



**THIAGO ORLANDO COSTA BARBOZA**

**ASSOCIAÇÃO ENTRE VARIÁVEIS CLIMÁTICAS E ÍNDICES  
DE VEGETAÇÃO NA ESTIMATIVA DA MATURAÇÃO DE  
AMENDOIM UTILIZANDO REDES NEURAS ARTIFICIAIS**

**LAVRAS – MG  
2023**

**THIAGO ORLANDO COSTA BARBOZA**

**ASSOCIAÇÃO ENTRE VARIÁVEIS CLIMÁTICAS E ÍNDICES DE VEGETAÇÃO  
NA ESTIMATIVA DA MATURAÇÃO DE AMENDOIM UTILIZANDO REDES  
NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração Produção Vegetal, para a obtenção do título de Mestre.

Prof. Dr. Adão Felipe dos Santos  
Orientador

Dra. Taynara Tuany Borges Valeriano  
Coorientadora

**LAVRAS-MG  
2023**

**THIAGO ORLANDO COSTA BARBOZA**

**ASSOCIAÇÃO ENTRE VARIÁVEIS CLIMÁTICAS E ÍNDICES DE VEGETAÇÃO  
NA ESTIMATIVA DA MATURAÇÃO DE AMENDOIM UTILIZANDO REDES  
NEURAS ARTIFICIAIS**

**ASSOCIATION BETWEEN CLIMATIC VARIABLES AND VEGETATION INDICES  
IN PEANUT MATURITY PREDICTION USING ARTIFICIAL NEURAL  
NETWORKS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração Produção Vegetal, para a obtenção do título de Mestre.

APROVADO em 18 de JULHO de 2023

Prof<sup>a</sup>. Dra. Franciele Morlin Carneiro

---

Prof<sup>a</sup>. Dra. Lorena Nunes Lacerda

---

Prof. Dr. Adão Felipe dos Santos

---

Orientador

Dra. Taynara Tuany Borges Valeriano

---

Coorientadora

**LAVRAS-MG  
2023**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo próprio autor.**

Barboza, Thiago Orlando Costa.

Associação entre variáveis climáticas e índices de vegetação na  
estimativa da maturação de amendoim utilizando redes neurais  
artificiais / Thiago Orlando Costa Barboza. - 2023.

94 p.: il.

Orientador: Adão Felipe dos Santos.

Coorientadora: Taynara Tuany Borges Valeriano.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2023.

Bibliografia.

1. Redes Neurais Artificiais. 2. Índices de Vegetação. 3.  
Variáveis Climáticas. I. Santos, Adão Felipe dos. II. Valeriano,  
Taynara Tuany Borges. III. Título.

*A minha mãe Silvia Helena Costa Barboza e ao meu pai Reginaldo Aparecido Ferreira Barboza, pelo apoio, carinho, esperança e fé depositados em mim e por serem meu maior exemplo de vida.*

*Dedico a vocês!*

*A todos meus primos(as), tios(as), avós e avôs em especial ao meu avô Orlando Costa (in memorian), por ter sido um grande exemplo aos meus pais.*

*Ofereço!*

## AGRADECIMENTOS

Em primeiro lugar, gostaria de agradecer aos meus pais Reginaldo Aparecido Ferreira Barboza e Silvia Helena Costa Barboza pelo incentivo, apoio e confiança depositados em mim, que ao longo dos meus anos de vida sempre se colocaram à disposição em me ajudar. Da mesma forma, gostaria de agradecer ao meu irmão Reginaldo Erik Costa Barboza e a Juliana Vasconcelos de Assis, por me incentivar durante o processo de formação na pós-graduação e por todo apoio, carinho, incentivo, ajuda e paciência ao longo desses anos.

Estendo meus agradecimentos aos meus tios Laudinei Romanello e Mario Gilberto Costa, tias Marilza Ferreira Barboza Romanello e Neusa Aparecida Costa dos Santos, primas Lana Pietra Romanello e Narian Romanello, pelo apoio e incentivo durante esses anos de estudo. Aos meus amigos que conheci ao longo dos anos de estudo em especial a Layane Aparecida Mendes dos Santos, Rodrigo Silva Alves, Otavio Augusto Andrade Oliveira, Victor Augusto da Costa Escarela e ao Marcelo Araújo Junqueira Ferraz por sempre me apoiar, me tolerar e compartilhar de momentos juntos durante todos esses anos, meu muito obrigado.

Ao meu orientador Prof. Dr. Adão Felipe dos Santos por me acompanhar durante essa jornada acadêmica, me instruindo e colaborando com o aperfeiçoamento dos meus conhecimentos. Muito obrigado por me ajudar a despertar meu lado crítico, por servir como referência na área de estudo e pelo excelente relacionamento pessoal e profissional que desenvolvemos durante esses anos. Ao professor Prof. Dr. Rouverson Pereira da Silva gostaria de agradecer por me incentivar a entrar na pós-graduação, pelo apoio e acolhimento que sempre teve comigo tanto no meio acadêmico como no meio pessoal.

Ao Grupo de Extensão e Pesquisa em Agricultura Digital (GEPAD) pela ajuda e acompanhamento durante os 16 meses de estudo e participação nas reuniões, que me apresentaram o lado bom da troca de experiência e debate na área de agricultura de precisão e digital, meu muito obrigado.

A Universidade Federal do Triângulo Mineiro, campus Iturama, MG, Universidade Estadual Paulista “Julio de Mesquita Filho” UNESP/FCAV, campus Jaboticabal, Universidade da Geórgia (UGA), campus de Tifton, GA, pela disponibilidade das informações para realização do estudo e pelo suporte durante as coletas para a avaliação. A Universidade Federal de Lavras, em especial ao programa de Pós-graduação em agronomia/fitotecnia por todo suporte, estrutura e conhecimentos fornecidos pelos docentes, servidores e técnicos que compõem o setor, muito obrigado.

Aos órgãos e agências de fomentos a pesquisa FAPEMIG (Fundação de Amparo a Pesquisa do Estado de Minas Gerais) pela aprovação do projeto (número apq-00219-21) e todo o desembolso para a realização do mesmo e a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa de estudo e pela oportunidade de ingressar na pós-graduação.

Por fim, gostaria de agradecer todas as pessoas que de alguma forma me apoiaram e incentivaram e que fizeram eu chegar até aqui. Saibam que todo esse esforço não é só mérito meu, mas sim de toda essa união! Muito obrigado.

## RESUMO

A avaliação da maturação de amendoim (PMI) que utiliza do quadro de maturação apresenta uma grande subjetividade. Uma das soluções para diminuir esses erros é a combinação da inteligência artificial com os índices de vegetação (IVs) e dados climáticos. Para a avaliação da plataforma NASA-POWER foram utilizados quatro campos comerciais com a cultivar Geórgia-06G localizados no estado da Georgia, USA (Tifton, Dougherty, Berrien, Coffee). O PMI foi avaliado em 5 épocas para Dougherty e 4 épocas para Tifton e 6 épocas para Coffee e Berrien a partir do método Hull-scrape. As variáveis climáticas avaliadas foram temperatura máxima (tmax), mínima (tmin), média (tmean), radiação solar (Qg), velocidade do vento (WS), umidade relativa (UR) e pressão de superfície (PS). Foi realizada a análise de regressão linear tomando como variável independente os valores da NASA-POWER e como variáveis dependentes os valores das estações meteorológicas de superfície. As métricas de acurácia e precisão foram raiz quadrada do erro médio (RMSE), coeficiente de determinação ( $R^2$ ) e a correlação de Pearson ( $p < 0,05$ ). Ao final, realizada a Análise de Componentes Principais (PCA). As variáveis tmax, tmin, tmean e Qg apresentam os melhores ajustes 0,95, 0,96, 0,91, 0,94 de  $R^2$ , respectivamente. Por outro lado, WS e UR não apresentaram um bom ajuste com  $R^2$  de 0,34 e 0,38. Os resultados comparando as plataforma NASA-POWER (predito) e as estações meteorológicas de superfície (observado) demonstram que a plataforma NASA-POWER é precisa e acurada para o fornecido dos dados climáticos de Qg, Tmax, Tmin, Tmean e PS. Feito isso foram incluídos mais dois estados do Brasil (Minas Gerais e São Paulo) para avaliar a maturação. Em MG contava com uma área e SP 6 áreas, em ambas as áreas a maturação foi avaliada em 5 épocas pelo método Hull-scrape. A partir disso, foram calibrados quatro modelos do tipo MLP um para cada estado (GA, MG e SP) e um outro a partir da união de todos os locais (Global). Para cada local foram calculados nove índices de vegetação (IVs) e utilizados quatro variáveis climáticas além do AGD e das bandas do vermelho e do NIR. Além disso, foi utilizada a PCA, correlação de Pearson ( $p < 0,05$ ) e análise sensitiva para seleção das combinações entre os parâmetros de entrada. Os algoritmos de treinamento utilizados foram *Backpropagation* e o *Levenberg-marquardt* individualmente e combinados. As redes calibradas foram avaliadas de acordo com o RMSE, MAE e  $R^2$ . O melhor modelo calibrado foi para o estado da Geórgia, que apresentou os valores de 0,9428, 0,080 e 0,060 de  $R^2$ , RMSE e MAE, para o teste. Dentre os métodos de treinamento o *Levenberg-marquardt* foi o melhor, e entre os IVs e dados climáticos o MNLI, AGD e Qg foram os que se destacaram. Os demais locais apresentaram uma variação de 4% e 9% em relação ao  $R^2$  e 10% (máximo) para RMSE comparação ao modelo da GA no teste. Os modelos calibrados são capazes de estimar o PMI, no entanto, estudos devem ser desenvolvidos para outros genótipos de amendoim e sobre os tipos de solos.

**Palavras-chaves:** NASA-POWER. Inteligência artificial. Maturação. *Arachis hypogaea* L.



## ABSTRACT

The assessment of peanut maturity (PMI) using the maturity frame is very subjective. One of the solutions to reduce these errors is the combination of artificial intelligence with vegetation indices (IVs) and climate data. For the evaluation of the NASA-POWER platform, four trade fields were used for cultivating Georgia-06G located in the state of Georgia, USA (Tifton, Dougherty, Berrien, Coffee). The PMI was evaluated into 5 seasons for Dougherty and 4 seasons to Tifton and 6 seasons of Coffe and Berrien from the Hull-scrape method. The climate variables evaluated were maximum temperature (tmax), minimum (tmin), average (tmean), solar radiation (Qg), wind speed (WS), relative humidity (UR) and surface pressure (PS). linear regression analysis was carried out taking as independent variable the values of NASA-POWER and as dependent variables the value of surface weather stations. The metrics of accuracy and precision were the square root of the average error (RMSE), determination coefficient ( $R^2$ ) and Pearson correlation ( $p < 0,05$ ). Analysis of the main components (PCA). The variables tmax, tmin, tmean and Qg present the best adjustment of  $R^2$  at 0.95, 0.96, 0.91, 0.94, respectively. On the other hand, WS and UR did not present a good adjustment with  $R^2$  of 0.34 and 0.38. The results comparing the NASA-POWER platforms (predicted) and surface weather stations (observed) demonstrate that the NASA-Power platform is accurate and accurate for providing the climate data for Qg, Tmax, Tmin, Tmean and PS. Two other Brazilian states (Minas Gerais and São Paulo) were included to evaluate maturity. In MG counted one area and SP 6 areas, in both areas the maturity was assessed in 5 seasons by the Hull-scrape method. From that, four MLP type models were calibrated one for each state (GA, MG and SP) and another from the union of all locations (Global). For each site nine vegetation indices (IVs) were calculated and four climate variables were used in addition to the AGD and the red and NIR bands. In addition, PCA, Pearson correlation ( $p < 0,05$ ) and sensitive analysis were used to select the combinations between the input parameters. The training algorithms used were Backpropagation and Levenberg-marquardt individually and combined. The calibrated networks were evaluated according to RMSE, MAE and  $R^2$ . The best calibrated model was for the state of Georgia, which presented the values of 0,9428, 0,080 and 0,060 of  $R^2$ , RMSE and MAE, for the test. Among the training methods the Levenberg-marquardt was the best, and among the IVs and climate data the MNLI, AGD and Qg were the ones that stood out. The other locations showed a variation of 4% and 9% from  $R^2$  and 10% (maximum) for RMSE compared to the GA model in the test. Calibrated models are able to estimate PMI, however, studies should be developed for other peanut genotypes and on soil types.

**Keywords:** NASA-POWER. Artificial Intelligence. Maturity. *Arachis hypogaea* L.

## LISTA DE FIGURAS

### REFERENCIAL TEÓRICO

Figura 1 - <i>peanut profile board</i> .....	20
Figura 2 - Fluxograma da avaliação dos dados em inteligência artificial.....	23
Figura 3 - Modelo do primeiro neurônio artificial.....	24
Figura 4 - Comparação entre as redes RBF (a) sua divisão em hiperelipsóides (b); rede MLP (c) e sua divisão em hiperplanos (d).....	25

### CAPÍTULO 1

Figura 1 – localização das áreas de produção de amendoim no estado da Geórgia, USA.....	39
Fluxograma 1 – Etapas de avaliações da maturação e comparação entre a plataforma NASA-POWER e as estações meteorológicas de superfície.....	43
Figura 2 – Análise de correlação para a localização de Berrien (a), Coffe (b), Dougherty (c), Tifton (d) e para o modelo geral $\epsilon$ de dois anos (2018 e 2019) de coleta de dados.....	45
Figura 3 – Análise de regressão linear, $R^2$ , RMSE e índice de desempenho de Willmott (d) para pressão de superfície. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....	47
Figura 4 – Análise de regressão linear, $R^2$ , RMSE e índice de desempenho de Willmott (d) para velocidade do vento. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....	48
Figura 5 – Análise de regressão linear, $R^2$ , RMSE e índice de desempenho de Willmott (d) para radiação solar. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....	49
Figura 6 – Análise de regressão linear, $R^2$ , RMSE e índice de desempenho de Willmott (d) para temperatura máxima. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....	51
Figura 7 – Análise de regressão linear, $R^2$ , RMSE e índice de desempenho de Willmott (d) para temperatura mínima. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....	52

Figura 8 – Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott (d) para temperatura média. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.....53

Figura 9 – Análise de PCA. (a) representa a PCA do modelo geral; (b) representa a PCA da região de Coffee; (c) representa a PCA da região de Tifton; (d) representa a PCA da região de Berrien; (e) representa a PCA da região de Dougherty.....55

## CAPÍTULO 2

Figura 1 – mapa de localização das regiões onde foram realizadas as coletas para a avaliação da maturação.....67

Figura 2 – média de 10 anos da temperatura ( $^{\circ}\text{C}$ ) e radiação solar ( $\text{Mj m}^2 \text{ dia}^{-1}$ ) dos locais de estudo.....67

Figura 3 – Vagens sendo lavadas sobre alta pressão para retirada do exocarpo (A) e classificação das vagens com o mesocarpo exposto (B).....69

Fluxograma 1 – Etapas realizadas de coleta (seta vermelha), análises prévias dos dados (setas amarelas) e calibração das redes neurais do tipo perceptron de multicamadas (MLP) (seta verde).....79

Figura 4 – análise de correlação para os dados utilizados para criação dos modelos de MLP.....80

Figura 5 – Análise de componentes principais (PCA) entre as variáveis climáticas e os índices de vegetação para cada modelo calibrado.....82

Figura 6 – Figura 5 - gráfico entre os valores observados e preditos do treinamento, seleção e teste de cada modelo da rede MLP calibrado.....86

Figura 7 – gráfico entre os valores observados e preditos do treinamento, seleção e teste de cada modelo da rede MLP calibrado.....87

## Sumário

<b>1 INTRODUÇÃO</b> .....	<b>14</b>
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>15</b>
2.1 Cultura do amendoim.....	15
2.2 Maturação e colheita do amendoim .....	18
2.3 Inteligência artificial na agricultura .....	21
2.3.1 Redes neurais artificiais.....	22
2.4 Sensoriamento remoto .....	26
2.5 Plataforma orbital de monitoramento climático.....	28
<b>3 REFERÊNCIAS</b> .....	<b>31</b>
<b>CAPÍTULO 1 - Comparação entre estações meteorológicas de superfície e dados NASA-POWER na estimativa da maturação de amendoim.....</b>	<b>36</b>
<b>1 INTRODUÇÃO</b> .....	<b>37</b>
<b>2 MATERIAL E MÉTODOS</b> .....	<b>38</b>
2.1 Local de estudo.....	38
2.2 Avaliação das vagens de amendoim .....	39
2.3 Coleta das informações climáticas.....	40
2.4 Análise estatística entre as duas plataformas.....	42
<b>3 RESULTADOS E DISCUSSÃO</b> .....	<b>44</b>
<b>4 CONCLUSÃO</b> .....	<b>56</b>
<b>REFERÊNCIAS</b> .....	<b>58</b>
<b>ANEXO</b> .....	<b>61</b>
<b>CAPÍTULO 2 – Aplicando inteligência artificial para identificar a maturação de amendoim usando variáveis climáticas e índices de vegetação .....</b>	<b>64</b>
<b>1 INTRODUÇÃO</b> .....	<b>65</b>
<b>2 MATERIAL E MÉTODOS</b> .....	<b>66</b>
2.1 Área de estudo .....	66
2.2 Cálculo da maturação.....	69
2.3 Coleta de dados climáticos .....	70
2.3.1 Acumulado de graus dias (AGD) .....	71
2.4 Imagens de satélite e cálculo dos índices de vegetação .....	72
2.5 Análises de PCA e correlação .....	74
2.6 Perceptron de Multicamadas (MLP) .....	74
2.6.1 Treinamento da rede do tipo Perceptron de Multicamadas (MLP).....	76
2.6.2 Avaliação das redes .....	78
<b>3 RESULTADOS E DISCUSSÃO</b> .....	<b>79</b>

<b>4 CONCLUSÃO.....</b>	<b>89</b>
<b>CONSIDERAÇÕES FINAIS.....</b>	<b>90</b>
<b>REFERÊNCIAS .....</b>	<b>91</b>

## 1 INTRODUÇÃO

A espécie *Arachis hypogaea* L. é descrita como a principal espécie comercial encontrada nos trópicos e subtropicais (BERTIOLI et al., 2011). Tal espécie é capaz de produzir grãos com altas quantidades de óleo, proteínas, minerais e vitaminas que são importantes para a alimentação humana e animal, como também na produção de óleo para o mercado consumidor (VARIATH; JANILA, 2017).

