado apresentaram médias inferiores se comparadas a produtividade puramente estimada pelo modelo (figura 27). Todas as alterações apresentaram produtividade inferior, em que seus níveis de penalidade produtiva progrediram em escala potencial em relação a redução da precipitação, onde foi possível observar uma produção 16.42% ( $\pm 0.62\%$ ) inferior para a alteração de T-70, 56.08% ( $\pm 0.93\%$ ) inferior para T-80, 97.14% ( $\pm 1.25\%$ ) inferior para T-90 e, desconsiderando a mortalidade da planta, 100% ( $\pm 1.27\%$ ) inferior para T-100.

Figura 27 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando as modificações na redução do total da precipitação anual.



Fonte: O autor.

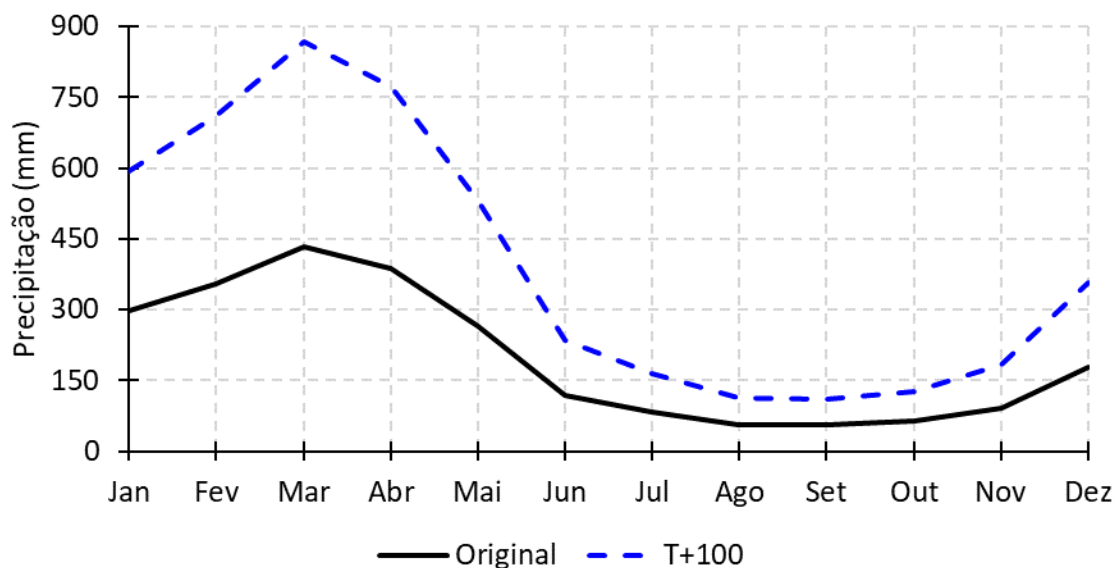
Essas penalidades eram esperadas, pois pesquisas anteriores demonstraram que quando a demanda hídrica não é atendida, reflexos do estresse hídrico começam a se expressar, podendo promover reduções que se iniciam em torno de 10% na sua produção e tem efeito cumulativo, devido a característica de desenvolvimento simultâneo e produção contínua da palma de óleo (ABUBAKAR et al., 2022; CORLEY; TINKER, 2015; TAO et al., 2017). Especialmente durante os estágios de reprodutivos, isto é, floração e frutificação, o déficit hídrico pode causar reduções drásticas no rendimento que podem ser notadas por um longo período,

chegando a 10% de redução de forma imediata durante o mesmo ano, e até 4% nos anos subsequentes (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020).

Estima-se que a cada mês em que ocorre um déficit hídrico significativo, cada fase constituinte do estágio de floração subsequente resulta em média na redução de 3% no rendimento da produção. Adicionalmente, a ocorrência de aborto floral, que pode ser potencializada pelo déficit hídrico, pode causar reduções adicionais na produção final em torno de 8 a 10% (AMBAR SUHARYANTI; MIZUNO; SODRI, 2020).

Em contraste, a nova assinatura de precipitação gerada para o aumento no total precipitado (figura 28) demonstrou que é necessário um aumento das chuvas em nível ainda mais intenso, se comparado com as reduções, para que a produção fosse significativamente afetada. Intuitivamente, o novo padrão de precipitação também não alterou o formato da assinatura de precipitação original, porém, pelo volume mensal de chuvas ter sido proporcionalmente aumentado, verificou-se forte intensificação do volume de chuvas nos meses mais chuvosos, atingindo picos que superaram os 800 mm/mês, enquanto os meses menos chuvosos não apresentaram mudanças extremas em seu volume total.


Figura 28 – Nova assinatura de precipitação mensal gerada a partir do ajuste dos dados observados para a condição de total T+100.



Fonte: O autor.

Para o caso do aumento do total precipitado, a produtividade apresentou média inferior se comparada a produtividade puramente estimada pelo modelo (figura 29), porém não tão expressiva quanto no caso das reduções da precipitação. Mesmo havendo um incremento expressivo na precipitação, dobrando o volume mensal (T+100), a redução da produção se equiparou ao resultado obtido pela modificação da distribuição em ICP10, onde também foi possível observar uma produção 5.46% ( $\pm 0.62\%$ ) inferior a produção de referência.

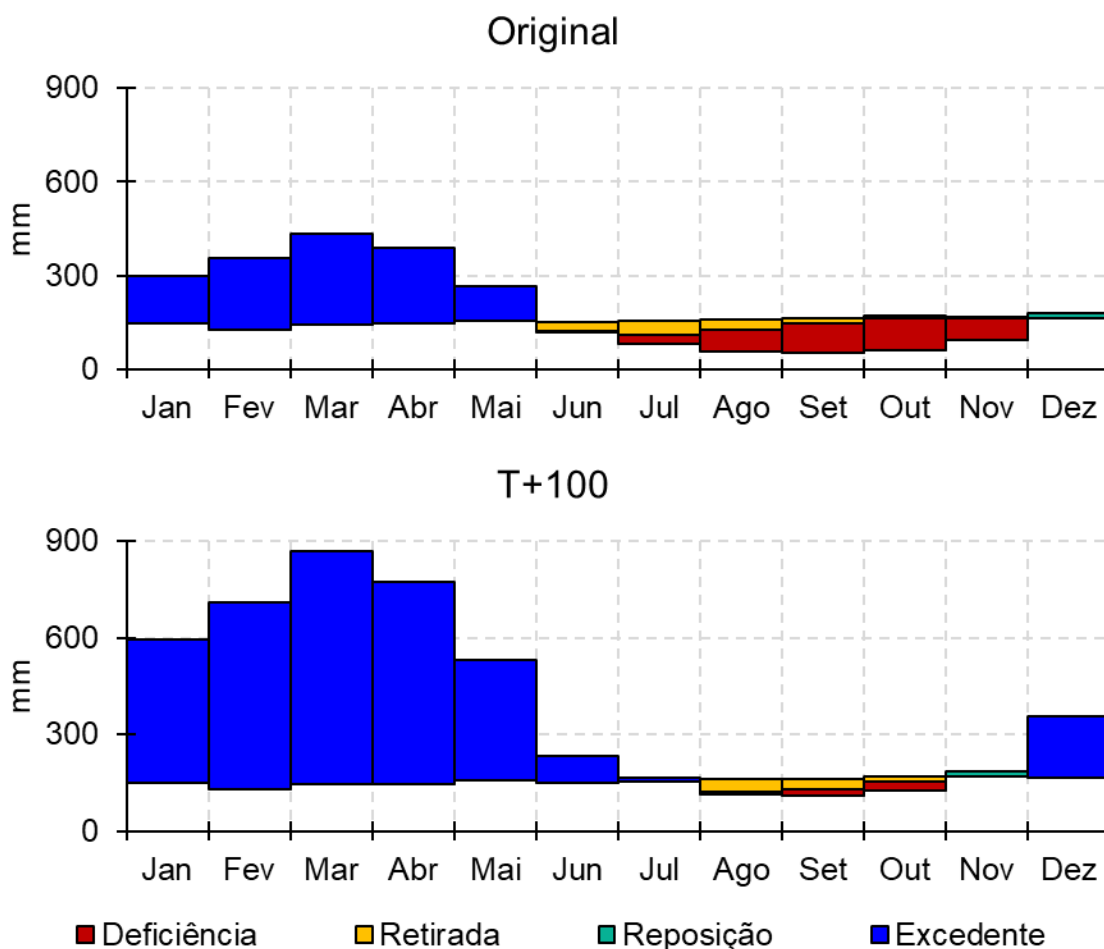
Figura 29 – Produtividade da palma de óleo em função da idade da planta para os dados puramente estimados pelo modelo e os dados estimados considerando a modificação do aumento no total da precipitação anual.



Fonte: O autor.

O balanço hídrico do solo para a simulação de aumento da precipitação apresentou uma assinatura semelhante a original, porém com fornecimento excedente de água em níveis muitos maiores e de longa duração, correspondentes aos meses de precipitações extremas geradas pela modificação da série de dados (figura 30). Aqui se repete o caso da distribuição ICP10, onde o aumento das chuvas no período seco não foi suficiente para impedir que houvessem momentos de deficiência hídrica e, adicionalmente, foram estimados oito meses consecutivos com excesso de fornecimento hídrico, neste caso, em níveis muito extremos.

Figura 30 - Balanço hídrico para a série de dados de precipitação original e para as condições de mudanças na precipitação, considerando aumento no total precipitado t+100.



Fonte: O autor.

Conforme mencionado anteriormente, a assinatura de produção obtida a partir da simulação T+100 segue um padrão bem semelhante a obtida pela simulação ICP10, inclusive com mesma taxa de redução na produção total. Os impactos reais desses cenários de mudança de precipitação devem ser bem mais intensos, pois o modelo não leva em consideração algumas influências do excesso de precipitação sob alguns componentes nutricionais e tão pouco considera impactos nas interações da palma de óleo para com as demais comunidades do sistema agrícola e sua participação na rede de serviços ecossistêmicos.

Existe um outro efeito negativo nesse cenário, que não foi mencionado na análise dos efeitos do ICP10, mas está diretamente relacionado aos excessos de chuva na região afetando a ocorrência e eficiência da polinização. As chuvas

extremas que ocorrem em torno de seis meses antes da colheita também são capazes de reduzir a produção pela redução da polinização, o que pode ocorrer tanto por inibir a procura dos polinizadores pelas flores, quanto por inviabilizar a polinização dos insetos ativos, degradando a qualidade do material carregado ou até mesmo lavando o material do corpo do inseto polinizador antes que ele possa alcançar a flor feminina (ABUBAKAR et al., 2022; ABUBAKAR; ISHAK; MAKMOM, 2021; CORLEY; TINKER, 2015; TAO et al., 2017).

Considerando a produção contínua, com colheitas mensais, um maior número de meses em situação de chuvas extremas frequentes causaria penalizações muito mais severas do que as apresentadas pelo modelo. Tal efeito não foi retratado pois é uma vertente de interações ecossistemas que o modelo, em sua versão atual, não considera para penalizar a estimativa da produção final.

É importante destacar que o presente estudo focou em avaliar os efeitos isolados de alterações na precipitação local, mantendo as demais variáveis conforme os registros observados. A ocorrência atípica da precipitação, especialmente em cenários que causaram algum nível de inversão entre as estações seca e chuvosa, muito provavelmente acarretaria também em alteração das condições de temperatura, umidade relativa, direção e velocidade do vento, os quais demandariam uma reconstrução total das condições atmosféricas, o que não está incluído na abordagem deste estudo.

#### **4.4. Perspectivas futuras para a região em relação as simulações**

As mudanças climáticas já afetam a produção agrícola e, caso seus efeitos futuros intensificados também ocorram, a potencialização da temperatura e escassez hídrica podem tornar regiões inteiras inaptas para cultivos ou, caso ainda sejam parcialmente aptas, isso pode se traduzir em aumento do custo de produção. Dessa forma, explorar estratégias de adaptação do cultivo e mitigação dos efeitos negativos é de extrema importância visando garantir a viabilidade da produção agrícola e, conseqüente, garantir o fornecimento de matéria prima e alimento (ASFAW et al., 2019; BOUREGAA, 2019; SARR et al., 2021).

Baseando-se na literatura, foi possível verificar que há uma expectativa para que a região de estudo sofra pela redução do total precipitado ao longo do ano, onde estima-se que as reduções no período chuvoso afetem principalmente os eventos extremos, as chuvas mais fortes, enquanto para o período mais seco, estima-se redução considerável no volume total da chuva da estação (DE SOUZA et al., 2014; MARENGO et al., 2010; SANTOS et al., 2012, 2020). Existem previsões de redução do total da precipitação que varia de 50% a 70% para a estação chuvosa, enquanto, para a estação seca, há estimativas de redução de até 60% a 80% do total precipitado para as regiões norte e nordeste do Brasil (DE SOUZA et al., 2014; MARENGO et al., 2010).

Parte dos estudos que estimam uma redução futura no total da precipitação na região de estudo, associam essa condição à mudança na relação entre dias com e sem chuvas, para os quais existem estimativas de aumento frequência de estiagens prolongadas, especialmente durante as estações mais secas, se intensificando durante o inverno (MARENGO et al., 2010; SANTOS et al., 2012, 2020). Alguns estudos estimaram que os dias consecutivos com chuva podem sofrer reduções superiores a 28%, elevando a porcentagens de dias secos ao longo ano para as regiões norte e nordeste do Brasil (ALVES et al., 2021; JEFERSON DE MEDEIROS; PRESTRELO DE OLIVEIRA; AVILA-DIAZ, 2022).

Ao avaliar a edição 2023 do relatório de mudanças climáticas do Painel Intergovernamental sobre Mudanças Climáticas (*Intergovernmental Panel on Climate Change - IPCC*), não foi possível concluir quanto a projeções de mudanças significativas na ocorrência de precipitações extremas para a região de estudo, contudo, o relatório indica uma tendência crescente quanto a ocorrência de temperaturas extremas e ondas de calor (CALVIN et al., 2023). Apesar da temperatura não ser o foco deste estudo, essa informação é relevante pois os distúrbios nas demais componentes climáticas tem forte relação com a temperatura da região, a qual pode agir como um agente intensificador das condições atípicas de precipitação e outros eventos extremos, elevando ainda mais as penalidades produtivas da palma de óleo.

Para a região de estudo, a maior parte das simulações realizadas indicaram redução da produção da palma de óleo, desde uma distribuição mais “homogênea” da precipitação, que na verdade resultou em vários meses com excedente hídrico,

até alterações no total precipitado, tanto para as modificações negativas quanto positivas. Foi possível constatar, porém, que as penalidades produtivas se destacaram na redução da precipitação total, onde até a menor taxa de redução (T-70: 16%) foi consideravelmente superior as condições modificadas para o aumento da precipitação ou homogeneização da distribuição, ambas registrando 5% de penalidade produtiva.

Apenas as simulações considerando o atraso na ocorrência da estação chuvosa, as defasagens temporais positivas, registraram o aumento da produtividade da palma de óleo. Contudo, foi possível verificar que tal cenário está possivelmente associado a inversão das estações seca e chuvosas, o que é pouco provável de ocorrer e, adicionalmente, nem foram verificadas projeções semelhantes na literatura.

Apesar dessa inversão ser um cenário naturalmente pouco provável, essas simulações também representam indícios positivos quando a suplementação do fornecimento hídrico aos plantios. Os resultados obtidos demonstraram como a aplicação de água em períodos críticos de redução de chuvas, associada a maior disponibilidade energética em condições ótimas tem considerável potencial em garantir a viabilidade do cultivo.