A produção dessa cultura tem aumentado cerca de 1,74% entre os anos de 1980 – 2014 (VARIATH; JANILA, 2017). Além disso, 64% da produção mundial se concentra na China, Índia, Nigéria e Estados Unidos que apresentam uma média de produtividade dos últimos 5 anos de 3.800, 1.200, 1.300 e 4.500 quilogramas por hectare de produtividade (USDA, 2013).

Apesar disso, um dos grandes fatores que restringe a produção do amendoim são as condições climáticas da área. A temperatura é descrita como o principal fator limitante da cultura, especialmente na produção de flores e vagens (NOGUEIRA; TAVORA, 2005; NETO; COSTA; CASTRO, 2012), o que fica mais evidente quando é observada relação com do somatório térmico (graus dias acumulado) com a maturação (SANTOS et al., 2021b; SOUZA et al., 2022).

Dessa forma, a temperatura é capaz de influenciar diretamente a duração do ciclo de cultivo do amendoim (NOGUEIRA; TAVORA, 2005; BOOTE, 1982). Tal efeito se torna mais acentuado na determinação da época de entrada das máquinas no campo para a realização do processo mecanizado de arranquio, visto que é realizada a avaliação da maturação das vagens.

Nesse sentido, para determinar a época de arranquio é comum realizar a avaliação pelo quadro de maturação de William e Drexler (1981). No entanto, o método apresenta uma alta subjetividade, não contabilizando a variabilidade entre plantas e na própria planta (SANTOS et al. 2021a; SANTOS et al., 2021b).

Por outro lado, o quadro de maturação foi desenvolvido para atender as cultivares norte americanas que acumulam no ciclo cerca de 2500 graus dias (SANTOS et al., 2021b). No entanto, no Brasil são acumulados aproximadamente 1500 a 1800 graus dias (SOUZA et al. 2022) divergindo das condições encontradas no outro país.

Além disso, como o amendoim apresenta hábito de crescimento do tipo indeterminado são produzidas flores de 30 dias após a semeadura até o momento do arranquio (BOOTE, 1984). Juntamente com isso, a temperatura pode prolongar o ciclo da cultura ou não, sendo mais um fator que vai interferir na maturação das vagens da cultura.

Na literatura são encontrados estudos que utilizam o acumulado de graus dias e diversos índices de vegetação para avaliação da maturação. Além disso, devido a complexidade do problema são aplicadas técnicas de *Machine Learning* para que o algoritmo seja capaz de reconhecer os padrões de maturação e generalizar a situação (SANTOS et al. 2021a; SANTOS et al. 2021b; SOUZA et al., 2022, SANTOS et al., 2019).

No entanto, na grande maioria dos estudos o foco maior é para os índices de vegetação que são capazes de mapear a variabilidade da biomassa. Mas a utilização de variáveis climáticas que influenciam na maturação ainda é pouco explorável. Fato esse que é dificultado até mesmo pela falta de estações meteorológicas próximas as áreas para a realização do monitoramento. Portanto, para suprir essa demanda é indispensável a avaliação de outras ferramentas que são capazes de realizar a coleta de dados climáticos, como os fornecidos pela plataforma NASA-POWER (<https://power.larc.nasa.gov/data-access-viewer/>).

Nesse sentido, a união de dados climáticos fornecidos por plataformas online e gratuitas com índices de vegetação calculados a partir de imagens de satélite são ferramentas promissoras para a investigação da maturação do amendoim. Principalmente por se tratar de plataformas remotas que são capazes de fornecer dados e imagens de qualquer local do globo, o que facilita a análise e estimativa da maturação. Portanto, o trabalho foi desenvolvido para avaliar novas plataformas orbitais como a NASA-POWER e sua capacidade de contribuir com os algoritmos de inteligência artificial na estimativa da maturação juntamente com os índices de vegetação.

Dessa forma, o intuito desse trabalho é avaliar os dados climáticos fornecidos pela plataforma NASA-POWER e identificar as variáveis climáticas que apresentam relação com maturação do amendoim. Ao final sendo possível avaliar a partir da união dos índices de vegetação com as melhores variáveis climáticas o desempenho das redes do tipo perceptron de multicamadas na estimativa da maturação das vagens de amendoim.

## **2 REFERENCIAL TEÓRICO**

### **2.1 Cultura do amendoim**

Para que resultados promissores com o cultivo sejam alcançados, o manejo da cultura deve ser empregado de maneira correta, evitando eventuais problemas ao longo do desenvolvimento da planta, gerando benefícios ao produtor e a indústria que se destina a matéria-prima. Nesse sentido, o conhecimento da cultura e seu comportamento em diferentes

regiões e durante o seu ciclo de desenvolvido é importante para a obtenção do máximo potencial produtivo da planta.

O amendoim (*Arachis hypogaea* L.) é originário da América do Sul, sendo caracterizado como uma planta anual, ramificada, podendo ser de porte ereto ou rasteiro (COELHO; FARIA; DALRI, 2017). A planta de amendoim apresenta diferentes gêneros, no entanto o gênero de maior interesse econômico para o cultivo de grãos e em grande maioria para a produção de óleo é o *Arachis hypogaea* L.

A planta apresenta germinação epígea, com o hipocótilo branco que pode ser facilmente observado nos estádios fenológicos iniciais. As folhas primárias surgem logo após a emergência das plântulas, na sequência surgem as raízes pivotante iniciais e logo em seguida surgem as raízes laterais, com cerca de três dias após a emergência. As flores surgem a partir das axilas das folhas e com geralmente três flores por inflorescência, no entanto, apenas uma dessas três flores será aberta (STALKER, 1997).

Do ponto de vista morfológico, são encontrados cultivares de amendoim pertencentes aos grupos: Virgínia, Valência e Spanish, sendo que os do tipo Virginia runner são os mais encontrados no Brasil. Suas características basicamente são ciclo tardio, frutos grandes possuindo dois grãos por vagens com maturação próximo de 130 dias ou mais (STALKER, 1997). A exemplo, algumas das cultivares semeadas no país são IAC 503, IAC OL3, IAC OL5, desenvolvidas pelo Instituto Agrônomo de Campinas (IAC).

Por pertencer a família das Fabaceae o amendoim apresenta grande capacidade em realizar simbiose com bactérias diazotróficas do gênero *Bradyrhizobium* spp., atuando na fixação biológica de nitrogênio, evidenciando seu potencial uso nos sistemas de rotação e sucessão de culturas, sobretudo na reforma de canaviais como comumente é encontrado (MINGOTTE; MORELLO; LEMOS, 2019).

Diferentemente de outras plantas cultivadas em larga escala, o amendoim possui características morfológicas especiais quanto à produção dos grãos. Isso é, a planta apresenta o desenvolvimento dos frutos (vagens) abaixo do solo enquanto que as flores são formadas acima do solo.

Para diferenciar os períodos de crescimento e desenvolvimento da cultura o amendoim é dividido em dois grandes estádios fenológicos, vegetativo e reprodutivo. O estágio vegetativo é caracterizado pelo início em VE - emergência em que, os cotilédones estão próximos do solo e parte da planta está visível, V0 - cotilédones visíveis e abertos, V1- primeiro tetrafolíolo, e assim continuando até V(N) em que ocorre a abertura e formação dos demais tetrafolíolos (BOOTE, 1982).



No estágio reprodutivo é dividido em nove etapas, compreende desde R1 até R9. Inicialmente em R1, ocorre o início da floração, R2 início da formação do ginóforo e sua alongação, R3 dentro do solo começa a formação da vagem, R4 formação total da vagem, R5 início da formação da semente, R6 formação total da semente, R7 início da maturação, R8 dois terços a três quartos das vages estão com coloração próxima da maturação e R9 maturação total das vagens (BOOTE, 1982).

O estágio fenológico de R1 inicia entorno de 31 DAS, caso a temperatura na área seja alta, então ocorre a antecipação do estágio de R1 e caso for baixa leva ao prolongamento do estágio fenológico. O estágio fenológico de R3 (42 DAS) é marcado pelo desenvolvimento inicial das vagens e sementes, sendo que em R3 é encontrada a época de maior taxa de acúmulo de matéria seca. Durante R4 a planta apresenta sua máxima taxa de crescimento vegetativo e está iniciando o processo de aumento do número e peso de vagens. Na sequência quando em R7 (93 DAS) é encontrado de 86 a 91% do peso seco dos frutos maduros. Quando a planta se encontra em R8, estágio de colheita dos frutos, são encontrados de 70 a 75% dos frutos maduros na planta (BOOTE, 1982), podendo iniciar a colheita, a depender da cultivar encontrada.

Nesse sentido, as vagens são formadas logo após a fecundação no ovário dando espaço a estrutura conhecida como ginóforo que apresenta características de geotropismo positivo se aprofundando de 2,8 a 8 centímetros no solo. Posteriormente ocorre a formação da casca envolta do embrião localizado no topo da vagem que se encontra na ponta do ginóforo. Internamente, as vagens são presas por uma estrutura denominada funículo que realiza o transporte de água e nutrientes para os grãos, quando imaturas as vagens apresentam maior composição de água, com o decorrer do tempo ocorre a maturação e a composição de água e carboidratos diminui, enquanto proteínas e óleos vão aumentando (PILON; MONFORT; GREY, 2019).

No entanto para atingir altas produtividades, além da necessidade de adequar o manejo nutricional e fitossanitário é importante que os fatores climáticos estejam adequados durante o ciclo da cultura. Sendo assim, algumas variáveis climáticas como a temperatura, precipitação, umidade são uns dos principais responsáveis pela perda de produtividade, além do tipo de solo encontrado na área produtora.

Quando relacionamos a temperatura com o cultivo de determinada espécie, a altitude exerce grande influência, principalmente por proporcionar menores temperaturas em altitude mais elevadas. Dessa forma, do ponto de vista prático a temperatura influenciara no crescimento da planta e na duração dos estádios fenológicos da cultura (COELHO; FARIA; DALRI, 2017).

Na cultura do amendoim a temperatura ideal encontrada varia de 25 a 35 °C (NOGUEIRA; TÁVORA, 2005). Temperaturas inferiores podem prolongar os estádios

vegetativos, como também o aumento excessivo pode causar diminuição no número de flores devido ao abortamento. Dessa forma, temperaturas próximas de 30 °C são descritas como ótimas para a fotossíntese e produção de matéria seca (COELHO; FARIA; DALRI, 2017; NETO; COSTA; CASTRO, 2012).

Além disso, a temperatura base que nada mais é do que a temperatura necessária para que a planta continue seu processo de crescimento e desenvolvimento vai variar entre os tipos de amendoim. Sendo assim, os grupos Valencia, Spanish e Virginia de amendoim possuem a temperatura base determinada em 12,5 °C, 13,6 °C e 13,3 °C respectivamente (BAGNALL; KING, 1990).

As exigências hídricas é outro fator limitante na produção principalmente em sistemas de cultivo de sequeiro. Em sistemas de sequeiros a precipitação pode ocorrer de maneira irregular e alguns casos ocorrendo veranicos na área produtora. Quando o amendoim está sobre déficit hídrico ocorre o fechamento dos estômatos, diminuindo a transpiração e a absorção de dióxido de carbono (CO<sub>2</sub>), afetando diretamente na fotossíntese (MANSUR et al., 1998), que por consequência diminuirá a translocação de fotoassimilados.

No ciclo do amendoim, são exigidos de 500 a 700 mm aproximadamente (DONREBOS; KASSAM, 1979). Algumas das fases mais importante e que exigem maiores quantidades de água são a germinação e o enchimento dos grãos. A fase de enchimento de grãos (70 DAS) entre R5 e R6, é época crítica de água para a cultura, sendo estabelecida como a época de maior exigência (PORTER, 2022).

Outro ponto bastante contextualizado dentro do cultivo de amendoim, refere-se ao tipo de solo. Durante os processos mecanizados de colheita, os teores de água no solo influenciam diretamente as perdas pela cultura, principalmente pelo fato de existir uma relação exponencial entre os teores de água no solo e a resistência do ginóforo ao rompimento (INCE; GUZEL, 2003). Dessa maneira, quando ocorre a diminuição dos teores de água, a resistência do ginóforo diminui rapidamente, podendo aumentar as perdas no momento do arranquio (PEREIRA et al., 2013).

## **2.2 Maturação e colheita do amendoim**

Durante o ciclo do amendoim próxima as etapas finais o processo de avaliação da maturação e da produtividade se inicia, essa etapa é o ponto chave para dar início ao processo mecanizado de colheita da cultura. Porém, para a correta tomada de decisão, a avaliação da

maturação deve ser criteriosa, especialmente porque a variabilidade encontrada das vagens entre plantas e em uma mesma planta é alta.

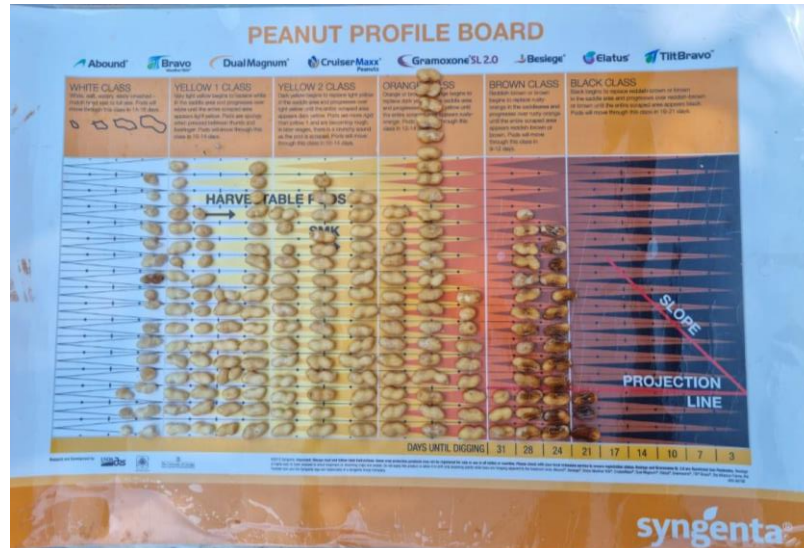
No Brasil, o acompanhamento de grande parte das lavouras ocorre por meio da avaliação dos estádios fenológicos. Entretanto para que a mudança de estádios fenológicos ocorra deve ocorrer o acúmulo de graus dias (AGD) (PEZZOPANE, 2009). Na cultura do amendoim, as cultivares norte-americanas o apresentam uma variação durante o ciclo de 2400 a 2500 AGD (ROWLAND et al., 2006). No Brasil, a relação entre os AGD e a maturação é pouco explorada, na grande maioria dos casos os estudos estão relacionados às cultivares americanas e o clima do país.

De um modo prático, o AGD ajuda os produtores rurais no manejo das lavouras, principalmente no que tange ao momento de colheita e maturação fisiológica das vagens. No estado da Georgia – EUA os produtores consegue ter acesso a uma plataforma que calcula de forma automática o AGD a partir de uma rede de estações que fornece os valores de temperatura máxima e mínima do dia (PEANUTFARM, 2022), podendo assim realizar o manejo na cultura e paralelo a isso saber o momento ideal para iniciar o arranquio.

Nesse sentido, a maturação torna-se um dos parâmetros mais rigorosos a serem avaliados a fim de que os produtores não tenham grandes perdas econômicas (ROWLAND et al., 2006). Diversas metodologias estão sendo desenvolvidas dentro do contexto de agricultura digital, principalmente, trabalhando com redes neurais artificiais e índices de vegetação (SANTOS et al., 2021a; LI et al., 2021; SANTOS et al., 2021b; ZOU et al., 2019; SOUZA et al., 2022). Mas grande parte dos produtores, indústrias e demais técnicos utilizam da metodologia desenvolvidas por Rowland et al., (2006) ocorrendo a classificação das vagens por meio do quadro de maturação do amendoim (*peanut profile board*) (WILLIAMS; DREXLER, 1981).

O método desenvolvido consta basicamente da classificação das vagens de acordo com a coloração do mesocarpo, fato esse observado por Williams e Drexler (1981). Tal coloração é observada na camada do mesocarpo variando de amarelo até preto sendo que quanto mais escura a camada do mesocarpo maior o grau de maturação (Figura 1). Dentro do quadro de maturação são encontradas seis macro divisões (branco, amarelo 1, amarelo 2, laranja, marrom e preto) subdivididas em colunas com diferentes colorações (Figura 1). Para que ocorra a análise da maturação é necessário que aproximadamente 150 a 200 vagens sejam classificadas no quadro, podendo assim calcular o índice de maturação do amendoim (PMI) (ROWLAND et al., 2006).

Figura 1 – Quadro de maturação.



Fonte: Do autor, 2023.

Após a classificação, ocorre a contagem das vagens dentro de cada coluna, podendo calcular o *peanut maturity index* (PMI) que varia de 0 até 1. Conforme o tempo passa, o cálculo do PMI tende a ficar mais próximo de 1. No entanto em condições de campo o valor adotado para o PMI é de 0,7, sendo esse o momento ideal para iniciar o processo de arranquio. Para obtenção deste valor, é necessário realizar o somatório do número de vagens na coluna marrom com a preta dividindo pelo total de vagens classificadas (ROWLAND et al., 2006).