Estudos apontam a irrigação como principal método para mitigar os efeitos das mudanças climáticas nos cultivos agrícolas, seja pela atenuação da temperatura em microescala ou pelo fornecimento hídrico complementar em períodos de estiagem (SRINIVASA RAO et al., 2017; URETA et al., 2020; VANSCHOENWINKEL; VAN PASSEL, 2018; WANG et al., 2021). A literatura frequentemente demonstra como o uso eficiente de métodos de irrigação pode auxiliar em garantir a produção, uma vez que essa técnica visa amenizar os efeitos das variações climáticas, com alto potencial em mitigar os efeitos do período de estiagem, e trazer o desenvolvimento vegetativo efetivo o mais próximo possível do desenvolvimento pleno ou potencial (BRUM et al., 2021; NAJIHAH et al., 2019; RHEBERGEN et al., 2019)

De fato, a irrigação é um método capaz de mitigar boa parte dos efeitos das mudanças climáticas *in loco*, contudo, deve-se atentar para sua viabilidade regional, em especial visando as estimativas dos efeitos negativos no clima quanto aos prolongados períodos de estiagem e secas extremas. Considerando essas

condições, a implementação de sistemas de irrigação pode ser dificultada, com grande risco de potencializar os efeitos da estiagem em escala regional e, conseqüentemente, tornar sua adoção menos viável economicamente ou ambientalmente (HAYASHI et al., 2018; LUAN et al., 2021; MUNYASYA et al., 2022).

Diferentes métodos de mitigação dos efeitos das mudanças climáticas devem ser utilizados preferencialmente em conjunto e englobando diferentes vertentes do meio agrícola-ambiental. A irrigação é um integrante importante desse conjunto de técnicas, contudo, destaca-se a necessidade de aplicar um manejo integrando a interface solo-água-vegetação-atmosfera. Como exemplos, destacam-se revolvimento mínimo do solo, cobertura permanente do solo, práticas conservacionistas da biodiversidade do solo e da qualidade da água, gerenciamento de uso mínimo da irrigação, mudança na estratégia de plantio e condução da cultura, diversificação de culturas por consorcio, integração lavoura floresta, entre outros (ABUBAKAR; ISHAK; MAKMOM, 2021; ASFAW et al., 2019; GODEBO et al., 2021; MARTÍNEZ-MENA et al., 2021; QIU et al., 2018; SINGH, 2020).

As práticas mencionadas, de modo geral, visam melhorar diferentes aspectos do agroecossistema, com foco em preservar o armazenamento de carbono no solo, promover fertilidade e física adequada do solo, estimular a infiltração de água no solo e, conseqüentemente, a recarga dos aquíferos, aumentar a disponibilidade hídrica regional, otimizar a utilização dos recursos necessários na produção agrícola reduzindo os desperdícios e contaminações ambientais, potencializar o sequestro e assimilação do carbono atmosférico em estruturas vegetais (BOONWICHAI et al., 2021; DEIHIMFARD et al., 2022; MARTÍNEZ-MALDONADO et al., 2021; SALDIVIA-TEJEDA et al., 2021; SIDIBÉ et al., 2018; SILUNGWE et al., 2019; URETA et al., 2020). Tais objetivos tendem a agir mitigando os efeitos climáticos extremos, contrapor as condições que estimulem a ocorrência das mudanças climáticas e, caso as recomendações mencionadas sejam amplamente adotadas pelos produtores e gestores de propriedades agrícolas, estima-se um elevado potencial em preservar a produção agrícola nacional e atender as futuras demandas de alimento entre outros recursos naturais indispensáveis para garantir o abastecimento e desenvolvimento mundial.

## 5. CONCLUSÕES

O estudo permitiu avaliar a aplicabilidade da modelagem agrometeorológica para determinar como ocorrências atípicas nos padrões de precipitação podem influenciar na produção esperada da palma de óleo. Demonstrou-se como diferentes modelos são capazes de processar diferentes informações de um mesmo sistema agrícola complexos, convertendo-as em métricas de desenvolvimento e previsões agrícolas com considerável acurácia, confiabilidade e relativa praticidade.

As simulações realizadas por meio da abordagem de modelagem baseada em processos se mostraram mais adequadas para a realização deste estudo, obtendo resultados consistentes e mais precisos com base nos dados observados em campo. A versão do modelo ECOSMOS aqui empregado ainda apresenta algumas limitações quanto às simulações das interações agroecossistêmicas para além das interações abióticas com a cultura de interesse, contudo, é um modelo que está em constante atualização e espera-se que esse estudo possa colaborar de alguma forma com sua melhoria contínua.

Por meio da análise de sensibilidade, foi possível apontar os limites que implicaram em alteração significativa da produção esperada, na qual foi possível observar que a condição de redução do total precipitado foi a mais crítica quanto a penalizar a produção da palma de óleo na região da Agropalma. As reduções significativas começaram a partir de uma redução de 70%, escalando rapidamente até completa ausência de chuvas, o que anulou a produção. A princípio tais níveis de redução parecem muito intensos e pouco prováveis, mas, após avaliação da literatura, constatou-se que esses cenários são plausíveis e esperados para o futuro da região norte brasileira.

Demonstrou-se que a integração dos dados de campo em um modelo biodinâmico capaz de simular precisamente a produção esperada da palma de óleo, apresenta grande potencial em apoiar gestores agrícolas no planejamento, definição, aplicação e avaliação de ações preventivas mitigadoras dos efeitos das mudanças climáticas.

## REFERÊNCIAS

- ABDULRAZIK, A. et al. Multi-products productions from Malaysian oil palm empty fruit bunch (EFB): Analyzing economic potentials from the optimal biomass supply chain. **Journal of Cleaner Production**, v. 168, p. 131–148, 2017.
- ABRAM, N. K. et al. Oil palm–community conflict mapping in Indonesia: A case for better community liaison in planning for development initiatives. **Applied Geography**, v. 78, p. 33–44, 2017.
- ABUBAKAR, A. et al. What does Modelling Tells us on the Influence of Certain Weather Parameters on Oil Palm Production in Peninsular Malaysia. **Indian Journal Of Agricultural Research**, v. 57, n. 1, p. 73–78, 23 jul. 2022.
- ABUBAKAR, A.; ISHAK, M. Y. An Overview of the Role of Smallholders in Oil Palm Production Systems in Changing Climate. **Nature Environment and Pollution Technology**, v. 21, n. 5(Suppl), p. 2055–2071, 29 dez. 2022.
- ABUBAKAR, A.; ISHAK, M. Y.; MAKMOM, A. A. Impacts of and adaptation to climate change on the oil palm in Malaysia: a systematic review. **Environmental Science and Pollution Research**, v. 28, n. 39, p. 54339–54361, 16 out. 2021.
- ABUBAKAR, A.; ISHAK, M. Y.; MAKMOM, A. A. Nexus between climate change and oil palm production in Malaysia: a review. **Environmental Monitoring and Assessment**, v. 194, n. 4, p. 262, 9 abr. 2022.
- AFRIZAL; ELFITRA; ZULDESNI. Analysing the effectiveness of the roundtable on sustainable palm oil's Free, Prior and Informed Consent policy to respect customary land rights. **Journal of International Development**, v. 35, n. 5, p. 761–780, 2023.
- AKHTAR, M. N. et al. Leveraging on Advanced Remote Sensing- and Artificial Intelligence-Based Technologies to Manage Palm Oil Plantation for Current Global Scenario: A Review. **Agriculture (Switzerland)**, v. 13, n. 2, 2023.

- ALTMAN, E. I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. **The Journal of Finance**, v. 23, n. 4, p. 589–609, 30 set. 1968.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.
- ALVES, L. M. et al. Assessment of rainfall variability and future change in Brazil across multiple timescales. **International Journal of Climatology**, v. 41, n. S1, p. E1875–E1888, 15 jan. 2021.
- AMARATUNGA, V. et al. Artificial Neural Network to Estimate the Paddy Yield Prediction Using Climatic Data. **Mathematical Problems in Engineering**, v. 2020, p. 1–11, 18 jul. 2020.
- AMBAR SUHARYANTI, N.; MIZUNO, K.; SODRI, A. The effect of water deficit on inflorescence period at palm oil productivity on peatland. **E3S Web of Conferences**, v. 211, p. 05005, 25 nov. 2020.
- AMUTI, T. et al. Validation of a Process-Based Agro-Ecosystem Model (Agro-IBIS) for Maize in Xinjiang, Northwest China. **Agronomy**, v. 8, n. 3, p. 29, 10 mar. 2018.
- ANG, Y. et al. Oil palm yield prediction across blocks from multi-source data using machine learning and deep learning. **Earth Science Informatics**, v. 15, n. 4, p. 2349–2367, 2 dez. 2022.
- APICHATMETA, K.; SUDSIRI, C. J.; RITCHIE, R. J. Photosynthesis of Oil Palm (*Elaeis guineensis*). **Scientia Horticulturae**, v. 214, p. 34–40, 2017.
- ASFAW, A. et al. Determinants in the adoption of climate change adaptation strategies: evidence from rainfed-dependent smallholder farmers in north-central Ethiopia (Woleka sub-basin). **Environment, Development and Sustainability**, v. 21, n. 5, p. 2535–2565, 5 out. 2019.
- AUSTIN, K. G. et al. Reconciling oil palm expansion and climate change mitigation in Kalimantan, Indonesia. **PLoS ONE**, v. 10, n. 5, p. 1–17, 2015.

BAYONA-RODRIGUEZ, C. J.; ROMERO, H. M. Physiological and agronomic behavior of commercial cultivars of oil palm (*Elaeis guineensis*) and OxG hybrids (*Elaeis oleifera* x *Elaeis guineensis*) at rainy and dry seasons. **Australian Journal of Crop Science**, v. 13, n. 3, p. 424–432, 2019.

BEHERA, S. K. et al. Oil palm cultivation enhances soil pH, electrical conductivity, concentrations of exchangeable calcium, magnesium, and available sulfur and soil organic carbon content. **Land Degradation and Development**, v. 31, n. 18, p. 2789–2803, 2020.

BENAMI, E. et al. Oil palm land conversion in Pará, Brazil, from 2006-2014: Evaluating the 2010 Brazilian Sustainable Palm Oil Production Program. **Environmental Research Letters**, v. 13, n. 3, 2018.

BENEZOLI, V. H. et al. Modeling oil palm crop for Brazilian climate conditions. **Agricultural Systems**, v. 190, n. September 2020, 2021.

BERINGER, T. et al. CO<sub>2</sub> fertilization effect may balance climate change impacts on oil palm cultivation. **Environmental Research Letters**, v. 18, n. 5, p. 054019, 1 maio 2023.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York, NY, USA: Oxford University Press, Inc., 1995.

BOLFE, É. L.; BATISTELLA, M. Análise florística e estrutural de sistemas silviagrícolas em Tomé-Açu, Pará. **Pesquisa Agropecuária Brasileira**, v. 46, n. 10, p. 1139–1147, out. 2011.

BOONWICHAI, S. et al. Adaptation strategies for rainfed rice water management under climate change in Songkhram River Basin, Thailand. **Journal of Water and Climate Change**, v. 12, n. 6, p. 2181–2198, 1 set. 2021.

BOUMA, J. Using Soil Survey Data for Quantitative Land Evaluation. In: [s.l: s.n.]. v. 9p. 177–213.

BOUREGAA, T. Impact of climate change on yield and water requirement of rainfed crops in the Setif region. **Management of Environmental Quality: An**

**International Journal**, v. 30, n. 4, p. 851–863, 10 jun. 2019.

BRANDÃO, F. et al. The challenge of reconciling conservation and development in the tropics: Lessons from Brazil's oil palm governance model. **World Development**, v. 139, p. 105268, 2021.

BRUM, M. et al. Effects of irrigation on oil palm transpiration during ENSO-induced drought in the Brazilian Eastern Amazon. **Agricultural Water Management**, v. 245, n. June 2020, p. 106569, fev. 2021.

CALVIN, K. et al. **IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland.** (P. Arias et al., Eds.) **Intergovernmental Panel on Climate Change, 2023.** [s.l: s.n.]. Disponível em: <<https://www.ipcc.ch/report/ar6/syr/>>.

CAVALCANTI, I. F. DE A. et al. **Tempo e Clima no Brasil.** 1. ed. São Paulo, SP: Oficina de Textos, 2009.

CHAPMAN, R. et al. Using Bayesian networks to predict future yield functions with data from commercial oil palm plantations: A proof of concept analysis. **Computers and Electronics in Agriculture**, v. 151, n. October 2017, p. 338–348, 2018.

CHARLOQ et al. Unmanned aerial vehicles (UAV) utilization for mapping the health of oil palm plants ( *Elaeis guineensis* Jacq.). **IOP Conference Series: Earth and Environmental Science**, v. 1241, n. 1, 2023.

CHONG, K. L. et al. A review of remote sensing applications for oil palm studies. **Geo-Spatial Information Science**, v. 20, n. 2, p. 184–200, 2017.

CHUNGCHAROEN, T. et al. Machine learning-based prediction of nutritional status in oil palm leaves using proximal multispectral images. **Computers and Electronics in Agriculture**, v. 198, n. December 2021, p. 107019, jul. 2022.

CIFUENTES-ESPINOSA, J. A. et al. Oil palm growers' prospects for sustainable

oil palm production. A case study from Campeche, Mexico. **Agricultural Systems**, v. 212, n. March, p. 103780, dez. 2023.

CLAESSEN, M. E. C. et al. **Manual de Métodos de Análise de Solo**. 2. ed. Rio de Janeiro: EMBRAPA, 1997. v. 26

COCK, J. et al. Learning from commercial crop performance: Oil palm yield response to management under well-defined growing conditions. **Agricultural Systems**, v. 149, n. October 2017, p. 99–111, nov. 2016.

COLE, N. S. Bias in testing. **American Psychologist**, v. 36, n. 10, p. 1067–1077, out. 1981.

COLMANETTI, M. A. A. et al. Implementation and calibration of short-rotation eucalypt plantation module within the ECOSMOS land surface model. **Agricultural and Forest Meteorology**, v. 323, n. May, p. 109043, ago. 2022.

COMBRES, J.-C. et al. Simulation of inflorescence dynamics in oil palm and estimation of environment-sensitive phenological phases: a model based analysis. **Functional Plant Biology**, v. 40, n. 3, p. 263, 2013.

CORLEY, R. H. V.; TINKER, P. B. **The Oil Palm**. Oxford, UK: Wiley, 2015.

CORLEY, R. H. V.; HARDON, J. J.; TAN, G. Y. Analysis of growth of the oil palm (*Elaeis guineensis* Jacq.) I. Estimation of growth parameters and application in breeding. **Euphytica**, v. 20, n. 2, p. 307–315, maio 1971.

COSBY, B. J. et al. A Statistical Exploration of the Relationships of Soil Moisture Characteristics to the Physical Properties of Soils. **Water Resources Research**, v. 20, n. 6, p. 682–690, 9 jun. 1984.

CULMAN, M. et al. Using agrometeorological data to assist irrigation management in oil palm crops: A decision support method and results from crop model simulation. **Agricultural Water Management**, v. 213, n. January, p. 1047–1062, 2019.

CUNHA, R. L. D. F.; SILVA, B. **Estimating Crop Yields With Remote Sensing**

**And Deep Learning**. 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS). **Anais...IEEE**, mar. 2020. Disponível em: <<https://ieeexplore.ieee.org/document/9165608/>>

DE LUIS, M. et al. Precipitation concentration changes in Spain 1946–2005. **Natural Hazards and Earth System Sciences**, v. 11, n. 5, p. 1259–1265, 9 maio 2011.

DE PAIVA, C. K. S. et al. Effect of oil palm on the Plecoptera and Trichoptera (Insecta) assemblages in streams of eastern Amazon. **Environmental Monitoring and Assessment**, v. 189, n. 8, 2017.

DE SOUZA, E. B. et al. Dynamical Downscaling for Railroad Areas in Eastern Amazon and Southeastern Brazil: Current Climate and Near-Future Projections. **Atmospheric and Climate Sciences**, v. 04, n. 02, p. 155–163, 2014.

DEIHIMFARD, R. et al. Future climate change could reduce irrigated and rainfed wheat water footprint in arid environments. **Science of The Total Environment**, v. 807, p. 150991, fev. 2022.

DIAS, H. B. et al. **Modelling integrated crop-livestock systems: preliminary results from an agroecosystem model**. II World Congress on Integrated Crop-Livestock-Forestry Systems. **Anais...2021**.