Na prática, a metodologia desenvolvida por Rowland et al. (2008) juntamente com o quadro de maturação de William e Drexler (1981), realiza a coleta de uma ou duas amostras de 200 vagens por hectare. Ocorrendo a classificação e cálculo do PMI, a partir disso, os valores obtidos serão extrapolados para o talhão em que a amostra foi retirada. Quando a análise é feita dessa forma não é contabilizada a variabilidade existente entre as plantas e nas próprias plantas, visto que desde aos 30 DAS até 110 DAS é possível ter flores e vagens nas plantas aumentando as incertezas sobre a maturação da cultura e tornando o método de análise subjetivo. Além disso para a correta classificação a habilidade do profissional é um ponto chave para a diferenciação das classes de coloração do quadro de maturação, tornando o processo oneroso e dependente da capacidade do técnico (SANTOS et al., 2021a; ROWLAND et al., 2008).

Portanto avaliar a maturação é um parâmetro importante para evitar as perdas dentro das lavouras. Tal fato fica mais evidente quando o arranquio se inicia muito cedo com a grande maioria das vagens ainda imaturas levando a perda de qualidade dos grãos. Por outro lado,

quando realizada a colheita tardiamente as vagens podem desprender da planta e ficarem retidas no solo, havendo redução na produtividade (SANTOS et al., 2019).

Não apenas a maturação, mais outras perdas estão relacionadas com a cultura no processo de arranquio. Dentre elas, podemos citar as perdas visíveis e invisíveis encontradas durante o arranquio, as visíveis são aquelas em que as vagens se localizam na superfície do solo e as invisíveis são as vagens encontradas abaixo do solo (SILVA, 2019). Os valores de perdas, variam de acordo com cada região, lavoura, tipo de solo, etc. indo de regiões com 3% até 48% de perdas, a depender do manejo adotado e das características edafoclimáticas (CAVICHOLI et al., 2014; SANTOS et al., 2013).

Portanto, encontrar um limiar entre o momento ótimo para o iniciar o arranquio e a maturação da cultura é o grande alvo de diversas instituições privadas e públicas do país. Dessa forma, como os AGDs apresentam uma boa relação com a maturação, a associação entre as variáveis climáticas direta (temperatura, radiação solar, pressão de superfície, etc.) e indiretamente (AGD) juntamente com o uso de índices de vegetação e algoritmos de aprendizado de máquinas são uma das possíveis soluções para o problema em questão.

### **2.3 Inteligência artificial na agricultura**

Os conceitos e desenvolvimento da inteligência artificial (IA) iniciaram até antes de 1940 com os primeiros trabalhos publicados de Isaac Asimov. A partir das suas publicações, Asimov inspirou outros cientistas a estudarem e aprimorarem os aprendizados em IA, como foi o caso de Mavin Minsky que se tornou um dos co-fundadores do laboratório de inteligência artificial do MIT (HAELEIN; KAPLAN, 2019). Dessa forma, os estudos voltados a área de IA começaram a se intensificar e novas subáreas foram criadas dentro da IA.

A IA em sua ampla área como já se sabe é estudada a anos, no entanto começou a ganhar notória importância a poucos anos quando começou a ser implementada em diversos setores (industriais, agrícolas, automobilísticos, medicinais, etc.). A IA pode ser definida como a capacidade do algoritmo em interpretar os dados externos corretamente, aprender com esses dados e aplicar esse aprendizado na identificação dos objetivos propostas e na resolução de tarefas flexíveis (HAENLEIN; KAPLAN, 2019).

A IA possui diversas ferramentas de trabalho, sendo que essas ferramentas são utilizadas a partir do problema encontrado, podendo selecionar aquelas que melhor se encaixam. Algumas das ferramentas mais encontradas na inteligência artificial e que são aplicadas na agricultura são o *Machine Learning* (ML) e o *Deep learning* (DP). Dentre essas áreas uma de grande

destaque e que vem impulsionando a análise de dados e imagens é o *Machine learning*. Apesar de ser uma subárea dentro da inteligência artificial o ML pode ser dividido ainda em duas partes principais as redes neurais artificiais e *Deep learning*.

O funcionamento dos algoritmos de ML é dividido em três etapas básicas: entrada de dados, construção dos modelos e generalização, sendo a última etapa a aplicação do algoritmo em dados não utilizados para o treinamento. Dessa forma, os algoritmos podem ser utilizados para a identificação de doenças, na predição climática e reconhecimento de padrões, fatores que seriam dificilmente detectados pelos humanos e pelos métodos tradicionais de análise de dados (SHARMA et al. 2020).

Para que uma rede tenha a capacidade de generalização, é necessário que ocorra o treinamento. O treinamento da rede pode ser realizado de três formas, os quais são mais comuns de serem encontrados, sendo eles supervisionado, não supervisionado e com reforço. No treinamento supervisionado é apresentado um conjunto de dados a rede selecionando as variáveis de entrada (*input*) e de saída (*output*) (SHARMA et al. 2020).

Já no treinamento não supervisionado os dados não são rotulados e a rede deve ter a capacidade de agrupar as formas e objetos parecidos, ou seja, o objetivo do treinamento é extrair informações sobre o alvo para usar como treinamento. Por último, no treinamento com reforço o algoritmo é punido quando a resposta ou saída informada está errada, dessa forma melhorando o aprendizado do algoritmo (SHARMA et al. 2020). Apesar desses três métodos apresentados, são encontradas mais formas de se realizar o treinamento das redes.

Dentre os trabalhos encontrados na literatura que enfatizam o uso da ML, como é o caso da maturação de amendoim em que alguns autores já relataram o uso de ML (SANTOS et al. 2021; SOUZA et al. 2022), na identificação por imagens de doenças em diversas culturas (WANI et al. 2022) e também na predição da produtividade (KLOPENBURG et al. 2020).

Portanto, a utilização de tais algoritmos é uma forma de torna a agricultura mais sustentável, conectada e eficiente, de modo a permitir que o produtor tenha controle sobre o que pode ocorrer em sua lavoura e assim tomar as possíveis decisões, baseando nas análises realizada pelo modelo. Portanto a combinação de diversos tipos de algoritmos (ML, redes neurais artificiais e *Deep learning*) e a construção de novos modelos cada vez mais apurados nas respostas são formas encontradas de tornar a agricultura ainda mais produtividade.

### **2.3.1 Redes neurais artificiais**

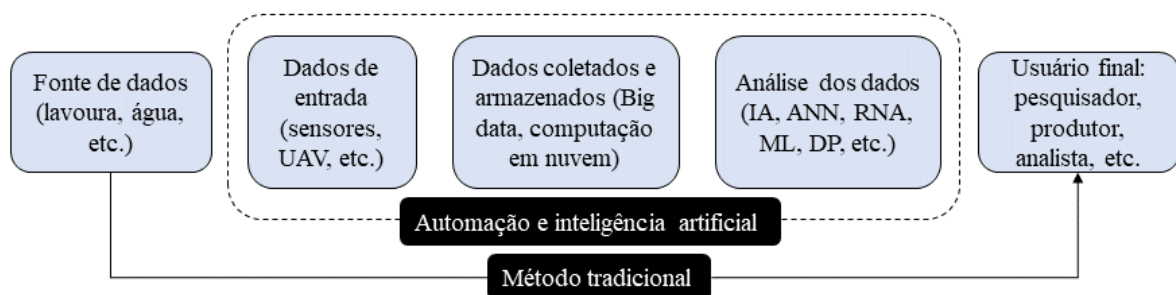
Apesar dos diversos métodos encontrados na IA boa parte dos trabalhos utilizam as redes neurais artificiais para resolução dos problemas. Ao longo do tempo, com o avanço das pesquisas na área da inteligência computacional, foram desenvolvidas diversas redes que contém características importantes na resolução de diferentes problemas impostos. Dentre essas redes, duas são alvos de bastante uso e estudo dentro do setor agrícola, a *Radial Basis Function* (RBF) e a rede *Multilayer perceptron* (MLP).

A análise de dados utilizando algoritmos de redes neurais artificiais vem ganhando força nos últimos anos, principalmente, por investigar mais a fundo o comportamento dos dados. A investigação ocorre a partir do uso de modelos complexos, passando por etapas decisivas, até chegar no resultado ideal, fugindo das análises tradicionais (Figura 2). A análise rápida dos dados, tomada de decisão rápida e os processos automatizados, além da alta acurácia e precisão, começaram a ganhar espaço dentro do setor agrícola, excepcionalmente quando utilizada a agricultura digital (SOOD; KUMAR; KUMAR, 2021).

Não mais distante, a cultura do amendoim é uma cultura que vem ganhando espaço em comparação às outras *commodities* dentro do cenário brasileiro. As tecnologias relacionadas para avaliação da maturação, produção e acompanhamento do crescimento das plantas, estão cada vez mais ganhando força e demonstrando seu potencial (SANTOS et al., 2021a; SANTOS et al., 2021b; ZOU et al., 2019).

Exclusivamente no amendoim, como relatado, a predição da maturação dispõe de ferramentas manuais, dependentes do conhecimento técnico da pessoa. Tal fato torna o método subjetivo, oneroso e capaz de não captar a variabilidade. Por outro lado, quando relacionado com a inteligência artificial (IA) respostas mais precisas são observadas, auxiliando na tomada de decisão nas lavouras.

Figura 2 - Fluxograma da avaliação dos dados em inteligência artificial.



Fonte: Adaptado de Sood et al. 2021.


Redes neurais artificiais são empregadas em diversas áreas de interesse humano, como por exemplo, na economia, no meio acadêmico, engenharia, setor de petróleo, indústrias e entre outras. Essas redes, são complexas e conseguem reconhecer padrões o que dificilmente seria captado por outros métodos tradicionais de análise de dados (ABIODUN et al., 2019).

A inspiração para criação das redes foi o neurônio biológico e sua capacidade de aprendizado. Dessa forma, o primeiro modelo artificial de um neurônio foi desenvolvido em 1943 por Warren McCulloch e Walter Pitts, porém com diversas adaptações e funções para ter o comportamento similar ao neurônio biológico (BRAGA et al., 2007).

Sendo assim, a base para a criação foi o neurônio biológico, visto que o mesmo, possui de maneira geral, os dendritos por onde recebem os sinais, o axônio por onde passará os impulsos gerados e o corpo celular. Além disso, nas regiões onde o axônio de um neurônio se comunica com o dendrito de outro formam as sinapses, responsável pela união e funcionalidade das redes (BRAGA et al., 2007).

O neurônio artificial, possui como estruturas os terminais de entrada (dendritos) recebendo os valores de  $X_1, X_2, \dots, X_n$ , e para simular as sinapses os pesos,  $W_1, W_2, \dots, W_n$ , são ajustados de acordo com os valores de entradas ( $X_n$ ). Os valores dos pesos podem ser positivos ou negativos dependendo das sinapses anteriores. Ao final denominado axônio no neurônio biológico e terminal de saída ( $Y$ ) no neurônio artificial temos os valores preditos. Portanto, o disparo vai ocorrer por meio da multiplicação dos valores de  $X_n W_n$ , passando pela junção aditiva que realiza a soma de  $X_n W_n$  dos neurônios (Figura 3) que ativa ou não a saída a depender da soma ponderada das entradas (BRAGA et al., 2007).

Figura 3 - Modelo do primeiro neurônio artificial.



Fonte: Adaptado de Braga et al. (2007).

A partir do primeiro neurônio artificial desenvolvido, intensificaram-se as pesquisas na área de inteligência computacional explorando ainda mais o ramo das redes neurais artificiais. Dento dessas áreas, as desde do tipo RBF e MLP receberam boa parte dos estudos impulsionando ainda mais o desenvolvimento. Um dos grandes feitos que trouxe à tona a

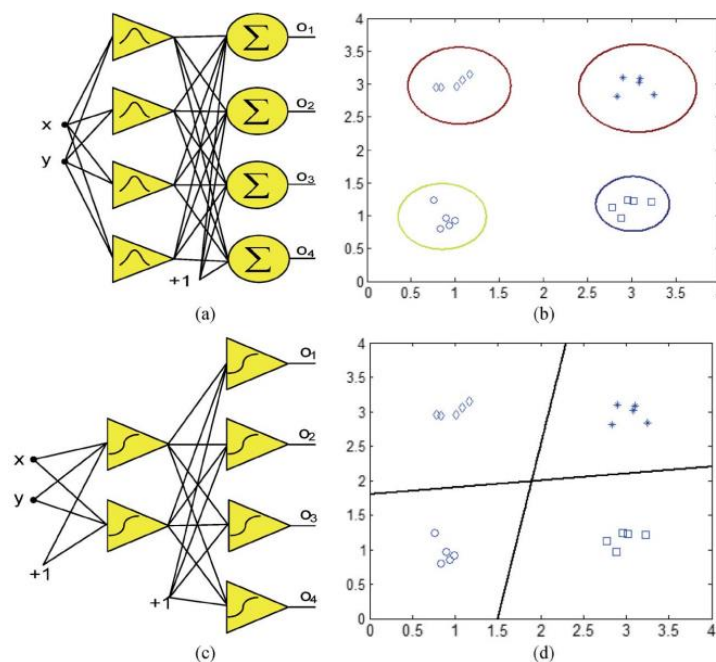


utilização dessas redes foi a partir do desenvolvimento do método de treinamento *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986).

Com o decorrer dos anos, novos métodos de treinamento foram desenvolvidos que em alguns casos apresentando resultados superiores ao encontrado com o *backpropagation*. Sendo assim, além do tipo de algoritmo utilizado para o treinamento é possível diferenciar as redes a partir de suas arquiteturas. Como é o caso das redes do tipo RBF que apresentam arquiteturas mais simples que as redes MLP (Figura 4). Outro ponto é o forma como é dado a saída dos resultados, as redes RBF atuam como redes de aproximação local e a saída é determinada por unidades ocultas específicas, já as redes MLP trabalham globalmente e a saída é formada a partir de todos os neurônios (YU et al., 2011).

As RBF possuem três tipos de funções matemáticas que podem ser aplicadas na função de ativação dos neurônios. No entanto, de maneira geral o modelo gaussiano é o mais utilizado (GHORBANI et al., 2016). Já as redes do tipo MLP são as mais populares na resolução de problemas, formada de uma camada de entrada, oculta e uma camada de saída, com possibilidade de uso de diferentes funções de ativação dependendo do problema que se deseja resolver (KASHANINEJAD; DEHBHANI; KASHIRI, 2009).

Figura 4 - Comparação entre as redes RBF (a) sua divisão em hiperelipsóides (b); rede MLP (c) e sua divisão em hiperplanos (d).



Fonte: Yu et al. (2011).

Portanto, a aplicabilidade das redes são inúmeras dentro da agricultura, podendo ser utilizadas desde o processo de produção de sementes testando diferentes temperaturas na embebição de sementes de trigo (KASHANINEJAD; DEHBHANI; KASHIRI, 2009), na predição de variáveis climáticas, tais como velocidade do vento (GHORBANI et al., 2013) e modelo de referência para evapotranspiração (FENG et al., 2017). Além disso, as redes tem sido largamente utilizada na estimativa de biomassa e produtividade de culturas anuais e perenes (ALI et al., 2017; KAMIR; WALDNER; HOCHMAN, 2020).

## **2.4 Sensoriamento remoto**

Além do uso da IA para análise dos dados, outro ponto de grande relevância refere-se ao sensoriamento remoto. Tal ferramenta, é dita como ciência ou arte de obter informações sobre alguma área, fenômeno ou objeto por meio de um sistema sensor que não realiza o contato físico com o alvo (MOLIN; AMARAL; COLAÇO, 2015).

Tal sistema sensor nada mais é do que um satélite que são capazes de captar a radiação eletromagnética refletida pelas plantas. Ou seja, após a chega da radiação solar na planta a mesma será refletida, absorvida e transmitida, sendo que a refletiva é a principal forma captada pelos satélites. Após captar essa radiação, as imagens são enviados a uma base que realiza a correção das imagens de satélite, visto que na atmosfera a presença de nuvens, gases, poeiras e gotículas de água, interferem na qualidade das imagens (MOLIN; AMARAL; COLAÇO, 2015).

Além dos satélites em outras plataformas, como as suborbitais e terrestres podem ser utilizados sensores que são capazes de captar a radiação eletromagnética refletida pelas plantas, como é o caso dos drones, aviões, etc. (suborbitais) e dos sensores embarcados em máquinas agrícolas como weedseeker, e também aqueles que podem ser utilizados de forma manual, como o greenseker, clorofilometro, etc.. Os UAV estão sendo alvo de grandes trabalhos principalmente na estimativa de diversos parâmetros nas plantas cultivadas, como por exemplo no conteúdo de clorofila, deficiência nutricional e na estimativa de produtividade (QIAO et al. 2022; SHARIFI et al. 2020).

Dito isso, no sensoriamento remoto uma das técnicas muito utilizadas na agricultura é o cálculo de índices de vegetação, que utilizam os dados de reflectância espectral da radiação eletromagnética do objeto para realizar o monitoramento e a distribuição da vegetação (LIU, 2015).

Tais índices, são definidos como fórmulas matemáticas obtidos a partir da combinação das bandas espectrais captadas pelos sensores. Na grande maioria dos casos as bandas do infravermelho próximo e do vermelho são as mais utilizadas, pois estão relacionadas com os pigmentos foliares e ao conteúdo interno de água nas células do mesófilo (FORMAGGIO e SANCHES 2017). Sendo assim é possível realizar o monitoramento ao longo do ciclo da cultura e captar as variações causadas pelos estresses abióticos e bióticos.

Dessa forma, os índices de vegetação começaram a ganhar espaço dentro do cenário agrícola permitindo que ocorra o monitoramento da variabilidade nas lavouras. No entanto além de possibilitar encontrar eventuais problemas devido ao monitoramento na área apenas utilizando os índices de vegetação, para a correta tomada de decisão é importante que o técnico realize a análise a campo.

Na literatura é possível encontrar diversos índices de vegetação que podem ser aplicados nas áreas de produção agrícola e na análise dos diferentes manejos adotados. No entanto para a escolha do índice de vegetação correta é importante ter em mente qual a finalidade da análise (CARNEIRO et al., 2019). Dito isso, alguns índices de vegetação apresentam melhor relação para avaliar a biomassa das plantas, outros para análise do estresse hídrico, como também para análise do conteúdo de clorofila (SHISODIA; RAY; SINGH, 2020).

Na cultura do amendoim já é relatado o uso de sensores orbitais (satélites) e sub orbitais (drones ou UAV) com os índices de vegetação e algoritmos de aprendizado de máquina na estimativa da maturação da cultura (SANTOS et al., 2021a). Em outras culturas como a batata doce são encontrados estudos que demonstram o potencial do sensoriamento remoto e dos UAV associados a inteligência artificial em mapear a variabilidade e definir a melhor época de colheita (TEDESCO et al., 2021a, TEDESCO et al. 2021b ).

Portanto utilizar as ferramentas gratuitas como as imagens de satélites disponibilizadas por alguns órgãos e calcular os índices de vegetação a partir da combinação das bandas dos sensores são passos importantes para início das análises e auxílio na tomada de decisão. Do ponto de vista acadêmico, utilizar essas ferramentas gratuitas são formas de potencializar e disseminar a importância que possuem, além de trazer informações espectrais como a identificação em tempo real da variabilidade espacial e a detecção de possíveis problemas nas lavouras.

Para o êxito da ferramenta, neste caso o sensoriamento remoto, na análise do monitoramento agrícola se faz necessário que cada vez mais estudos sejam realizados. Por sua vez, os estudos devem realizar a integração de diversos parâmetros e métodos de avaliação,

como os citados anteriormente. A união dessas ferramentas possibilita a análise mais profunda e a tomada de decisão mais assertiva.

## **2.5 Plataforma orbital de monitoramento climático**

A agricultura é a grande responsável por produzir fibra, alimento entre outras coisas que são importantes para a sobrevivência humana. No entanto, para que toda essa produção ocorra é imprescindível que as condições climáticas sejam adequadas para atingir altas produtividades. O clima afeta as condições do solo, a incidência de pragas e doenças, no meio ambiente terrestre como no aquático, devendo se atentar com as alterações que o mesmo está sofrendo (PRAVEEN; SHARMA, 2019).

As mudanças climáticas e sua influência nos ecossistemas estão se tornando cada vez mais alvos de estudos. A grande parte das mudanças são causadas pelos gases do efeito estufa emitidos na atmosfera terrestre e impactando diretamente as condições climáticas do planeta. Diversos órgãos mundiais e regiões apresentam campanhas de incentivo a diminuição da emissão de gases causadores do efeito estufa como dióxidos de carbono e metano (PRAVEEN; SHARMA, 20219).

Uma das soluções encontradas para começar a avaliar os efeitos causados nas mudanças climáticas foi o desenvolvimento de plataformas que realizam a análise global de parâmetros como temperatura, precipitação, radiação solar, umidade relativa, pressão de superfície, etc. Visto que, boa parte dos países não dispõem de estações meteorológicas suficientes para cobrir todo o território e em alguns casos as estações estão concentradas em uma região, como é o caso do Brasil.

No Brasil, o órgão responsável por realizar a análise das condições climáticas do país é o Instituto Nacional de Meteorologia (INMET). O INMET é responsável por mais de 700 estações meteorológicas cobrindo boa parte do território nacional e possuindo um banco de dados climáticos a partir de 1961 (INMET, 2023).

Outro programa que merece destaque aplicado a análises climatológicas foi o desenvolvido pela NASA (*National Aeronautics and Space Administration*). O programa possui cinco satélites que captam informações climáticas a respeito da Terra. A partir disso, a plataforma NASA POWER (*Prediction of Worldwide Energy Resources*) (<https://power.larc.nasa.gov/data-access-viewer/>) foi desenvolvida com o intuito de fornecer os dados gratuitamente, baseada em três objetivos: desenvolvimento de energias renováveis, construção de energia eficiente e sustentável e aplicações agroclimatológicas (NASA, 2020).

O programa POWER, teve sua abrangência a partir do desdobramento do programa *Surface Meteorology and Solar Energy* (SSE), que estava focado em fornecer dados facilmente para a indústria de energia renovável afim de realizar o monitoramento climático. A partir disso, o programa POWER começou a ser criado e mais duas áreas foram inseridas, o das indústrias arquitetônicas e a área da agricultura com o emprego do setor de agroclimatologia (STACKHOUSE, 2020).

A coleta das informações ocorre por meio do próprio site do programa e pode ocorrer em qualquer local no globo terrestre. Além disso, as informações climatológicas são divididas em grades regulares com dimensões de  $1^\circ \times 1^\circ$  de latitude/longitude para fontes de dados de radiação solar primária e dados meteorológicos (temperatura, umidade relativa, precipitação, pressão de superfície e velocidade do vento) em grades regulares  $\frac{1}{2}^\circ \times \frac{5}{8}^\circ$  de latitude/longitude (STACKHOUSE, 2020).

A estimativa da temperatura do ar, ocorre mediante ao uso do modelo *Goddard Earth Observing System Global* versão 4 (GEOS - 4), com intervalo de análise de 3 horas. Por outro lado, os dados de radiação solar são obtidos por meio do uso NASA *International Satellite Cloud Climatology Project* (ISCCP) (BAI et al., 2010). Para o funcionamento preciso desse sistema, demais satélite meteorológicos estão ligados principalmente para informar valores para a correção atmosférica devido a presença de nuvens, poeiras e gases.

Plataformas orbitais que fornecem informações climatológicas a respeito do globo terrestre são importantes ferramentas para serem aplicadas na agricultura. A dificuldade de encontrar estações meteorológicas próximas pode ser suprida por meio do uso de dados meteorológicos em grid como é a casa da plataforma NASA POWER. Dessa forma é possível utilizar os dados fornecidos para comparar o desenvolvimento da lavoura e adequar os manejos.

Alguns autores tem demonstrado que já é possível estimar a evapotranspiração das culturas utilizando dados da plataforma NASA POWER (FARMIÑÁN et al. 2021), na estimativa de produtividade de milho e café entre outras culturas (BAI et al. 2010; APARECIDO et al. 2022) e na análise do impacto das mudanças climáticas no surgimento de ferrugem asiática na cultura da soja (JUNIOR FATTORI; SENTELHAS; MARIN, 2022).

No entanto, por mais que os modelos apresentem bons resultados nas estimativas diversos erros na medição podem ser encontrados. Como é o caso da precipitação e velocidade do vento, ambos apresentam falhas quando são correlacionados com dados de estação meteorológica fixa. Por outro lado, a plataforma NASA POWER apresenta bons ajustes quando trabalhos com os as variáveis climáticas de temperatura máxima e mínima, umidade relativa e radiação solar (DUARTE; SENTELHAS, 2020; RODRIGUES; BRAGA, 2021).

O uso dos dados de plataforma orbital é uma oportunidade interessante quando deseja-se aplicar na agricultura, são de livre acesso e podem ser aplicados em diversas áreas. Na cultura do amendoim, não são encontrados trabalhos na literatura relacionando a coleta de dados climáticos a partir de plataformas orbitais e de livre acesso com a maturação das vagens de amendoim, uma vez que isso é possível, visto que a cultura responde bem ao acúmulo de graus dias que indiretamente utiliza os valores de temperatura máxima e mínima na sua fórmula para o cálculo e podem ser obtidos por meio dessas plataformas orbitais como o NASA-POWER.

### 3 REFERÊNCIAS

- ABIODUN, O. I. *et al.* Comprehensive review of artificial neural networks applications to pattern recognition. **IEEE**, v. 7, 2019. Doi: 10.1109/ACCESS.2019.2945545
- ALI, I.; CAWKELL, F.; DWYER, E.; GREEN, S. Modeling managed grassland biomass estimation by using multitemporal remote sensing data – a machine learning approach. **IEEE Journal of selected topics in applied Earth observations and remote sensing**, University College Cork, Ireland, 2017. DOI: <http://dx.doi.org/10.1109/JSTARS.2016.2561618>
- APARECIDO, L. E. O. *et al.* Predicting coffee yield based on agroclimatic data and machine learning. **Theoretical and Applied Climatology**, v. 148, p. 899 – 914, 2022. Doi: <https://doi.org/10.1007/s00704-022-03983-z>
- BAGNALL, D. J.; KING, R. W. Response of peanut (*Arachis hypogaea*) to temperature, photoperiod and irradiance 1. Effect on flowering. **Field Crops Research**, v. 26, p. 263 – 277. Doi: [https://doi.org/10.1016/0378-4290\(91\)90004-F](https://doi.org/10.1016/0378-4290(91)90004-F)
- BAI, J. *et al.* Evaluation of nasa satellite- and model-derived weather data for simulation of maize yield potential in china. **Agroclimatology**, v. 102, issue I, 2010. Doi: 10.2134/agronj2009.0085
- BERTIOLI, D. J. *et al.* An overview of peanut and its wild relatives. **Plant Genetic Resources: Characterization and Utilization**, v. 9, n. 1, p. 134 – 149. Doi: 10.1017/S1479262110000444
- BOOTE, K. J. Growth Stages of Peanut (*Arachis hypogaea* L.). **Peanut Science**, v. 9, p. 35–40, 1982. Doi: <https://doi.org/10.3146/i0095-3679-9-1-11>
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. Redes neurais artificiais teoria e aplicações. **LTC**, 2º edição, 2007.
- CARNEIRO, F. M. *et al.* Correlations among vegetation indices and peanut traits during different crop development stages. **Engenharia Agrícola**, v. 39, n. especial, p. 33 - 40, 2019. Doi: <https://doi.org/10.1590/1809-4430-Eng.Agric.v39nep33-40/2019>
- CAVICHOLI, F. A. *et al.* Precision Agriculture in peanut mechanization View project Technological innovations for precision coffee cultivation. **Científica**, v. 42, p. 211–215, 2014.
- COELHO, A. P.; FARIA, R. T. DE; DALRI, A. B. Ecofisiologia e irrigação do amendoim cultivado na segunda safra. **Brazilian Journal of Applied Technology for Agricultural Science**, v.10, n.2 p.119-126, 2017. Doi: 10.5935/PAeT.V10.N2.13
- DOORENBOS, J.; KASSAM, A. H. Yield response to water. **FAO Irrigation and Drainage**, v. 33, p. 193, Roma 1979. Doi: <http://dx.doi.org/10.1016/B978-0-08-025675-7.50021-2>
- DUARTE, Y. C. N.; SENTELHAS, P. NASA/POWER and daily gridded weather datasets—how good they are for estimating maize yields in brazil?. **Internacional Journal of Biometeorology**, v. 64, p. 319 – 329, 2020. Doi: <https://doi.org/10.1007/s00484-019-01810-1>

- FARMIÑÁN, A. M. G.; DEGANO, M. F.; CARMONA, F.; RODRIGUEZ, P. O. Estimation of actual evapotranspiration using NASA-POWER data and Support Vector Machine. **XIX Workshop on Information Processing and Control (RPIC)**, 2021. Doi: <https://doi.org/10.1109/RPIC53795.2021.9648425>
- FENG, Y.; PENG, Y.; CUI, N.; GONG, D.; ZHANG, K. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. **Computers and Electronics in Agriculture**, v. 136, p. 71 – 78, 2017. Doi: <http://dx.doi.org/10.1016/j.compag.2017.01.027>
- FORMAGGIO, A. R.; SANCHES, I. D. índices espectrais de vegetação x agricultura. *In*: FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São Paulo: editora Oficina de textos, 2017. Cap. 3. p. 95 – 119.
- GHORBANI, M. A.; KHATIBI, R.; HOSSEINI, B.; BILGILLI, M. Relative importance of parameters affecting wind speed prediction using artificial neural networks. **Thero. Appl. Climatol.** 114, p. 107 – 114, 2013. Doi: 10.1007/s00704-012-0821-9
- HAENLEIN, M.; KAPLAN, A. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. **California Management Review, BerkeleyHass**, v. 61, n. 4, p. 5 – 14, 2019. Doi: <https://doi.org/10.1177/0008125619864925>
- INCE, A.; GUZEL, E. Effects of gynophore breaking resistance on losses in mechanized peanut harvesting. **American Society of Agricultural and Biological Engineers**, 2003. Doi: 10.13031/2013.15189
- INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Sobre o INMET. INMET, 2023. Disponível em: <https://portal.inmet.gov.br/sobre>
- JUNIOR FATTORI, I. M.; SENTELHAS, P. C.; MARIN, F. R. Assessing the Impact of Climate Variability on Asian Rust Severity and Soybean Yields in Different Brazilian Mega-Regions. **International Journal of Plant Production**, v. 16, p. 17 – 28, 2022. Doi: <https://doi.org/10.1007/s42106-021-00169-x>
- KAMIR, E.; WALDNER, F.; HOCHMAN, Z. Estimating wheat yields in Australia using climate records, satellite image time series and machine learning methods. **ISPRS Journal of photogrammetry and remote sensing**, 160, p. 124 – 135, 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.11.008>
- KASHANINEJAD, M.; DEGHANI, A. A.; KASHIRI, M. Modeling of wheat soaking using two artificial neural networks (MLP and RBF). **Journal of food engineering**, 91, p. 602 – 607, 2009. Doi: 10.1016/j.jfoodeng.2008.10.012
- KLOMPENBURG, T. V.; KASSAHUN, A.; CATAL, C. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, v. 177, 2020. Doi: <https://doi.org/10.1016/j.compag.2020.105709>
- LI, D. et al. Remote sensing improving potato yield prediction by combining cultivar information and UAV remote sensing data using machine learning. *Remote Sensing*, edição especial, v. 13, p. 1 – 18, 2021. Doi: <https://doi.org/10.3390/rs13163322>



LIU, W. T. H. Índices de vegetação. In: LIU, W. T. H. **Aplicações do sensoriamento remoto**. São Paulo, 2015: editora Oficina de textos. Ed. 2. Cap. 7

MANSUR, R. J. et al. Comportamento fisiológico de duas cultivares de amendoim submetidas a diferentes regimes hídricos. **Pesquisa agropecuária brasileira**, v. 33, n. 12, p. 1963–1963, 1998. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/AI-SEDE/4286/1/pab323-96.pdf>

MINGOTTE, F.; MOREIRA, O. F.; LEMOS, L. B. Amendoim: origem, classificação e produção. In: Avanços na produção de amendoim. SILVA, R. P.; SANTOS, A. F.; CARREGA, W. C. Capítulo 1. **FUNEP**, Jaboticabal, 2019.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. Sensoriamento e sensores. In: MOLIN, J.P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de precisão**. São Paulo: editora Oficina de textos, 2019. cap. 5. p. 119 – 131.

National Aeronautics and Space Administration (Nasa). The Prediction of Worldwide Energy Resources (POWER) Project. **Nasa power**, 2020. Disponível em: <https://storymaps.arcgis.com/stories/52116d331ff64e468fe9351fc1c76423>

NETO, J. F.; DA COSTA, C. H. M.; CASTRO, G. S. A. Vista do Ecofisiologia do amendoim. **Scientia Agraria Paranaensis**, v. 11, n. 4, p. 1 – 13, 2012 Disponível em: <<https://saber.unioeste.br/index.php/scientiaagraria/article/view/6033/5748>>.

NOGUEIRA, R.J.M.; TÁVORA, F.J.A.F.; Ecofisiologia do amendoim. In: DOS SANTOS, R.C. O agronegócio do amendoim no Brasil. **Campina Grande: Embrapa Algodão**, 2005. p. 71-122. Disponível em: <https://livimagens.sct.embrapa.br/amostras/00052910.pdf>

Peanut Field Agronomic Resource Manager (PeanuFARM). Overview. Disponível em: <http://peanutfarm.org/overviews>.

PEREIRA, E. S. *et al.* Produtividade e perdas de amendoim em cinco diferentes datas de arranquio. **Revista Ciência Agronômica**, v. 44, n. 4, p. 695-702, out - dez 2013. Doi: <https://doi.org/10.1590/S1806-66902013000400005>

PEZZOPANE, J. R. M. Amendoim. In: Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola, MONTEIRO, J. E. B. A. **Embrapa Pecuária Sudeste**, INMET, 2009. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/576953>

PILON, C.; MONFORT, W. S.; GREY, T. L. Physiology of peanut seed maturation and factors affecting vigor of seeds and seedling. In: Avanços na produção de amendoim. SILVA, R. P.; SANTOS, A. F.; CARREGA, W. C. Capítulo 3. **FUNEP**, Jaboticabal, 2019.