DO AMARAL TELES, D. A. et al. Yield Analysis of Oil Palm Cultivated under Irrigation in the Brazilian Savanna. **JAOCS, Journal of the American Oil Chemists' Society**, v. 93, n. 2, p. 193–199, 2016.

DUNN, O. J. Multiple Comparisons Using Rank Sums. **Technometrics**, v. 6, n. 3, p. 241–252, ago. 1964.

ELLSÄSSER, F. et al. Predicting evapotranspiration from drone-based thermography-a method comparison in a tropical oil palm plantation. **Biogeosciences**, v. 18, n. 3, p. 861–872, 2021.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Sistema brasileiro de classificação de solos**. [s.l.: s.n.].

EULER, M. et al. Exploring yield gaps in smallholder oil palm production systems in eastern Sumatra, Indonesia. **Agricultural Systems**, v. 146, p. 111–119, 2016.

EYCOTT, A. E. et al. Resilience of ecological functions to drought in an oil palm agroecosystem. **Environmental Research Communications**, v. 1, n. 10, p. 101004, 1 nov. 2019.

EZZATZADEGAN, L. et al. Experimental and artificial intelligence modelling study of oil palm trunk sap fermentation. **Energies**, v. 14, n. 8, 2021.

FAN, Y. et al. A sub-canopy structure for simulating oil palm in the Community Land Model (CLM-Palm): phenology, allocation and yield. **Geoscientific Model Development**, v. 8, n. 11, p. 3785–3800, 26 nov. 2015.

FAN, Y. et al. Reconciling Canopy Interception Parameterization and Rainfall Forcing Frequency in the Community Land Model for Simulating Evapotranspiration of Rainforests and Oil Palm Plantations in Indonesia. **Journal of Advances in Modeling Earth Systems**, v. 11, n. 3, p. 732–751, 2019.

FLEISS, S. et al. Limited impacts of climatic conditions on commercial oil palm yields in Malaysian plantations. **CABI Agriculture and Bioscience**, v. 3, n. 1, p. 59, 9 set. 2022.

FOLEY, J. A. et al. An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics. **Global Biogeochemical Cycles**, v. 10, n. 4, p. 603–628, dez. 1996.

FURUMO, P. R. et al. Improve Long-Term Biodiversity Management and Monitoring on Certified Oil Palm Plantations in Colombia by Centralizing Efforts at the Sector Level. **Frontiers in Forests and Global Change**, v. 2, n. August, 2019.

FURUMO, P. R.; AIDE, T. M. Characterizing commercial oil palm expansion in Latin America: Land use change and trade. **Environmental Research Letters**, v. 12, n. 2, 2017.

GÉRON, A. **Mãos à Obra Aprendizado de Máquina com Scikit-Learn & TensorFlow: Conceitos, Ferramentas e Técnicas Para a Construção**

**deSistemas Inteligentes.** [s.l: s.n.].

GHAHARI, A. et al. Deep Learning at the Interface of Agricultural Insurance Risk and Spatio-Temporal Uncertainty in Weather Extremes. **North American Actuarial Journal**, v. 23, n. 4, p. 535–550, 2 out. 2019.

GODEBO, T. R. et al. Water Quality Threats, Perceptions of Climate Change and Behavioral Responses among Farmers in the Ethiopian Rift Valley. **Climate**, v. 9, n. 6, p. 92, 6 jun. 2021.

GONÇALVES, F.; BACK, Á.; SUTIL, T. Índice de concentração de precipitação no município de Garuva - SC. In: **Planejamento e gestão territorial: a sustentabilidade dos ecossistemas urbanos.** [s.l.] Ediunec, 2018. p. 519–531.

HAGAN, M. T. et al. **Neural network design.** 2. ed. [s.l: s.n.].

HASHEMVAND KHIABANI, P.; TAKEUCHI, W. Assessment of oil palm yield and biophysical suitability in Indonesia and Malaysia. **International Journal of Remote Sensing**, v. 41, n. 22, p. 8520–8546, 16 nov. 2020.

HAYASHI, K. et al. Reducing vulnerability of rainfed agriculture through seasonal climate predictions: A case study on the rainfed rice production in Southeast Asia. **Agricultural Systems**, v. 162, n. February, p. 66–76, maio 2018.

HAYKIN, S. **Redes neurais: princípios e prática.** 2. ed. São Paulo, SP: BOOKMAN, 2017.

HEIDARI, A. et al. Hydrologic impacts and trade-offs associated with developing oil palm for bioenergy in Tabasco, Mexico. **Journal of Hydrology: Regional Studies**, v. 31, n. June, p. 100722, 2020.

HERNAWATI, R.; WIKANTIKA, K.; DARMAWAN, S. Modeling of oil palm phenology based on remote sensing data: opportunities and challenges. **Journal of Applied Remote Sensing**, v. 16, n. 02, 22 abr. 2022.

HOFFMANN, M. P. et al. Yield gap analysis in oil palm: Framework development and application in commercial operations in Southeast Asia. **Agricultural**

**Systems**, v. 151, p. 12–19, 2017.

HOFFMANN, M. P. P. et al. Simulating potential growth and yield of oil palm (*Elaeis guineensis*) with PALMSIM: Model description, evaluation and application. **Agricultural Systems**, v. 131, p. 1–10, nov. 2014.

HUTH, N. I. et al. Development of an oil palm cropping systems model: Lessons learned and future directions. **Environmental Modelling & Software**, v. 62, p. 411–419, dez. 2014.

IBRAGIMOV, A.; SIDIQUE, S. F.; TEY, Y. S. Productivity for sustainable growth in Malaysian oil palm production: A system dynamics modeling approach. **Journal of Cleaner Production**, v. 213, p. 1051–1062, 2019.

JARAYEE, A. N. et al. Oil Palm Plantation Land Cover and Age Mapping Using Sentinel-2 Satellite Imagery and Machine Learning Algorithms. **IOP Conference Series: Earth and Environmental Science**, v. 1051, n. 1, 2022.

JEFERSON DE MEDEIROS, F.; PRESTRELO DE OLIVEIRA, C.; AVILA-DIAZ, A. Evaluation of extreme precipitation climate indices and their projected changes for Brazil: From CMIP3 to CMIP6. **Weather and Climate Extremes**, v. 38, n. July, p. 100511, dez. 2022.

KANIAPAN, S. et al. The utilisation of palm oil and oil palm residues and the related challenges as a sustainable alternative in biofuel, bioenergy, and transportation sector: A review. **Sustainability (Switzerland)**, v. 13, n. 6, 2021.

KEANE, M.; NEAL, T. Comparing deep neural network and econometric approaches to predicting the impact of climate change on agricultural yield. **The Econometrics Journal**, v. 23, n. 3, p. S59–S80, 1 set. 2020.

KELLY-YONG, T. L. et al. Potential of hydrogen from oil palm biomass as a source of renewable energy worldwide. **Energy Policy**, v. 35, n. 11, p. 5692–5701, nov. 2007.

KHALED, A. Y. et al. Spectral features selection and classification of oil palm leaves infected by Basal stem rot (BSR) disease using dielectric spectroscopy.

**Computers and Electronics in Agriculture**, v. 144, n. November 2017, p. 297–309, 2018.

KHALID, N.; SHAHROL, N. A. Evaluation the Accuracy of Oil Palm Tree Detection Using Deep Learning and Support Vector Machine Classifiers. **IOP Conference Series: Earth and Environmental Science**, v. 1051, n. 1, 2022.

KHAN, N. et al. Prediction of Oil Palm Yield Using Machine Learning in the Perspective of Fluctuating Weather and Soil Moisture Conditions: Evaluation of a Generic Workflow. **Plants**, v. 11, n. 13, p. 1697, 27 jun. 2022.

KHASANAH, N. et al. Carbon neutral? No change in mineral soil carbon stock under oil palm plantations derived from forest or non-forest in Indonesia. **Agriculture, Ecosystems and Environment**, v. 211, p. 195–206, 2015.

KHOR, J. F. et al. Impact Comparison of El Niño and Ageing Crops on Malaysian Oil Palm Yield. **Plants**, v. 12, n. 3, p. 424, 17 jan. 2023.