PORTER, W. M. Water use and relationships in peanut production. In: Peanut production guide, capítulo 10. **UGA**, extension, p. 1 – 179, 2022. Disponível em: [https://secure.caes.uga.edu/extension/publications/files/pdf/B%201146\\_2.PDF](https://secure.caes.uga.edu/extension/publications/files/pdf/B%201146_2.PDF)

PRAVEEN, B.; SHARMA, P. A review of literature on climate change and its impacts on agriculture productivity. **Journal of Public Affairs an international journal**, v. 19, n. 4, 2019. Doi: <https://doi.org/10.1002/pa.1960>

- QIAO, L. *et al.* UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages. *Computers and Electronics in Agriculture*, v. 196, 2022. Doi: <https://doi.org/10.1016/j.compag.2022.106775>
- RODRIGUES, G. C.; BRAGA, R. P. Evaluation of NASA POWER reanalysis products to estimatedaily weather variables in a hot summer mediterranean climate. *Agronomy MDPI*, v. 11, p. 1 – 17, 2021. Doi: <https://doi.org/10.3390/agronomy11061207>
- ROWLAND, D. L. *et al.* Determination of Maturity and Degree Day Indices and their Success in Predicting Peanut Maturity. *Peanut Science*, p. 125–136, 2006. Doi: [https://doi.org/10.3146/0095-3679\(2006\)33\[125:DOMADD\]2.0.CO;2](https://doi.org/10.3146/0095-3679(2006)33[125:DOMADD]2.0.CO;2)
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 329, n. 9, 1986. Doi: <https://doi.org/10.1038/323533a0>
- SANTOS, A. F. *et al.* High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agriculture*, v. 22, p. 1464–1478, 2021a. Doi: <https://doi.org/10.1007/s11119-021-09791-1>
- SANTOS, A. F. *et al.* Using uav and multispectral images to estimate peanut maturity variability on irrigated and rainfed fields applying linear models and artificial neural networks. *Remote sensing*, v. 14, n. 93, 2021b. Doi: <https://doi.org/10.3390/rs14010093>
- SANTOS, A. F.; SILVA, R. P.; ZERBATO, C.; MENEZES, P. C.; KAZAMA, E. H.; PAIXÃO, C. S. S.; VOLTARELLI, M. A. Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agriculture*, v. 20, p. 840 - 856, 2019. DOI: <https://doi.org/10.1007/s11119-018-9616-z>
- SANTOS, E. P.; SILVA, R. P.; BERTONHA, R. S.; NORONHA, R. H. F.; ZERBATO, C. Produtividade e perdas de amendoim em cinco diferentes datas de arranquio. *Revista Ciência Agrônômica*, v. 44, n. 4, 2013. Doi: <https://doi.org/10.1590/S1806-66902013000400005>
- SHARIFI, A. Remotely sensed vegetation indices for crop nutrition mapping. *Journal of Science Food and Agric.*, v. 100, p. 5191-5196, 2020. Doi: 10.1002/jsfa.10568
- SHARMA, A.; JAIN, A.; GUPTA, P.; CHOWDARY, V. Machine learning applications for precision agriculture: a comprehensive review. *IEEE*, v. 9, 2021. Doi: 10.1109/ACCESS.2020.3048415
- SILVA, R. P Colheita mecanizada do amendoim. In: Avanços na produção de amendoim. SILVA, R. P.; SANTOS, A. F.; CARREGA, W. C. Capítulo 14. **FUNEP**, pag. 129, Jaboticabal, 2019.
- SISHODIA, R. P.; LAY, R. L.; SINGH, S. K. Applications of remote sensing in precision agriculture: a review. *Remote sensing MDPI*, v. 12, 2020. Doi: 10.3390/rs12193136
- SOOD, A.; KUMAR, R. S.; KUMAR, A. S. Artificial intelligence research in agriculture: a review. **Online information review: artificial intelligence in agriculture**, p. 01–22, 2021. DOI: <https://doi.org/10.1108/OIR-10-2020-0448>

SOUZA, J. C. B.; ALMEIDA, S. L. H.; OLIVEIRA, M. F.; SANTOS, A. F.; FILHO, A. L. B.; MENESES, M. D.; SILVA, R. P. Integrating satellite and UAV data to predict peanut maturity upon artificial neural networks. **Agronomy MDPI**, v. 12, p. 1 – 15, 2022. Doi: <https://doi.org/10.3390/agronomy12071512>

STACKHOUSE, P. Metodologia: fonte de dados. **Nasa docs**, 2021. Disponível em: <https://power.larc.nasa.gov/docs/methodology/data/sources/>

STALKER, H. T. Peanut (*Arachis hypogaea* L.). **Field Crops Research**, v. 53, p. 205 – 217, 1997. Doi: [https://doi.org/10.1016/S0378-4290\(97\)00032-4](https://doi.org/10.1016/S0378-4290(97)00032-4)

TEDESCO, D. et al. Predicting on multi-target regression for the yield of sweet potato by the market class of its roots upon vegetation indices. **Computers and Electronics in Agriculture**, v. 191, p. 1 - 8, 2021a. DOI: <https://doi.org/10.1016/j.compag.2021.106544>

TEDESCO, D. et al. Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. **European Journal of Agronomy**, v. 129, p. 1-12, set. 2021b. DOI: <https://doi.org/10.1016/j.eja.2021.126337>

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Peanut explorer. USDA, 2023. Disponível em: <https://ipad.fas.usda.gov/cropexplorer/cropview/commodityView.aspx?cropid=2221000>

VARIATH, M. T.; JANILA, P. Economic and Academic importance of peanut. *The Peanut Genome*, v. 2, p. 7 -26, 2017. Doi: [http://dx.doi.org/10.1007/978-3-319-63935-2\\_2](http://dx.doi.org/10.1007/978-3-319-63935-2_2)

WANI, J. A.; SHARMA, S.; MUZAMIL, M.; AHMED, S.; SHARMA, S.; SINGH, S. Machine learning and deep learning based computational techniques in automatic agricultural diseases detection: methodologies, applications, and challenges. **Archives of Computational Methods in Engineering**, v. 29, p. 647 – 677, 2022. Doi: <https://doi.org/10.1007/s11831-021-09588-5>

WILLIAMS, E. J.; DREXLER, J. S. A Non-Destructive Method for Determining Peanut Pod Maturity. **Peanut Science**, v. 8, n. 2, p. 134–141, 1981. Doi: <https://doi.org/10.3146/i0095-3679-8-2-15>

YU, H.; XIE, T.; PASZCZYŃSKI, S.; WILAMOWSKI, B. M. Advantages of radial basics function networks for dynamic system design. **IEEE Transactions on industrial electronics**, v. 58, n. 12, 2011. Doi: 10.1109/tie.2011.2164773

ZOU, S. et al. Peanut maturity classification using hyperspectral imagery. **Biosystems Engineering**, v. 188, p. 165 – 177, 2019. Doi: <https://doi.org/10.1016/j.biosystemseng.2019.10.019>

## **CAPÍTULO 1 - Comparação entre estações meteorológicas de superfície e dados NASA-POWER na estimativa da maturação de amendoim**

### **RESUMO**

As variações na temperatura podem afetar a qualidade e produtividade do amendoim alterando o tamanho, formato e conteúdo nutricional sendo uma variável que deve ser monitorada. Entretanto, muitos produtores ao redor do mundo não possuem estações meteorológicas próximas do campo. Portanto, o objetivo do trabalho foi verificar a possibilidade de aplicação dos dados NASA-POWER na estimativa da maturação de amendoim e comparar com as estações meteorológicas. Quatro campos localizados no estado da Geórgia, Estados Unidos foram utilizados para avaliação da maturação durante os anos de 2018 e 2019. Cada campo foi dividido em áreas de um hectare totalizando 24 pontos de coleta para Tifton, Dougherty e Coffee e 12 pontos de coleta para Berrien. Em Tifton a maturação foi avaliada aos 115, 122, 129 e 139 dias após a semeadura (DAS), em Dougherty aos 96, 107, 117, 126 e 135 DAS, Coffee aos 96, 104, 109, 116, 128 e 135 e em Berrien aos 103, 109, 117, 124, 131, 145. Todas as análises da maturação foram realizadas utilizando o método Hull-Scrape. As estações meteorológicas de superfície estavam distantes a 14, 9, 10,5 e 8,4 quilômetros dos campos de avaliação da maturação de Blaelock, Grand Canyon, Docia e Magnolia, respectivamente. Tais estações pertencem a Universidade da Geórgia (UGA) e foram fornecidos os dados climáticos dos anos completos de 2018 e 2019 pela própria instituição. As coordenadas geográficas das estações meteorológicas de superfície foram inseridas na plataforma NASA-POWER para realizar o download das variáveis climáticas umidade relativa, velocidade do vento, temperatura máxima, mínima, média e radiação solar. A análise de regressão linear foi realizada entre a plataforma NASA-POWER e as estações meteorológicas, avaliando o coeficiente de determinação ( $R^2$ ), raiz quadrada do erro médio (RMSE) e o índice de Willmott (d), ao final a análise de PCA foi conduzida para avaliação das variáveis climáticas que afetavam a maturação. As variáveis temperatura máxima, mínima, média e radiação solar apresentam os melhores ajuste 0,95, 0,96, 0,91, 0,94 of  $R^2$ , respectivamente. Por outro lado, velocidade do vento e umidade relativa do ar não apresentaram um ajuste satisfatório dos modelos com  $R^2$  de 0,34 e 0,38. Os resultados comparando as duas plataformas demonstram que é possível estimar a maturação por meio dos dados da NASA-POWER, especialmente porque a temperatura foi a variável que mais contribuiu na análise de PCA para a estimativa da maturação de amendoim. Apesar disso, o tamanho das grades de coleta dos dados da plataforma deve ser levado em conta, visto que restrições e interferências podem ocorrer.

**Palavras-chaves:** Estações Meteorológicas. Variáveis Climáticas. *Arachis Hypogaea* L.

## 1 INTRODUÇÃO

O clima é um dos fatores decisivos na produção agrícola, uma vez que grande parte da produção depende das suas condições. Não apenas a água, mas também a temperatura, umidade relativa do ar, radiação solar e velocidade do vento são fatores que podem afetar a produção, à incidência de pragas e doenças, além da macro e microbiota do solo (JEGER, 2022).

Investigar as mudanças climáticas é necessário para se adaptar ao manejo das culturas agrícolas, especialmente aquelas que respondem de forma sensível às variações climáticas no crescimento, desenvolvimento e, conseqüentemente, na qualidade dos grãos e no rendimento (Wei et al., 2022).

Nesse sentido, na cultura do amendoim para que ganhos sejam obtidos com a produção da cultura, realizar o monitoramento climático passou a ser o foco de grande importância. Visto que a produção mundial é distribuída em diversos países, especialmente na China (36%), Índia (13%), Nigéria (9%) e Estados Unidos (5%), sendo que nos Estados Unidos, o estado da Geórgia é responsável por 44% da produção nacional (USDA, 2022).

Diante dessa expressividade na produção de amendoim, os produtores tem utilizado cada vez mais tecnologias que ajudam no monitoramento e tomada de decisão para a produção de amendoim. Nos EUA produtores tem utilizado do sistema PeanutFarm (PeanutFARM) para o acompanhamento do desenvolvimento das plantas de amendoim. Esse sistema consiste no cálculo de acúmulo de graus dias proveniente de estações meteorológicas distribuídas em diversas regiões (PEANUTFARM, 2023).

Apesar da eficiência do sistema, uma rede de estações meteorológicas de superfície é necessária para o fornecimento dos dados climáticos. Uma alternativa é o uso de estações meteorológicas de superfície em rede nacional (DUARTE; SENELHAS, 2020), series obtidas por modelos matemáticos (VOYANT et al., 2012; BENGTSSON et al., 2017), e o uso de plataformas orbitais.

Dentre as principais plataformas orbitais de monitoramento climático destaca-se o NASA-POWER que realiza a coleta de informações em grade de  $1^\circ \times 1^\circ$  de latitude e longitude para fontes de radiação solar e  $\frac{1}{2}^\circ \times \frac{5}{8}^\circ$  para de dados climáticos e consegue realizar o monitoramento climático do globo terrestre por inteiro. Essa ferramenta tem sido aplicada na estimativa de produtividade de milho (DUARTE; SENELHAS, 2020), na estimativa da área foliar e produtividade na cultura da soja (GASO et al., 2023) e no desenvolvimento de modelos para identificação do estresse térmico (PALMERO et al., 2022).

Apesar dos dados em grade serem utilizados em diversas culturas e para diversas finalidades, não se tem relato do uso desses dados na estimativa de maturação das vagens na cultura do amendoim, fator preponderante na determinação da produtividade e qualidade dos grãos. O processo de maturação das vagens de amendoim é dependente da quantidade de graus dias que as plantas acumulam, sendo que altas temperaturas podem acelerar o crescimento e desenvolvimento da cultura, levando a maturação mais rápida, enquanto que baixas temperaturas podem diminuir o crescimento e atrasar a época do arranquio das plantas (ROWLAND et al., 2006; SANTOS et al., 2021).

No entanto, são encontradas limitações com o uso dos dados em grades. A divisão das regiões em grades extensas pode perder a qualidade e riqueza de detalhes. Erros nas medições das variáveis climáticas podem ser encontradas, como no caso da precipitação e velocidade do vento (DUARTE; SENTELHAS, 2020; SANTOS et al., 2021), afetando a qualidade dos dados e tornando a análise errônea. No entanto, trabalhar com ferramentas de coleta de dados orbitais e de livre acesso é uma forma de melhorar o entendimento das mudanças no clima e seus efeitos na produção e maturação da cultura do amendoim, além de eliminar a necessidade de estações meteorológicas próximas as áreas de produção.

A partir disso, estudos devem ser conduzidos com o intuito de investigar a confiabilidade dos dados obtidos por plataformas orbitais. Dessa forma, descrevendo quais variáveis são confiáveis para serem utilizadas na agricultura. Sendo assim, o objetivo do trabalho foi verificar se é possível aplicar os dados NASA-POWER, obtidos remotamente, para estimar a maturação das vagens de amendoim e comparar os dados fornecidos pela NASA-POWER com os obtidos por estações meteorológicas de superfície.

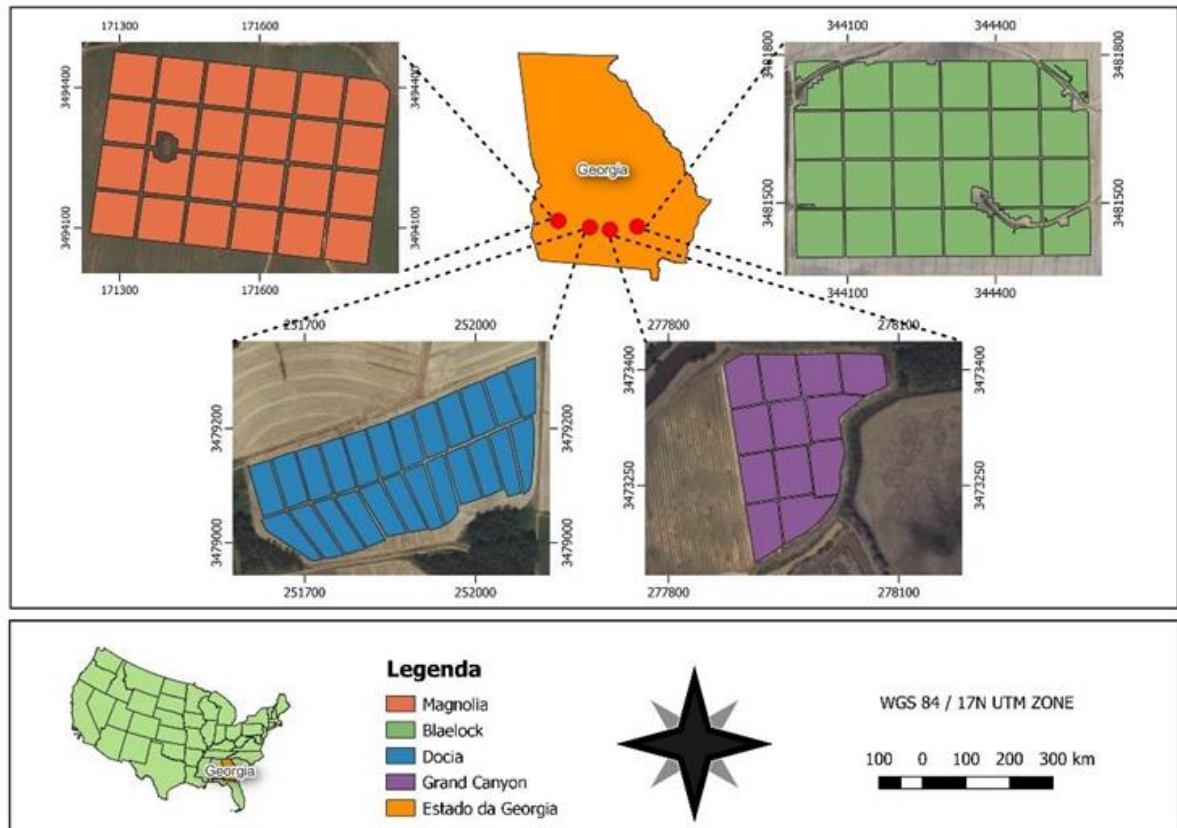
## **2 MATERIAL E METÓDOS**

### **2.1 Local de estudo**

Os campos utilizados para verificar a relação da maturação com dados climáticos, estão localizados no estado da Geórgia – USA. A região é caracterizada com clima subtropical (Cfa) com verões quentes (KOPPEN; GEIGER, 1927). Foram utilizados quatro campos, sendo dois irrigados sobre pivô central irrigado (Magnolia 2018 e Docia 2019) e os outros dois não irrigados (Grand Canyon 2019 e Blaelock 2018) (Figura 1). Em cada área, foram inseridos pontos georreferenciados espaçados a 100 metros cada, totalizando 24 pontos (1 ponto por

hectare) de coleta para maturação na área de Blaelock, Docia e Magnolia, 12 pontos (1 ponto por hectare) de coleta de maturação em Grand Canyon.

Figura 1 - Localização das áreas de produção de amendoim no estado da Geórgia, USA.



Fonte: do autor, 2023.

A cultivar de amendoim semeada nas áreas foi a Georgia-06G, com folhagem verde escura e hábito de crescimento rasteiro (Runner) e intermediário (BRANCH, 2007). O espaçamento adotado foi de 0,90 metros, com ciclo de aproximadamente 140 dias. A semeadura ocorreu no dia 05 de junho de 2018 para Magnolia (Ducker), 09 de maio de 2019 para Docia (Tifton), 11 de junho de 2018 para Blaelock (Coffee) e 27 de abril de 2019 para Grand Canyon (Berrien).

## 2.2 Avaliação das vagens de amendoim

As coletas para a avaliação da maturação são apresentadas na tabela 1. Para cada ponto amostral, em um raio de 2 a 5 metros do ponto georreferenciado, foram coletadas de 8 a 13 plantas, identificadas e ensacadas, que posteriormente foram encaminhadas ao laboratório para retirada das vagens objetivando 200 vagens por ponto amostral.