KIPLI, K. et al. Deep learning applications for oil palm tree detection and counting. **Smart Agricultural Technology**, v. 5, n. April, p. 100241, 2023.

KÖPPEN, G. W. et al. Handbuch der Klimatologie. **Bulletin of the American Geographical Society**, v. 43, n. 12, p. 935, 1936.

KRUSKAL, W. H.; WALLIS, W. A. Use of Ranks in One-Criterion Variance Analysis. **Journal of the American Statistical Association**, v. 47, n. 260, p. 583–621, dez. 1952.

KUCHARIK, C. J. et al. Testing the performance of a dynamic global ecosystem model: Water balance, carbon balance, and vegetation structure. **Global Biogeochemical Cycles**, v. 14, n. 3, p. 795–825, set. 2000.

KUCHARIK, C. J.; BRYE, K. R. Integrated Biosphere Simulator (IBIS) Yield and Nitrate Loss Predictions for Wisconsin Maize Receiving Varied Amounts of Nitrogen Fertilizer. **Journal of Environmental Quality**, v. 32, n. 1, p. 247–268, jan. 2003.

KUWATA, K.; SHIBASAKI, R. Estimating corn yield in the united states with MODIS EVI and machine learning methods. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. III–8, n. July, p. 131–136, 7 jun. 2016.

LAGUNES-ESPINOZA, L. D. C. et al. Oil palm crop: state and gaps of research and technological development at global scale, Latin America and Mexico. **Cahiers Agricultures**, v. 31, p. 3, 17 jan. 2022.

LEE, J. S. H. et al. Modelling environmental and socio-economic trade-offs associated with land-sparing and land-sharing approaches to oil palm expansion. **Journal of Applied Ecology**, v. 51, n. 5, p. 1366–1377, 13 out. 2014.

LI, L. et al. Mapping Oil Palm Plantations in Cameroon Using PALSAR 50-m Orthorectified Mosaic Images. **Remote Sensing**, v. 7, n. 2, p. 1206–1224, 23 jan. 2015.

LI, W. et al. Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images. **Remote Sensing**, v. 9, n. 1, p. 22, 30 dez. 2016.

LI, W. et al. Large-scale oil palm tree detection from high-resolution satellite images using two-stage convolutional neural networks. **Remote Sensing**, v. 11, n. 1, 2019.

LIEBMANN, B. et al. Onset and End of the Rainy Season in South America in Observations and the ECHAM 4.5 Atmospheric General Circulation Model. **Journal of Climate**, v. 20, n. 10, p. 2037–2050, 15 maio 2007.

LIM, F. K. S. et al. Land-use change from market responses to oil palm intensification in Indonesia. **Conservation Biology**, v. 38, n. 1, 26 fev. 2024.

LUAN, X. et al. Combined heat and drought suppress rainfed maize and soybean yields and modify irrigation benefits in the USA. **Environmental Research Letters**, v. 16, n. 6, p. 064023, 1 jun. 2021.

MA, J.-W. et al. Regional-scale rice-yield estimation using stacked auto-encoder

with climatic and MODIS data: a case study of South Korea. **International Journal of Remote Sensing**, v. 40, n. 1, p. 51–71, 2 jan. 2019.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier nonlinearities improve neural network acoustic models. in **ICML Workshop on Deep Learning for Audio, Speech and Language Processing**, v. 28, 2013.

MANOLI, G. et al. Ecohydrological changes after tropical forest conversion to oil palm. **Environmental Research Letters**, v. 13, n. 6, 2018.

MARENGO, J. A. et al. Future change of climate in South America in the late twenty-first century: intercomparison of scenarios from three regional climate models. **Climate Dynamics**, v. 35, n. 6, p. 1073–1097, nov. 2010.

MARIN-BURGOS, V.; CLANCY, J. S. Understanding the expansion of energy crops beyond the global biofuel boom: evidence from oil palm expansion in Colombia. **Energy, Sustainability and Society**, v. 7, n. 1, p. 1–21, 2017.

MARTÍNEZ-ARTEAGA, D. et al. Typology of Irrigation Technology Adopters in Oil Palm Production: A Categorical Principal Components and Fuzzy Logic Approach. **Sustainability**, v. 15, n. 13, p. 9944, 22 jun. 2023.

MARTÍNEZ-MALDONADO, F. E. et al. Gross Primary Production of Rainfed and Irrigated Potato (*Solanum tuberosum* L.) in the Colombian Andean Region Using Eddy Covariance Technique. **Water**, v. 13, n. 22, p. 3223, 13 nov. 2021.

MARTÍNEZ-MENA, M. et al. Short-term impact of crop diversification on soil carbon fluxes and balance in rainfed and irrigated woody cropping systems under semiarid Mediterranean conditions. **Plant and Soil**, v. 467, n. 1–2, p. 499–514, 21 out. 2021.

MARWANTO, S.; AGUS, F. Is CO<sub>2</sub> flux from oil palm plantations on peatland controlled by soil moisture and/or soil and air temperatures? **Mitigation and Adaptation Strategies for Global Change**, v. 19, n. 6, p. 809–819, 15 ago. 2014.

MCCALMONT, J. et al. Oil palm (*Elaeis guineensis*) plantation on tropical peatland in South East Asia: Photosynthetic response to soil drainage level for mitigation of

soil carbon emissions. **Science of the Total Environment**, v. 858, n. January 2022, p. 159356, fev. 2023.

MEIJIDE, A. et al. Controls of water and energy fluxes in oil palm plantations: Environmental variables and oil palm age. **Agricultural and Forest Meteorology**, v. 239, p. 71–85, 2017.

MENDOZA-HERNÁNDEZ, J. H. R. et al. Effect of supplementary irrigation on the transpiration and reproductive development of oil palm trees during the dry season in Tabasco, Mexico. **Cahiers Agricultures**, v. 30, n. 4, p. 41, 27 out. 2021.

MICHIELS, P.; GABRIELS, D.; HARTMANN, R. Using the seasonal and temporal Precipitation concentration index for characterizing the monthly rainfall distribution in Spain. **CATENA**, v. 19, n. 1, p. 43–58, fev. 1992.

MIDDELBERG, J. et al. An ecosystem services analysis of oil palm and alternative land use systems on peat in Malaysia. **Journal of Oil Palm Research**, v. 31, n. 3, p. 468–479, 2019.

MOHD NAJIB, N. E. et al. Synergy of active and passive remote sensing data for effective mapping of oil palm plantation in Malaysia. **Forests**, v. 11, n. 8, 2020.

MONTEIRO DE CARVALHO, C. et al. Deforested and degraded land available for the expansion of palm oil for biodiesel in the state of Pará in the Brazilian Amazon. **Renewable and Sustainable Energy Reviews**, v. 44, p. 867–876, abr. 2015.

MOREIRA, J. R.; GOLDEMBERG, J. Oil palm deserves government attention in Brazil. **Environmental Research Letters**, v. 10, n. 7, p. 9–11, 2015.

MUNYASYA, A. N. et al. Integrated on-site & off-site rainwater-harvesting system boosts rainfed maize production for better adaptation to climate change. **Agricultural Water Management**, v. 269, n. September 2020, p. 107672, jul. 2022.

NAJIHAH, T. S. et al. Effects of water stress on the growth, physiology and biochemical properties of oil palm seedlings. **AIMS Agriculture and Food**, v. 4, n. 4, p. 854–868, 2019.

NOURQOLIPOUR, R. et al. A GIS-based model to analyze the spatial and temporal development of oil palm land use in Kuala Langat district, Malaysia.

**Environmental Earth Sciences**, v. 73, n. 4, p. 1687–1700, 2015.

NURLIZA et al. Do Sustainability Standards Provide Environmental, Social and Economic Benefits for Independent Oil Palm Smallholders? **Jurnal Penyuluhan**, v. 18, n. 02, p. 232–245, 2022.

OETTLI, P.; BEHERA, S. K.; YAMAGATA, T. Climate Based Predictability of Oil Palm Tree Yield in Malaysia. **Scientific Reports**, v. 8, n. 1, p. 1–13, 2018.