Tabela 1 - Época de coleta e avaliação da maturação das vagens de amendoim em dias após a semeadura (DAS).

Área	DAS
Blaelock (Coffee)	96, 104, 109, 116, 128, 135
Grand Canyon (Berrien)	103, 109, 117, 124, 131, 138, 145
Docia (Tifton)	115, 122, 129, 139
Magnolia (Ducker)	96, 107, 117, 126, 135

Fonte: do autor, 2023.

Na sequência, as vagens foram lavadas sobre alta pressão retirando o exocarpo e expondo o mesocarpo (ROWLAND et al., 2006) ocorrendo a classificação no quadro de maturação (WILLIAMS; DREXLER, 1991) adotado como padrão para avaliação da maturação. A determinação do índice de maturação do amendoim (PMI), que varia de 0 a 1, ocorreu a partir da soma da coluna marrom e preta, encontradas no quadro de maturação, dividindo pelo total de vagens classificadas, sendo que, valores próximos a 1 indicam a maturação das vagens e próximos de 0 as vagens se encontram distantes da maturação. No entanto, em condições de campo, adota-se o valor de PMI variando de 0,7 até 0,75 afim de minimizar perdas quantitativas e qualitativas (ROWLAND et al., 2006; SANTOS et al., 2022).

### 2.3 Coleta das informações climáticas

As estações meteorológicas localizadas em Berrien (Alapaha) Tifton (Tyty) Coffee (Douglas) Dougherty (Ducker) foram as utilizadas para a coleta dos dados climáticos. Essas estações foram as encontradas mais próximas dos campos de produção descritos na tabela 2.

Tabela 2 - Distância (quilômetros) e altitude (metros) das estações meteorológicas de superfície (EM) dos campos de produção (CP) e avaliação das vagens de amendoim.

EM	CP	Distância (km)	Altitude (m)
Berrien	Grand Canyon	9	82
Tifton	Docia	10,5	113
Coffee	Blaelock	14	68
Dougherty	Magnolia	8,4	62

Fonte: do autor, 2023.

Essas estações próximas dos campos de coleta para avaliação da maturação, foram selecionadas para compor as análises. Dessa forma, foi possível realizar o estudo comparativo



entre as variáveis climáticas previstas pela NASA-POWER e o observado pelas estações meteorológicas de superfície. A Universidade da Geórgia, Campus de Tifton (UGA), forneceu as planilhas com os dados climáticos coletados pelas estações meteorológicas. No entanto, devido ao sistema de coleta da estação, são registrados os dados das variáveis climáticas da tabela 3 a cada 15 minutos. Sendo assim, como a plataforma NASA-POWER disponibiliza apenas dados diários das variáveis climáticas, os dados fornecidos pelas estações meteorológicas de superfície (UGA) foram transformados para uma escala diária por meio do cálculo da média dos valores das variáveis climáticas fornecidas a cada 15 minutos do dia. Dessa forma ambas as estações foram padronizadas em uma escala diária. Além disso, foram fornecidos os dados dos anos completos de 2018 e 2019 das quatro estações meteorológicas, selecionando as variáveis apresentadas na tabela 3.

Tabela 3 - Variáveis climáticas obtidas pelas estações fixas e plataforma NASA-POWER.

Variáveis climáticas	Unidade de medida
Wind speed <sup>1</sup>	m s <sup>-1</sup>
UR <sup>2</sup>	%
Tmax <sup>3</sup>	°C
Tmean <sup>4</sup>	°C
Tmin <sup>5</sup>	°C
SWN <sup>6</sup> (Qg)	MJ m <sup>-2</sup> dia <sup>-1</sup>
PS <sup>7</sup>	kPa

<sup>1</sup> velocidade do vento a 2 metros de altura; <sup>2</sup> umidade relativa do ar a 2 metros de altura; <sup>3</sup> temperatura máxima do ar a 2 metros de altura; <sup>4</sup> temperatura média do ar a 2 metros de altura; <sup>5</sup> temperatura mínima do ar a 2 metros de altura; <sup>6</sup> radiação solar incidente na superfície; <sup>7</sup> pressão de superfície.

Na plataforma NASA-POWER (<https://power.larc.nasa.gov/data-access-viewer/>), foram inseridas as coordenadas geográficas de cada estação meteorológica de superfície, para realização da coleta das informações climáticas descritas na tabela 3. A plataforma fornece as informações diárias de cada variável climática, sendo baixadas as informações no formato .CSV dos anos completos de 2018 e 2019 das quatro estações meteorológicas (Alapaha, Tyty, Douglas e Ducker). A resolução espacial da grade da plataforma é de 1° x 1°, aproximadamente 12347 km<sup>2</sup> para fontes de radiação solar primária, já para os dados meteorológicos em grades regulares a resolução passa a ser de 0,5° x 0,625° de latitude/longitude, aproximadamente 3850 km<sup>2</sup> (MALDONATO; VALERIANO; ROLIM, 2019; STACKHOUSE, 2019).

A estimativa da temperatura do ar, ocorre mediante ao uso do modelo Goddard Earth Observing System Global versão 4 (GEOS - 4), com intervalo de análise de 3 horas. Os dados de radiação solar, são obtidos por meio do uso NASA *International Satellite Cloud Climatology*

*Project* (ISCCP) e a radiação solar de superfície estimada a partir do modelo ISCCP (STACKHOUSE, 2022; BAI et al., 2010).

Com a coleta dos dados climáticos das duas plataformas, foi realizado o comparativo entre as duas formas de coleta (terrestre e orbital), podendo evidenciar se os dados NASA-POWER são fiéis na estimativa de variáveis climáticas e conseqüentemente ser utilizados na estimativa da maturação de amendoim em qualquer lugar do globo terrestre.

#### 2.4 Análise estatística entre as duas plataformas

Os dados climáticos das duas plataformas de coleta foram divididos em um modelo geral, que contabilizou os dois anos (2018 e 2019) de coleta, o qual considerava todas as localizações (Berrien, Coffee, Dougherty e Tifton). E a divisão por localização, sendo Berrien, Coffe, Dougherty e Tifton, que possuíam dois anos (2018 e 2019) de coleta de dados climáticos para cada localização.

Inicialmente, todos os dados foram inseridos na análise exploratória por meio do uso do Box-plot, removendo os valores descritos como outliers por meio do cálculo dos limites (inferior e superior). Na sequência, os dados climáticos foram submetidos a análise de correlação de Pearson ( $P < 0,05$ ) e foram plotados os gráficos (Heat-maps) por meio do uso da plataforma Jupyter com linguagem Python. Após a correlação, para as variáveis climáticas que apresentaram resultados acima de 0,8 de correlação foi realizada a análise de regressão linear. Nessa análise, a variável dependente foram as variáveis climáticas das estações meteorológicas de superfície e a variável independente a variáveis climáticas da plataforma NASA-POWER. A análise exploratória com o uso do box-plot e a análise de regressão linear foram realizadas utilizando o software SAS© JMP pro 14 e os gráficos de regressão criados utilizando o software Excel 2016. A partir disso, para a avaliação das métricas dos modelos, foram utilizados como medida de acurácia a raiz quadrada do erro médio (RMSE) (Equação 1) e como medida de precisão o coeficiente de determinação ( $R^2$ ) (Equação 3).

Além disso, foi realizado o cálculo do índice de concordância de Willmott (1981) (d) descrito na equação 2. O índice de desempenho de Willmott (d) trata-se de uma representação do grau do erro dos modelos, variando de 0,0 até 1,0, sendo que valores próximos de 1,0 indicam uma boa concordância entre os valores observados e preditos (WILLMOTT et al., 1985).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{obs} - y_{est})^2}{n}} \quad (1)$$

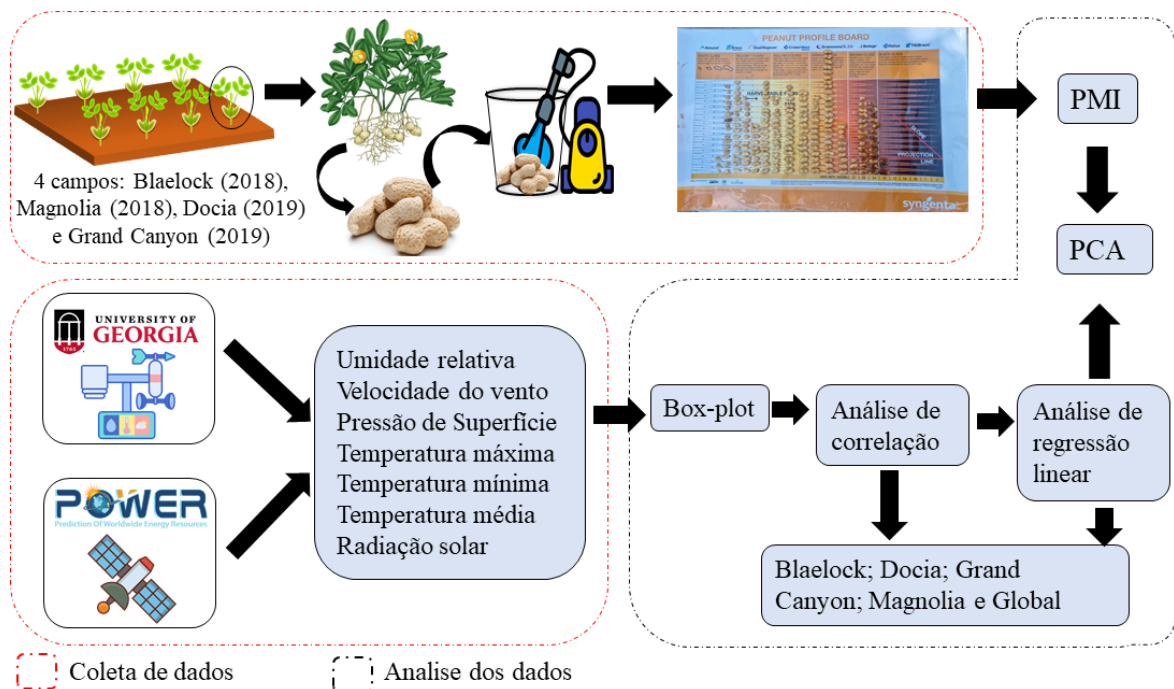
$$d = 1 - \frac{\sum_{i=1}^N (Y_{obs_i} - Y_{est_i})^2}{\sum_{i=1}^N (|Y_{est_i} - \bar{Y}| + |Y_{obs_i} - \bar{Y}|)} \quad (2)$$

$$R^2 = \frac{\sum_{i=1}^N (Y_{est_i} - \bar{Y})^2}{(Y_{obs_i} - \bar{Y})^2} \quad (3)$$

Em que, RMSE é a raiz quadrada do erro médio,  $d$  é o coeficiente de concordância de Willmott e  $R^2$  o coeficiente de determinação.  $y_{obs}$  é o valor observado,  $y_{est}$  é o valor estimado pelo modelo,  $n$  é o número de dados.  $\bar{Y}$  é a valor médio da variável estimada

Após a análise de regressão linear foi possível evidenciar se a plataforma NASA-POWER é precisa e acurada para estimar as variáveis climáticas encontradas na tabela 2. Feito isso, as variáveis foram inseridas na análise de componentes principais (PCA). Sendo assim, o conjunto de dados utilizados foi restringido as épocas de avaliação da maturação nos campos, sendo realizada a PCA para cada campo (Berrien, Dougherty, Tifton e Coffee) e para o modelo global. Ao final, sendo possível observar a relação entre a maturação das vagens de amendoim (PMI) e as variáveis climáticas, podendo selecionar aquelas variáveis que apresentaram os melhores resultados. A PCA foi realizada utilizando o software SAS© JMP pro 14. Nesse sentido, abaixo é apresentado o fluxograma das análises e coletas realizadas.

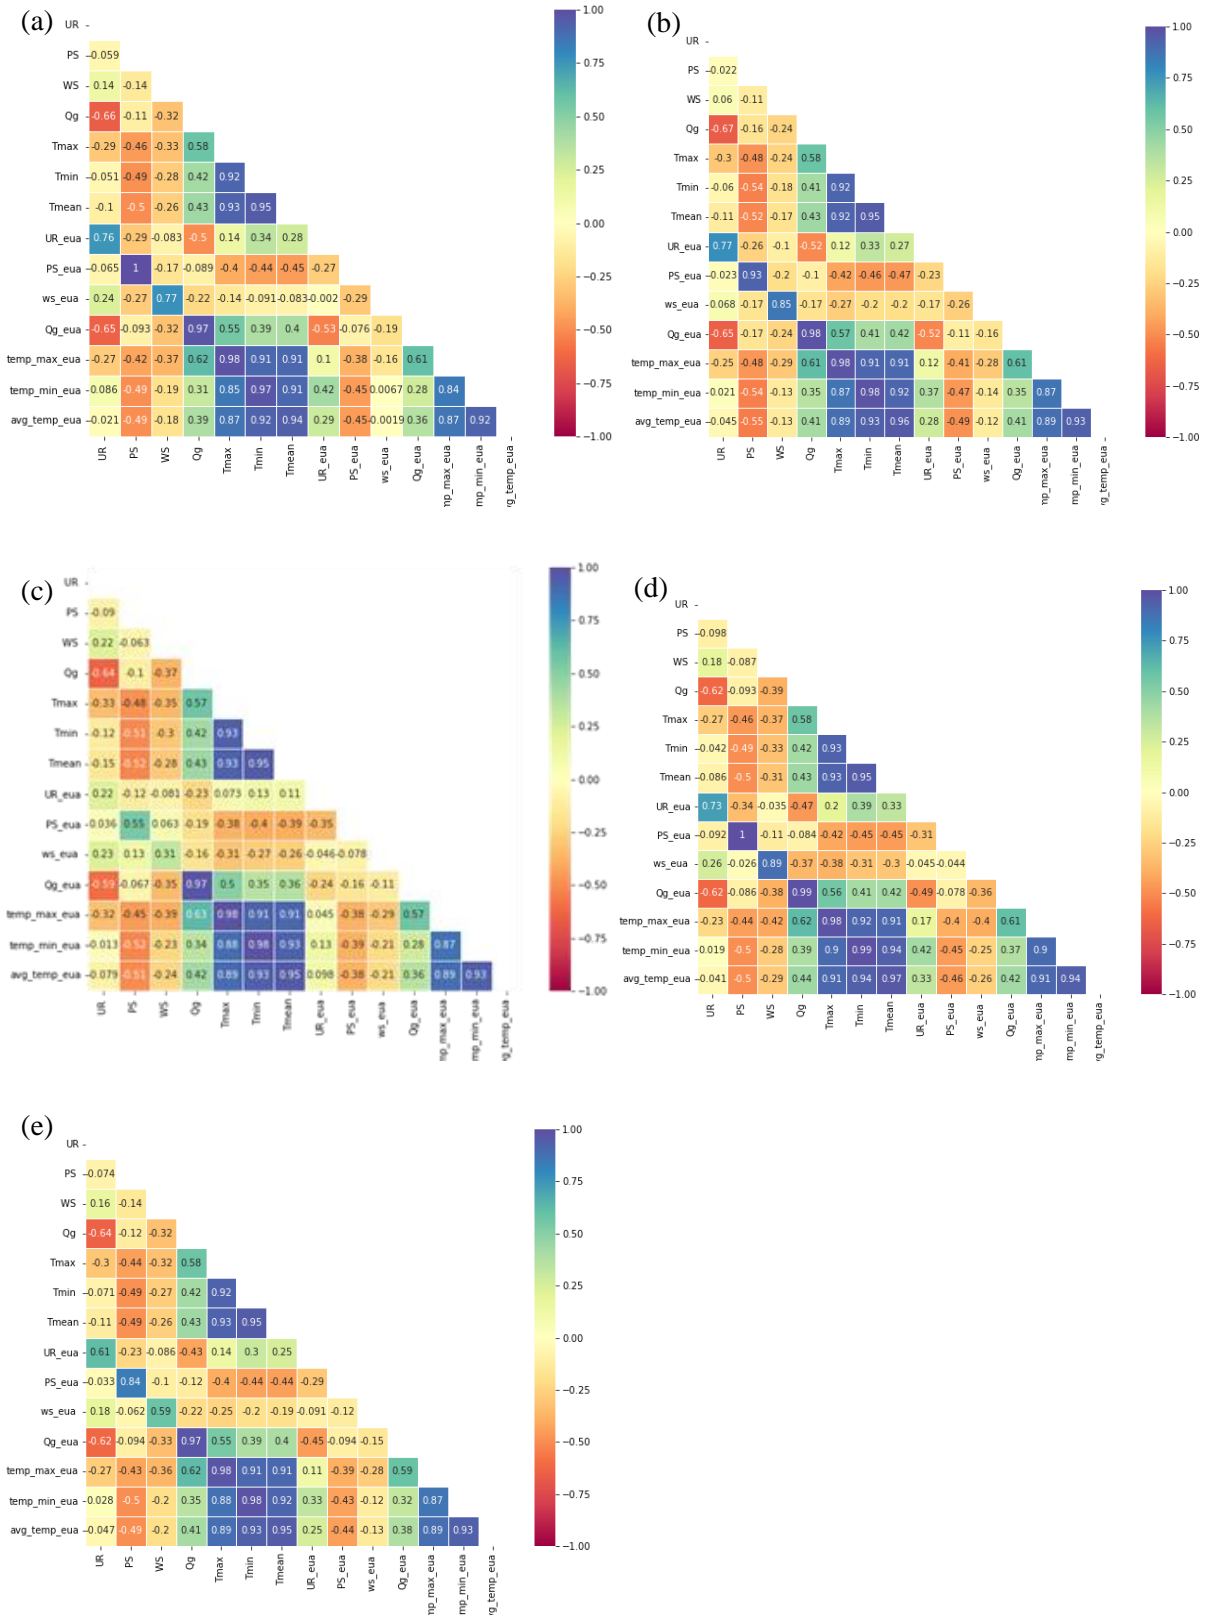
Fluxograma 1 - Etapas de avaliações da maturação e comparação entre a plataforma NASA-POWER e as estações meteorológicas de superfície.



### 3 RESULTADOS E DISCUSSÃO

Os menores valores de correlação entre as plataformas de coleta de dados climáticos foram encontrados para as variáveis velocidade do vento (WS) e umidade relativa (UR), 0,58 e 0,61 respectivamente no modelo global (Figura 2e). Enquanto que para as variáveis pressão de superfície (PS), radiação solar (Qg), temperatura máxima, mínima e média os valores foram maiores que 0,84 no modelo global (Figura 2e). Os baixos valores de correlação das variáveis UR e WS é devido a interferência da sua localização, topografia, mudança no uso da terra, os quais podem causar erros nas medições, quando se utiliza os dados em grid (MALDONATO; VALERIANO; ROLIM, 2019; VALERIANO, 2019). Por outro lado, apesar de ter tido correlação de 0,84, o PS apresentou baixa confiabilidade frente as estações meteorológicas em outros trabalhos (ABOELKHAIR, 2019), que também avaliou a eficiência do NASA-POWER.

Figura 2 - Análise de correlação para a localização de Berrien (a), Coffe (b), Dougherty (c), Tifton (d) e para o modelo geral (e) de dois anos (2018 e 2019) de coleta de dados.



Fonte: do autor, 2023. PS: pressão de superfície; WS: velocidade do vento; UR: umidade relativa; QG: radiação solar; Tmax: temperatura máxima; Tmin: temperatura mínima; Tmean: temperatura média. EUA: estações meteorológicas de superfície.

Quando realizada a análise de correlação por localização, foi observado que em Berrien, Coffe e Tifton (Figura 2a, 2b e 2d) as variáveis UR, WS, PS aumentaram. Dentre essas variáveis, a WS passou de 0,59 na correlação geral (Figura 2e) para 0,85 e 0,89 para Coffe (Figura 2b) e Tifton (Figura 2d), respectivamente. Apesar dos valores de correlação de WS terem melhorado para esses locais, quando analisado individualmente essas variáveis (UR, WS e PS) em Dougherty (Figura 2c) os valores de correlação diminuíram. Enquanto que para temperatura máxima, mínima, média e radiação global todos os locais apresentaram resultados semelhante com o modelo geral.

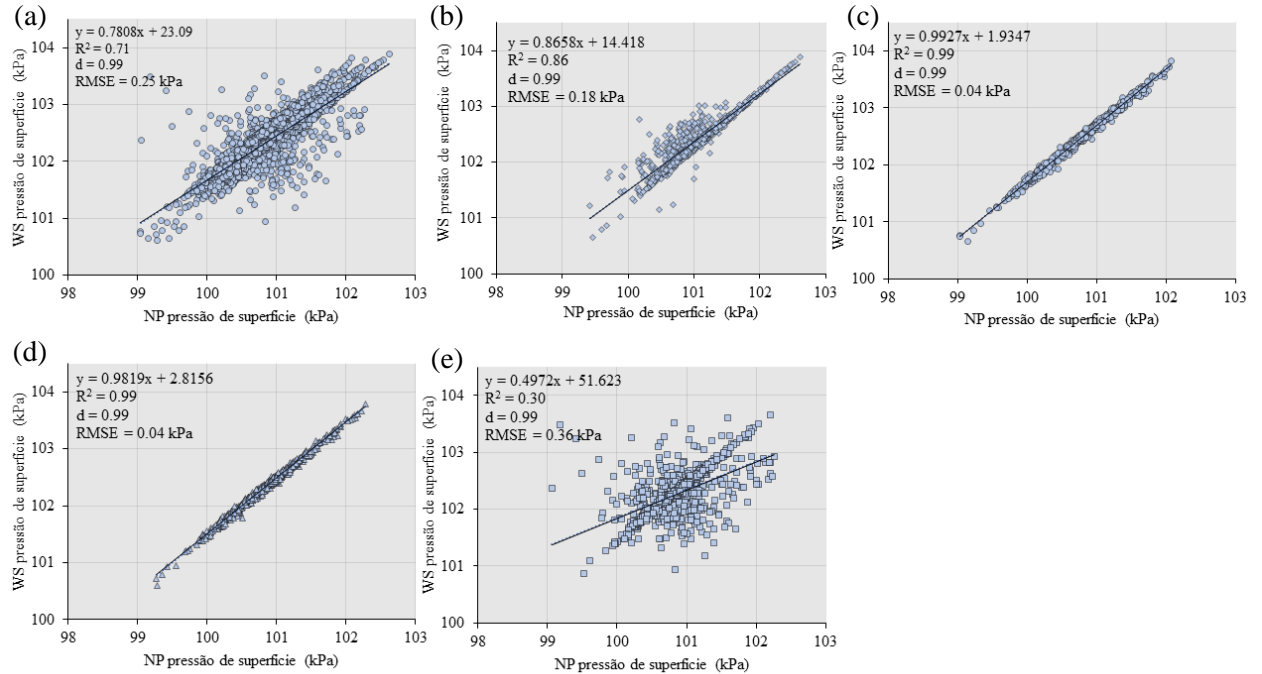
O aumento do coeficiente de correlação pode ser atribuído as condições de localização de cada estação meteorológicas de superfície, visto que na coleta dos dados NASA-POWER não houve sobreposição dos grids. Apesar disso, a topografia é um dos principais fatores que afeta essa relação, com o aumento da elevação maiores são os erros descrito pela plataforma NASA-POWER (JIMÉNEZ et al., 2022; NEGM; JABRO; PROVENZANO, 2017).

Após a avaliação da correlação, as variáveis climáticas foram submetidas a análise de regressão linear, tomando como variável dependente as estações meteorológicas de superfície e a variável independente os dados NASA POWER.

A análise de regressão linear demonstrou que os valores de precisão ( $R^2$ ) para variável pressão de superfície (PS) foram altos para Berrien e Tifton (Figura 3d e 3c) com valores de 0,99 e uma acurácia 0,04 kPa (RMSE) para ambas localidades. Por outro lado, para o modelo geral e em Coffe (Figura 3a e 3b) os valores de RMSE foram de 0,25 e 0,18 kPa e de  $R^2$  0,71 e 0,86 respectivamente. Os resultados para Dougherty (Figura 3e) apresentaram as maiores variações entre as plataformas para a variável PS, o que resultou em baixo  $R^2$  (0,30) e alto RMSE (0,36 kPa). Além disso, o índice de desempenho de Willmott (d) não apresentou variação em nenhuma das análises e localidades para a pressão de superfície.

A pressão de superfície possui relação com o deslocamento da água no solo, favorecendo o processo de absorção de água e nutrientes pelas raízes das plantas. Além disso, a pressão de superfície é um parâmetro relacionado com a topografia do local, sendo que regiões com maiores elevações apresentam menores PS enquanto que regiões com menores elevações são observadas maiores valores de PS (RICHARDSON; NEWMAN, 2018).

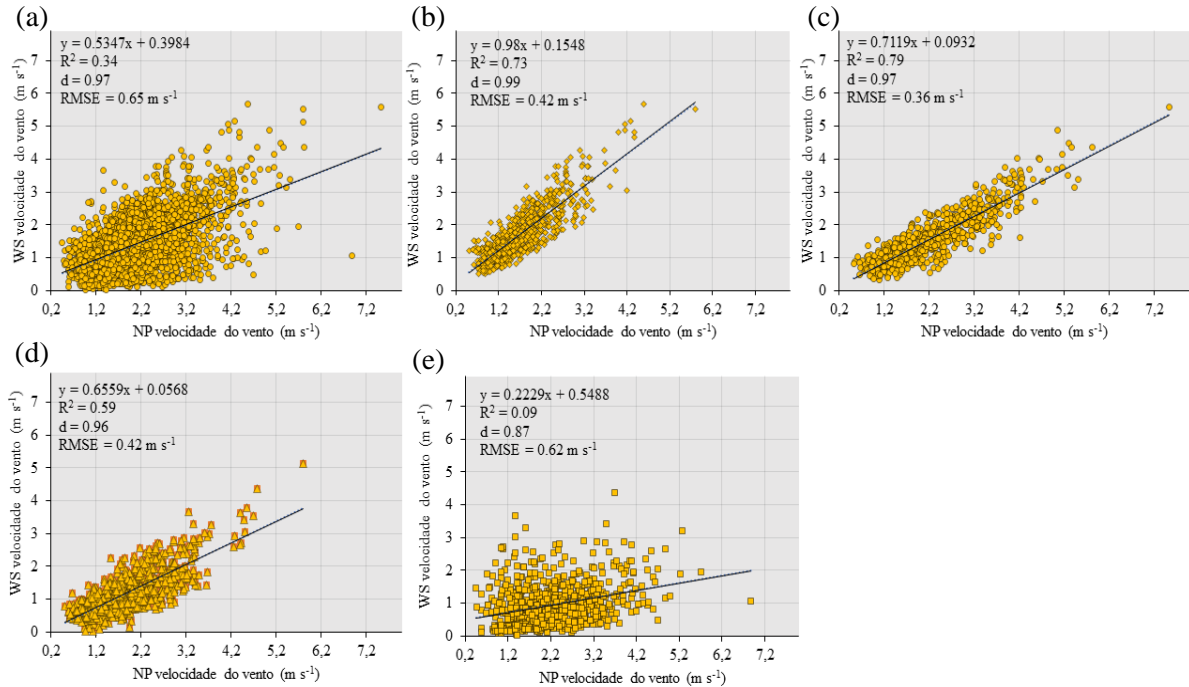
Figure 3 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott ( $d$ ) para pressão de superfície (PS). (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

A variável WS teve as maiores variações nos níveis de acurácia e precisão nas diferentes localidades. Dougherty (Figura 4e) foi a região que apresentou os piores ajustes de  $R^2$  (0,09) e alto RMSE ( $0,62 \text{ m s}^{-1}$ ) seguido do modelo geral (Figura 4a) com valores de  $R^2$  e RMSE de 0,34 e  $0,65 \text{ m s}^{-1}$  respectivamente. Quando houve a divisão por regiões, os modelos de regressão linear de Berrien, Coffe e Tifton (Figura 4d, 4b e 4c) apresentaram um melhor ajuste, observados nos valores de  $R^2$  e RMSE, que variaram de 0,59 até 0,79 e RMSE de 0,36 até 0,42  $\text{m s}^{-1}$ .

Figure 4 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott ( $d$ ) para velocidade do vento. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

Apesar da diferença encontrada entre os valores de  $R^2$  e RMSE, em estudos comparativos entre a Plataforma NASA-POWER e as estações em rede nacional, foram observados valores de  $R^2$  variando de 0,09 até 0,16 e RMSE de 0,93 até 1,82  $m s^{-1}$  (DUARTE; SENTELHAS, 2020), assim como reportado por (JIMÉNEZ et al., 2022) em que observou valores de RMSE variando de 0,92 até 1,63  $m s^{-1}$  e  $R^2$  entre 0,19 até 0,52, valores próximos do observado neste trabalho. Além disso, na grande maioria das localizações, a dispersão dos gráficos apresentados na figura 2, demonstra que as maiores concentrações dos dados está entorno de 1,2 a 3,2  $m s^{-1}$ .

Tais variações na medição do parâmetro de WS estão relacionados a forma como esses dados são coletados. A Plataforma NASA-POWER dispõe de modelos matemáticos, neste caso MERRA-2 (*Modern-era Retrospective Analysis for Research and Applications 2*), que calculam a velocidade e direção do vento e realizam o comparativo com estações meteorológicas da própria NASA, sendo que são constatados valores de RMSE de até 2,47  $m s^{-1}$  (STACKHOUSE, 2022).

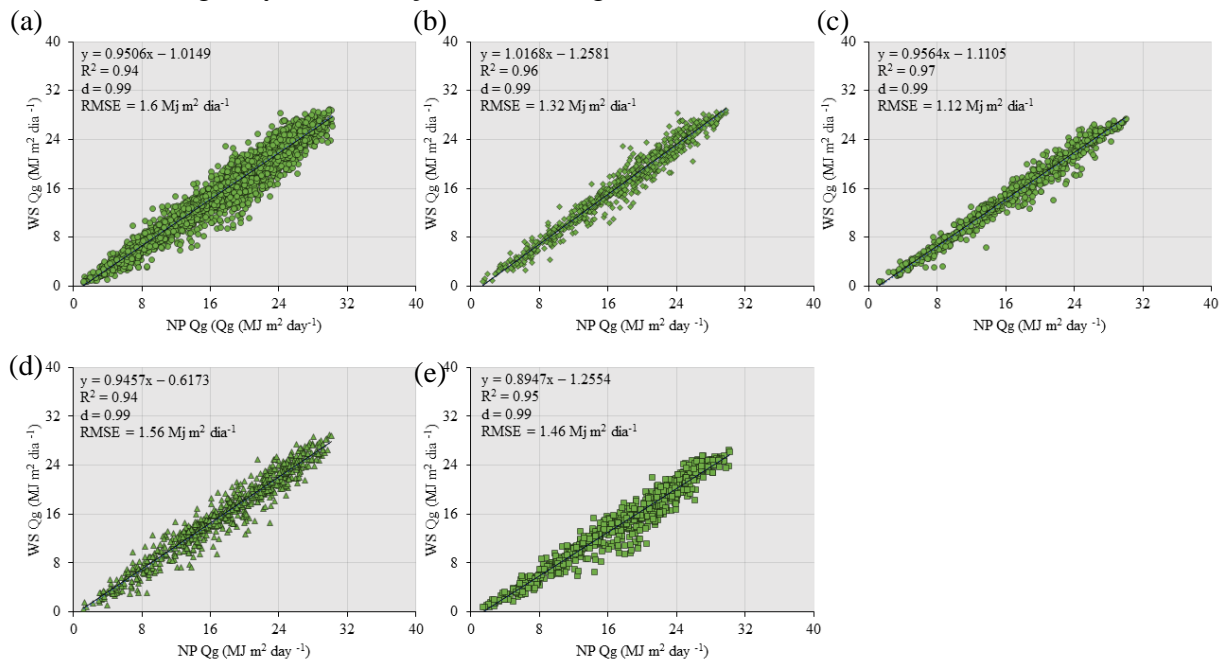
Na agricultura, o vento representa um fator importante do ponto de vista da evapotranspiração das culturas. Na definição da época de semeadura na cultura do amendoim, semeaduras realizadas no meio do mês de maio apresentaram melhores valores de



evapotranspiração que refletiram em um aumento na área foliar (ZHANG et al., 2022). Fato esse, que coincide com a época de maiores valores de velocidade do vento (Anexo), registradas no período da primavera, início da semeadura no estado da Geórgia, USA.

Todos os modelos de radiação solar diária ( $Q_g$ ) apresentaram ajustes acima de 0,94. Os maiores valores de  $R^2$  e menores de RMSE foram observados para o modelo geral e para Berrien (Figura 5a e 5d). Em Tifton foram observados os melhores ajustes para  $Q_g$ , com valores de  $R^2$  0,97 e RMSE de  $1,12 \text{ MJ m}^{-2} \text{ d}^{-1}$  (Figura 5c). A variação nos valores de RMSE foi de  $0,48 \text{ MJ m}^{-2} \text{ d}^{-1}$  entre o maior (Figura 5a) e o menor (Figura 5c) observado, e não houve variações para nenhum modelo nos valores do índice de desempenho de Willmott ( $d = 0,99$ ). Os erros encontrados neste trabalho podem ser considerados baixos, uma vez que os valores de erro para  $Q_g$  estimados a partir NASA POWER variam entre  $2,73$  até  $3,41 \text{ MJ m}^{-2} \text{ d}^{-1}$  (DUARTE; SENTELHAS, 2020; JIMÉNEZ et al., 2022).

Figure 5 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott ( $d$ ) para radiação solar. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

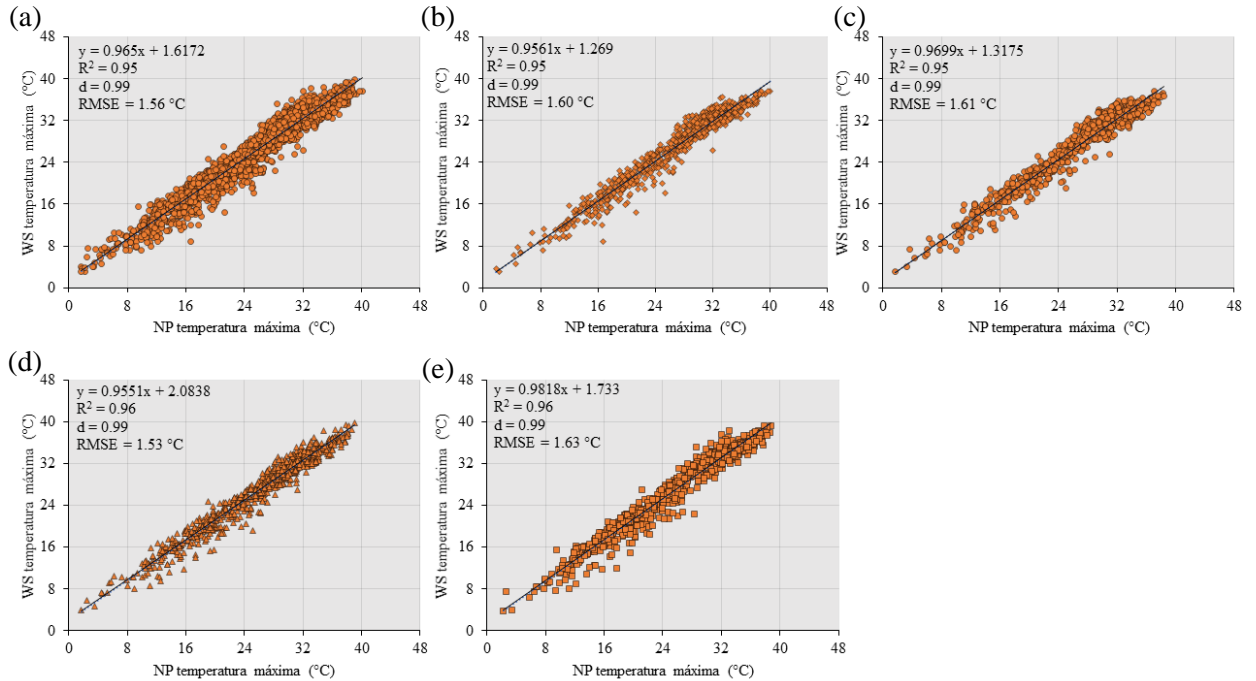
A radiação solar é um parâmetro dependente das condições climáticas e a presença de nuvens dificulta o seu processo de análise levando a erros (DUARTE; SENTELHAS, 2020), diminuindo os valores de acurácia e precisão. No entanto, os modelos apresentaram bons valores de acurácia e precisão, mesmo quando utilizado os dados de todas as áreas dos dois anos (Global) e quando separados por localização, demonstrando a acurácia e precisão da

plataforma em estimar a variável  $Q_g$  em qualquer época do ano. Para o cálculo da radiação solar, o modelo matemático GEWEX (*Global Energy and Water Exchanges*) utilizado pela Plataforma NASA-POWER dispõe de mais satélites que captam informações a respeito da cobertura de nuvens, além de outros satélites para fornecer os dados de temperatura e gases na atmosfera que são informados aos modelos de transferência radiativa para a correção dos efeitos desses constituintes na estimativa da radiação solar (STACKHOUSE, 2022).