OFEM, K. I.; KEFAS, P. K.; GARJILA, Y. A. Land suitability evaluation for oil palm production in Cross River State, Nigeria. **Agro-Science**, v. 21, n. 3, p. 85–93, 9 mar. 2023.

OISHY, M. N. et al. Unravelling the effects of climate change on the soil-plant-atmosphere interactions: A critical review. **Soil and Environmental Health**, v. 3, n. 1, 2025.

OKORO, S. U. et al. A novel approach in monitoring land-cover change in the tropics: Oil palm cultivation in the Niger Delta, Nigeria. **Erde**, v. 147, n. 1, p. 40–52, 2016.

OLIVER, J. E. Monthly precipitation distribution: A comparative index. **The Professional Geographer**, v. 32, n. 3, p. 300–309, 15 ago. 1980.

ONSET COMPUTER CORPORATION. **HOBO U30 Station/NRC Starter System (U30-NRC-SYS-C) User's Guide**. , 2021.

PARDON, L. et al. Quantifying nitrogen losses in oil palm plantations: Models and challenges. **Biogeosciences**, v. 13, n. 19, p. 5433–5452, 2016.

PARDON, L. et al. Yield and nitrogen losses in oil palm plantations: Main drivers and management trade-offs determined using simulation. **Field Crops Research**, v. 210, n. May, p. 20–32, 2017.

PATERSON, R. R. M. Depletion of Indonesian oil palm plantations implied from

modeling oil palm mortality and *Ganoderma boninense* rot under future climate.

**AIMS Environmental Science**, v. 7, n. 5, p. 366–379, 2020.

PATERSON, R. R. M.; LIMA, N. Climate change affecting oil palm agronomy, and oil palm cultivation increasing climate change, require amelioration. **Ecology and Evolution**, v. 8, n. 1, p. 452–461, 2018.

PEARSON, K. Contributions to the Mathematical Theory of Evolution.

**Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 185, p. 71–110, 1893.

PEREZ, R. P. A. et al. Integrating mixed-effect models into an architectural plant model to simulate inter-and intra-progeny variability: A case study on oil palm (*Elaeis guineensis* Jacq.). **Journal of Experimental Botany**, v. 67, n. 15, p. 4507–4521, 2016.

PINDYCK, R. S. S.; RUBINFELD, D. L.; RUBINFELD, L. R. Econometric Models and Economic Forecasts. Economics series. 1991.

PIRKER, J. et al. What are the limits to oil palm expansion? **Global Environmental Change**, v. 40, p. 73–81, 2016.

POHL, C.; LOONG, C. K. In-situ data collection for oil palm tree height determination using synthetic aperture radar. **IOP Conference Series: Earth and Environmental Science**, v. 34, n. 1, p. 1–8, abr. 2016.

PURNOMO, H. et al. Reconciling oil palm economic development and environmental conservation in Indonesia: A value chain dynamic approach. **Forest Policy and Economics**, v. 111, n. January 2019, p. 102089, 2020.

PUTRA, Y. C.; WIJAYANTO, A. W. Automatic detection and counting of oil palm trees using remote sensing and object-based deep learning. **Remote Sensing Applications: Society and Environment**, v. 29, n. December 2022, p. 100914, jan. 2023.

QAIM, M. et al. Environmental, economic, and social consequences of the oil palm boom. **Annual Review of Resource Economics**, v. 12, p. 321–344, 2020.

QIU, L. et al. Simulation of the irrigation requirements for improving carbon sequestration in a rainfed cropping system under long-term fertilization on the Loess Plateau of China. **Agriculture, Ecosystems & Environment**, v. 265, n. 99, p. 198–208, out. 2018.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2014. Disponível em: <<http://www.r-project.org/>>

RAMDANI, F.; MOFFIET, T.; HINO, M. Local surface temperature change due to expansion of oil palm plantation in Indonesia. **Climatic Change**, v. 123, n. 2, p. 189–200, 21 mar. 2014.

RAY, D. K. et al. Climate change has likely already affected global food production. **PLOS ONE**, v. 14, n. 5, p. e0217148, 31 maio 2019.

REYNOLDS, L. P. et al. Importance of animals in agricultural sustainability and food security. **The Journal of Nutrition**, v. 145, n. 7, p. 1377–1379, 1 jul. 2015.

RHEBERGEN, T. et al. Climate, soil and land-use based land suitability evaluation for oil palm production in Ghana. **European Journal of Agronomy**, v. 81, p. 1–14, 2016.

RHEBERGEN, T. et al. Yield gap analysis and entry points for improving productivity on large oil palm plantations and smallholder farms in Ghana. **Agricultural Systems**, v. 165, n. July 2017, p. 14–25, 2018.

RHEBERGEN, T. et al. The influence of water and nutrient management on oil palm yield trends on a large-scale plantation in Ghana. **Agricultural Water Management**, v. 221, n. May, p. 377–387, 2019.

RIVAL, A. Breeding the oil palm (*Elaeis guineensis* Jacq.) for climate change. **OCL - Oilseeds and fats, Crops and Lipids**, v. 24, n. 1, p. 1–7, 2017.

RIZEEI, H. M. et al. Oil palm counting and age estimation from WorldView-3 imagery and LiDAR data using an integrated OBIA height model and regression analysis. **Journal of Sensors**, v. 2018, 2018.

- RÖLL, A. et al. Transpiration in an oil palm landscape: effects of palm age. **Biogeosciences**, v. 12, n. 19, p. 5619–5633, 5 out. 2015.
- RUSLAN, S. A. et al. Using satellite-measured relative humidity for prediction of *Metisa plana*'s population in oil palm plantations: A comparative assessment of regression and artificial neural network models. **PLoS ONE**, v. 14, n. 10, p. 1–15, 2019.
- SABAJO, C. R. et al. Expansion of oil palm and other cash crops causes an increase of the land surface temperature in the Jambi province in Indonesia. **Biogeosciences**, v. 14, n. 20, p. 4619–4635, 2017.
- SAGAR, H. S. S. C. et al. India in the Oil Palm Era: Describing India's dependence on palm oil, recommendations for sustainable production, and opportunities to become an influential consumer. **Tropical Conservation Science**, v. 12, p. 1–9, 29 jan. 2019.
- SALDIVIA-TEJEDA, A. et al. Permanent Bed Width Has Little Effect on Crop Yield under Rainfed and Irrigated Conditions across Central Mexico. **Agriculture**, v. 11, n. 10, p. 930, 27 set. 2021.
- SANTOS, C. A. C. DOS et al. Trends in precipitation extremes over the Northern part of Brazil from ERA40 dataset. **Revista Brasileira de Geografia Física**, v. 5, n. 4, p. 836–851, 9 nov. 2012.
- SANTOS, D. J. DOS et al. Future rainfall and temperature changes in Brazil under global warming levels of 1.5°C, 2°C and 4°C. **Sustentabilidade em Debate**, v. 11, n. 3, p. 57–90, 31 dez. 2020.
- SANTOS, L. S. et al. Paisagem rural da microrregião de Tomé-Açu sob a ótica bertrandiana. **Revista Brasileira de Geografia Física**, v. 12, n. 7, p. 2694, fev. 2019.
- SARR, M. et al. Who benefits from climate-friendly agriculture? The marginal returns to a rainfed system of rice intensification in Tanzania. **World Development**, v. 138, p. 105160, fev. 2021.

SASIRAT, P. et al. Influence of Tropical Climate Parameters on Properties of Acid Sulfate Soils for Sustainable Oil Palm Cultivation. **International Journal of Agronomy**, v. 2019, 2019.

SERRANO-NOTIVOLI, M. R. Package ' bioclim '. 2023.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, v. 52, n. 3/4, p. 591, dez. 1965.

SHEAVES, M. et al. Impact of oil palm development on the integrity of riparian vegetation of a tropical coastal landscape. **Agriculture, Ecosystems and Environment**, v. 262, n. October 2017, p. 1–10, 2018.

SIBHATU, K. T. et al. Spatial heterogeneity in smallholder oil palm production. **Forest Policy and Economics**, v. 139, n. April, p. 102731, jun. 2022.

SIDIBÉ, Y. et al. Adaptation to Climate Change in Rainfed Agriculture in the Global South: Soil Biodiversity as Natural Insurance. **Ecological Economics**, v. 146, n. June 2017, p. 588–596, abr. 2018.

SILUNGWE, F. R. et al. Modelling Rainfed Pearl Millet Yield Sensitivity to Abiotic Stresses in Semi-Arid Central Tanzania, Eastern Africa. **Sustainability**, v. 11, n. 16, p. 4330, 10 ago. 2019.

SILVA, A. K. L. et al. Estimation of sediment production in oil palm expansion areas in the Amazon. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 5, p. 344–348, 2018.

SINGH, S. Farmers' perception of climate change and adaptation decisions: A micro-level evidence from Bundelkhand Region, India. **Ecological Indicators**, v. 116, n. April, p. 106475, set. 2020.

SOUSA, A. C.; CANDIDO, L. A.; SATYAMURTY, P. Convective Cloud Clusters and Squall Lines along the Coastal Amazon. **Monthly Weather Review**, v. 149, n. 11, p. 3589–3608, nov. 2021.

SRINIVASA RAO, C. et al. Farm Ponds for Climate-Resilient Rainfed Agriculture.

**Current Science**, v. 112, n. 03, p. 471, 10 fev. 2017.

STIEGLER, C. et al. El Niño–Southern Oscillation (ENSO) event reduces CO<sub>2</sub> uptake of an Indonesian oil palm plantation. **Biogeosciences**, v. 16, n. 14, p. 2873–2890, 31 jul. 2019.

STIEGLER, C. et al. Temporal variation in nitrous oxide (N<sub>2</sub>O) fluxes from an oil palm plantation in Indonesia: An ecosystem-scale analysis. **GCB Bioenergy**, v. 15, n. 10, p. 1221–1239, 14 out. 2023.

SUSANTI, A.; MARYUDI, A. Development narratives, notions of forest crisis, and boom of oil palm plantations in Indonesia. **Forest Policy and Economics**, v. 73, p. 130–139, 2016.

SWAILS, E. et al. The response of soil respiration to climatic drivers in undrained forest and drained oil palm plantations in an Indonesian peatland.

**Biogeochemistry**, v. 142, n. 1, p. 37–51, 2019.

SWAILS, E. et al. How can process-based modeling improve peat CO<sub>2</sub> and N<sub>2</sub>O emission factors for oil palm plantations? **Science of The Total Environment**, v. 839, n. January, p. 156153, set. 2022.

TABI, F. O.; MUKI, E. Agro-economic implications of weather variation on oil palm yield and yield components in the humid forest zone of Cameroon. **IOP Conference Series: Earth and Environmental Science**, v. 6, n. 47, 1 fev. 2009.

TAN, K. P.; KANNIAH, K. D.; CRACKNELL, A. P. On the upstream inputs into the MODIS primary productivity products using biometric data from oil palm plantations. **International Journal of Remote Sensing**, v. 35, n. 6, p. 2215–2246, 2014.

TANI, N. et al. Small temperature variations are a key regulator of reproductive growth and assimilate storage in oil palm (*Elaeis guineensis*). **Scientific Reports**, v. 10, n. 1, p. 1–11, 2020.

TAO, H. H. et al. Effects of best management practices on dry matter production and fruit production efficiency of oil palm. **European Journal of Agronomy**, v. 90,

n. December 2016, p. 209–215, out. 2017.

TENG, K. C. et al. A dense medium microwave backscattering model for the remote sensing of oil palm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 6, p. 3250–3259, 2015.

THIESSEN, A. H. Precipitation averages for large areas. **Monthly Weather Review**, v. 39, n. 7, p. 1082–1089, jul. 1911.

THOMPSON-MORRISON, H. et al. Development and use of a mass-balance model to calculate the likely effects of agrichemicals on trace element accumulation in soils supporting palm oil production. **Soil Use and Management**, 3 jul. 2023.

THORNTHWAITE, C. W.; MATHER, J. R. **The Water Balance**. [s.l.] Drexel Institute of Technology, Laboratory of Climatology, 1955.

TUKEY, J. W. **Exploring Data Analysis**. [s.l.] Addison-Wesley, 1977.

URETA, C. et al. Maize yield in Mexico under climate change. **Agricultural Systems**, v. 177, n. September 2019, p. 102697, jan. 2020.

VAN KRAALINGEN, D. W. .; BREURE, C. .; SPITTERS, C. J. . Simulation of oil palm growth and yield. **Agricultural and Forest Meteorology**, v. 46, n. 3, p. 227–244, maio 1989.

VANSCHOENWINKEL, J.; VAN PASSEL, S. Climate response of rainfed versus irrigated farms: the bias of farm heterogeneity in irrigation. **Climatic Change**, v. 147, n. 1–2, p. 225–234, 16 mar. 2018.

VÁZQUEZ-RAMÍREZ, A. et al. Real-Time Detection of Bud Degeneration in Oil Palms Using an Unmanned Aerial Vehicle. **Eng**, v. 4, n. 2, p. 1581–1596, 2023.

VIJAY, V. et al. Deforestation risks posed by oil palm expansion in the Peruvian Amazon. **Environmental Research Letters**, v. 13, n. 11, 2018.

VILLELA, A. A. et al. Status and prospects of oil palm in the Brazilian Amazon. **Biomass and Bioenergy**, v. 67, p. 270–278, ago. 2014.

WAITE, P. A. et al. Soil moisture regime and palm height influence embolism resistance in oil palm. **Tree Physiology**, v. 39, n. 10, p. 1696–1712, 2019.

WANG, X. et al. Global irrigation contribution to wheat and maize yield. **Nature Communications**, v. 12, n. 1, p. 1235, 23 fev. 2021.

WATSON-HERNÁNDEZ, F. et al. Quantification and Evaluation of Water Requirements of Oil Palm Cultivation for Different Climate Change Scenarios in the Central Pacific of Costa Rica Using APSIM. **Agronomy**, v. 13, n. 1, p. 19, 21 dez. 2022.

WATSON-HERNÁNDEZ, F.; GÓMEZ-CALDERÓN, N.; DA SILVA, R. P. Oil Palm Yield Estimation Based on Vegetation and Humidity Indices Generated from Satellite Images and Machine Learning Techniques. **AgriEngineering**, v. 4, n. 1, p. 279–291, 3 mar. 2022.

WEBLER, G. et al. Evaluation of a dynamic agroecosystem model (Agro-IBIS) for soybean in Southern Brazil. **Earth Interactions**, v. 16, n. 12, p. 1–15, 2012.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184–194, 1981.

WISENA, B. A. et al. Sustainable Development Strategy for Improving the Competitiveness of Oil Palm Industry. **International Research Journal of Business Studies**, v. 7, n. 1, p. 13–37, 1 abr. 2014.

WOITTIEZ, L. S. et al. Yield gaps in oil palm: A quantitative review of contributing factors. **European Journal of Agronomy**, v. 83, p. 57–77, 2017.

XAVIER, A. C. et al. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, n. May, p. 1–15, jun. 2022.

XIN, Y.; SUN, L.; HANSEN, M. C. Biophysical and socioeconomic drivers of oil palm expansion in Indonesia. **Environmental Research Letters**, v. 16, n. 3, 2021.

XU, B. et al. Empirical Evaluation of Rectified Activations in Convolutional Network. 2015.

XU, K. et al. A new machine learning approach in detecting the oil palm plantations using remote sensing data. **Remote Sensing**, v. 13, n. 2, p. 1–17, 12 jan. 2021.

XU, Y. et al. Oil palm modelling in the global land-surface model ORCHIDEE-MICT. **Geoscientific Model Development Discussions**, p. 1–32, 2020.

YU, L. et al. A study of the serious conflicts between oil palm expansion and biodiversity conservation using high-resolution remote sensing. **Remote Sensing Letters**, v. 14, n. 6, p. 654–668, 2023.

ZHENG, J. et al. Cross-regional oil palm tree counting and detection via a multi-level attention domain adaptation network. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 167, n. July, p. 154–177, 2020.

ZHENG, J. et al. Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, n. January, p. 95–121, 2021.