Além disso, a  $Q_g$  é um parâmetro dependente da temperatura e que pode influenciar na umidade do ar e do solo. Na primavera e no verão, período que apresentam maiores temperaturas e umidades relativas (Anexo), são registrados os maiores valores de  $Q_g$ , época em que ocorre o cultivo de amendoim no estado da Geórgia, USA. Assim, semeaduras tardias de verão podem retornar em baixas produtividades. O que é observado devido as mudanças nas condições climáticas, principalmente de temperatura e radiação solar. Tais mudanças vão alterar a taxa fotossintética causada pela baixa radiação solar e a baixa temperatura (ZHANG et al., 2022).

Na variável temperatura máxima os valores observados de  $R^2$  variaram entre 0,95 para o modelo geral, Coffe e Tifton (Figura 2a, 2b e 2c) e 0,96 para Berrien e Dougherty (Figura 6d e 6e). Os valores mais baixos de RMSE foram de 1,56 °C para o modelo geral (Figura 6a) e os maiores de 1,63 °C (Figura 6e), com uma variação de 0,07 °C entre o máximo e o mínimo observado. O índice de desempenho de Willmott (d) foi de 0,99 não diferindo entre os modelos de regressão linear

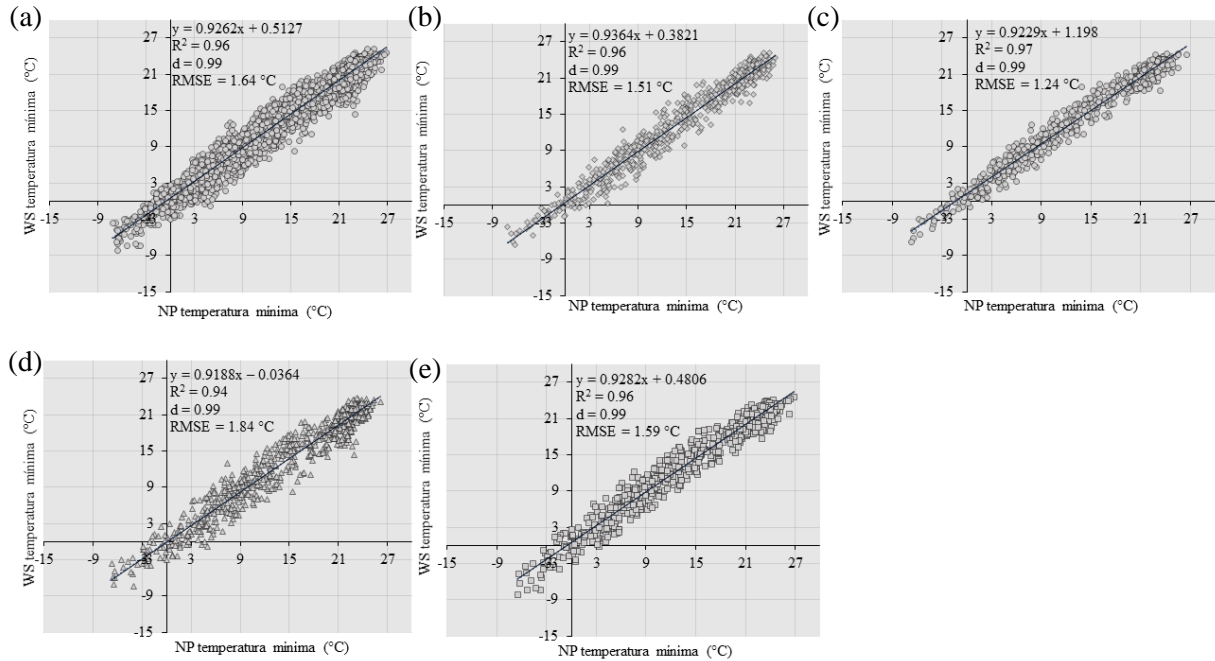
Figure 6 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott (d) para temperatura máxima. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

Ambas plataformas de coletas de dados registraram valores negativos. Apesar disso, foram obtidos bons ajustes dos modelos descritos pelos valores de precisão ( $R^2$ ) de 0,96 para o modelo geral, Coffe e Dougherty (Figura 7a, 7b e 7e), 0,97 para Tifton (Figura 7c) e 0,94 para Berrien (Figura 7d). Em termos de acurácia, Tifton foi a região que apresentou os menores valores 1,24  $^\circ\text{C}$  (RMSE) e Berrien foi a que apresentou os maiores valores 1,84  $^\circ\text{C}$  (Figuras 7c e 7d). Foi observado que para o índice de desempenho de Willmot (d) os valores não variaram (0,99) quando analisado por localidade ou pelo modelo geral.

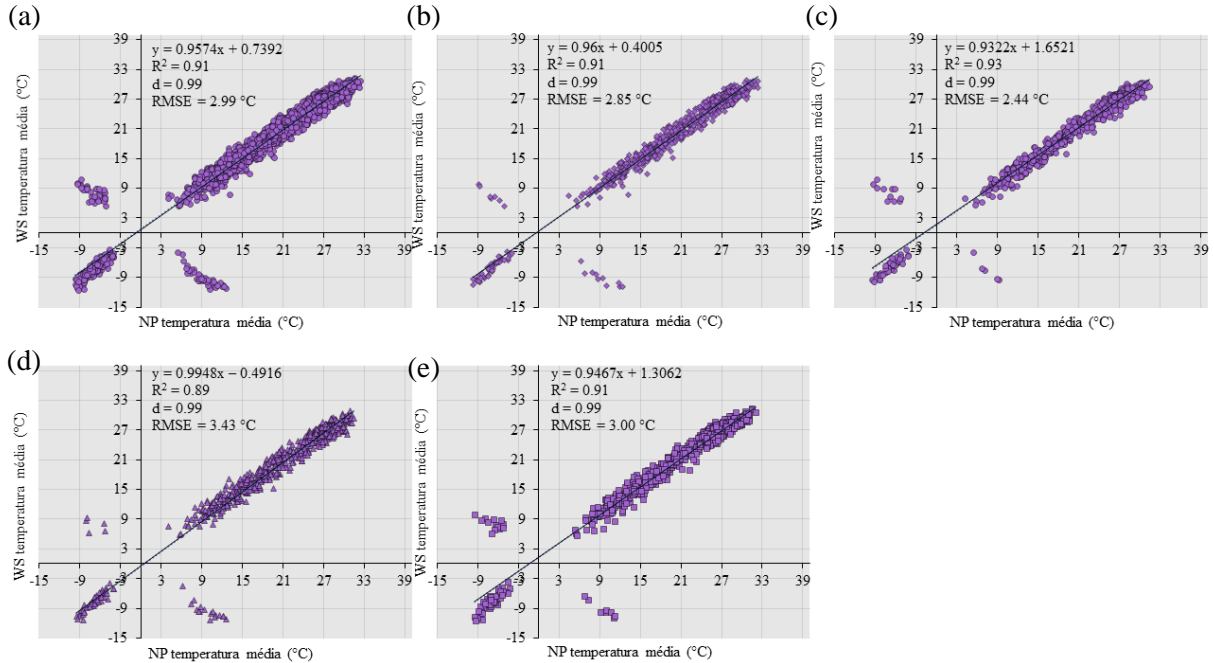
Figure 7 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott (d) para temperatura mínima. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

Na variável temperatura média do ar, foram encontrados os piores ajustes dos modelos de regressão linear. O que pode ser observado pela distribuição dos dados em todas as localizações e no modelo Global. Sendo que no modelo geral, Coffe e Dougherty (Figuras 8a, 8b e 8e) foram observados valores de precisão ( $R^2$ ) de 0,91, enquanto que para Tifton (Figura 8c) foram registrados os maiores valores de  $R^2$  chegando a 0,93 e Berrien (Figura 8d) os menores valores de  $R^2$  com 0,89. Os valores de RMSE variaram entre 2,44  $^\circ\text{C}$  para Tifton (Figura 8c) até 3,43  $^\circ\text{C}$  para Berrien (Figura 8d). O índice de desempenho de Willmott (d) não apresentou variação (0,99) em nenhum dos modelos analisados.

Figure 8 - Análise de regressão linear,  $R^2$ , RMSE e índice de desempenho de Willmott ( $d$ ) para temperatura média. (a) modelo geral; (b) modelo para a região Coffee; (c) modelo para a região de Tifton; (d) modelo para a região de Berrien; (e) modelo para a região de Dougherty. WS: estação meteorológica; NP: NASA-POWER.



Fonte: do autor, 2023.

Na temperatura máxima e mínima do ar foram registradas baixas variações na distribuição dos dados, obtendo ao final um bom ajuste dos modelos de regressão linear. Por outro lado, na temperatura média do ar foi observado uma maior dispersão dos dados entorno da linha de ajuste do modelo de regressão linear. Tal dispersão, pode ser atribuída a forma de coleta de dados das duas plataformas, enquanto uma registrada valores positivos para a mesma data a outra registra valores negativos, afetando o ajuste dos modelos e diminuindo os parâmetros de acurácia (RMSE) e precisão ( $R^2$ ). Esse erro na dispersão ainda é causado pelo cálculo dos modelos da plataforma NASA-POWER. Como os dados são fornecidos em grade ( $0,5^\circ \times 0,625^\circ$ ) pelo modelo MERRA-2, a grande extensão da grade de mais de 50 quilômetros pode levar a erros durante o cálculo, principalmente por ser contabilizado os locais em que as condições climáticas são diferentes das observadas pelas estações meteorológicas próximas dos campos. Diferente das estações meteorológicas, que vão coletar informações mais precisas daquele local.

Nos estudos com a Plataforma NASA-POWER e estações terrestres de superfície, são observados valores de  $R^2$  variando de 0,84 até 0,95 e RMSE de  $1,29\text{ °C}$  até  $3,67\text{ °C}$  para temperatura máxima, mínima e média do ar (JIMÉNEZ et al., 2022). Em outros casos, quando trabalhado com rede de estações no Brasil, podendo variar o RMSE de  $2,64\text{ °C}$  até  $2,83\text{ °C}$  com

R<sup>2</sup> de 0,68 até 0,65 (DUARTE; SENTELHAS, 2020) como também para temperatura máxima de 0,08 até 0,63 e mínima de 0,08 até 0,85 (R<sup>2</sup>) (AGUIAR; JUNIRO LOBO, 2020). Por outro lado, o próprio programa da NASA-POWER relata que são encontrados erros (RMSE) de 2,10 °C nos modelos (MERRA-2) na estimativa da temperatura média do ar (STACKHOUSE, 2022).

Diferente do observado neste trabalho, em que foram registrados bons ajustes dos modelos descritos pelos altos valores de R<sup>2</sup> e baixo de RMSE para temperatura máxima e mínima do ar. Por outro lado, ficando próximos apenas da temperatura média que apresentou uma maior variação nos valores de acurácia e precisão.

A análise regional das condições topográficas e uso do solo são importantes para a caracterização climática do local. No estado da Georgia, são registradas alterações na temperatura a depender da região em que se encontra. Regiões próximas do Tennessee a temperatura é menor variando de 3,0 – 5,9°C no mês de janeiro, enquanto que nas regiões próximas a Flórida no mesmo mês são encontradas variações de 8,0 – 14,9°C (SOULÉ, 1998; BINITA; SHEPHERD; GAITHER, 2015).

A determinação da época de semeadura da cultura é importante para obtenção das características climáticas ideais para o cultivo. Nesse sentido, a depender da época de semeadura são observadas influência da temperatura na matéria seca, crescimento das folhas e germinação do amendoim, descritas como ótimas entre 27 a 33 °C, encontradas no mês de junho. Além disso, o rápido crescimento inicial influenciado pelas altas temperaturas encontradas no mês de junho, são importantes para o estabelecimento da cultura no campo e conseqüentemente a produção (VIRK; PILON; SNIDER, 2019).

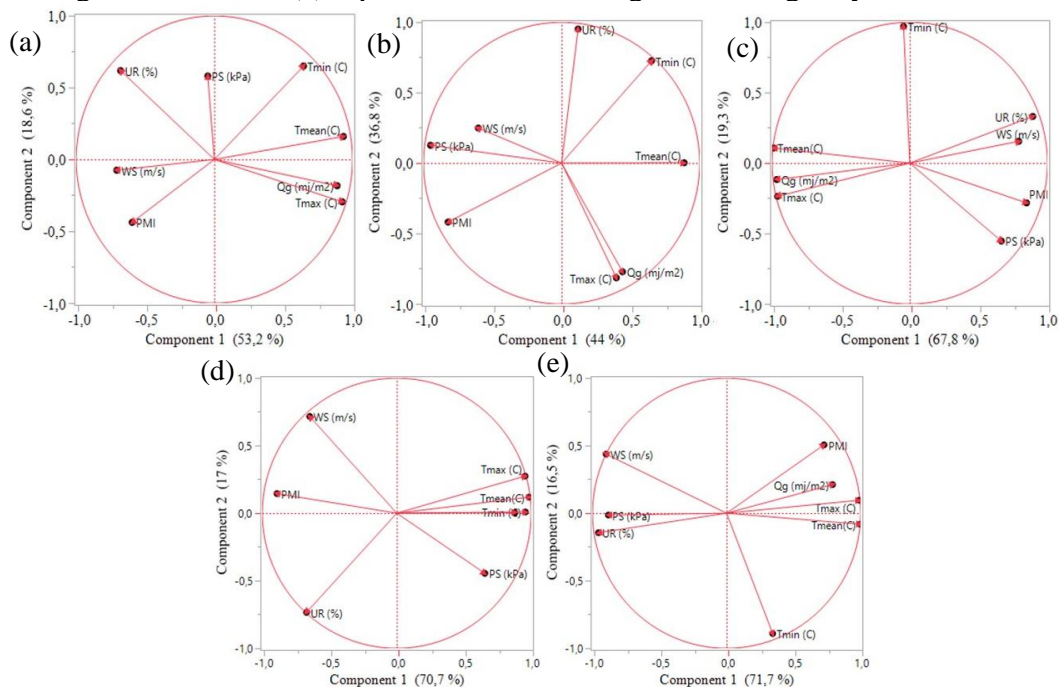
A planta de amendoim é impactada substancialmente pela temperatura, o que pode afetar no seu processo de maturação das vagens e na qualidade do produto colhido. Tal fato pode ser evidenciado quando são utilizados índices agrometeorológicos como o acumulado de graus dias (AGD) para avaliação da maturação. Esse índice, já vem sendo utilizado em diversos trabalhos, visto que são boas as respostas encontradas entre a maturação e o AGD (ROWLAND et al., 2006; SANTOS et al., 2021; SOUZA et al., 2022). Para a realização do cálculo, além da temperatura máxima e mínima do ar é necessário o fornecimento da temperatura base de 13,5 °C descrito como limite para o cultivo de amendoim (ZHANG et al., 2022). Outro ponto importante da temperatura é a capacidade de exercer influência em outras variáveis climáticas, com isso, alterando todo o planejamento agrícola no manejo das culturas.

A temperatura é um fator importante do ponto de vista climático, sendo que outras variáveis climáticas como umidade relativa e radiação solar são influenciadas pelas suas

alterações. No manejo das culturas agrícolas essas variáveis climáticas colaboram para obtenção de altas produtividades. No entanto, para a realização do monitoramento das condições climáticas, plataformas em grid como a NASA-POWER são ferramentas de baixo custo e viáveis, podendo ser aplicadas para análise das condições climáticas locais. Tais plataformas apresentam resultados similares quando comparados com estações meteorológicas de superfície, principalmente, para as variáveis pressão de superfície, temperatura máxima, mínima, média e radiação solar (Figura 3, 5, 6, 7, 8).

Dados climatológicos são relevantes do ponto de vista agrônomo, visto que podem interferir na produtividade das culturas agrícolas. No entanto, para avaliação das variáveis climatológicas que mais se relacionam com a maturação na cultura do amendoim, foi realizada a análise de componentes principais (PCA) apresentada na figura 6. Na análise de PCA foram inseridas as variáveis pressão de superfície, umidade relativa, temperatura máxima, mínima, média, velocidade do vento e radiação solar, podendo observar a relação das variáveis climáticas com a maturação.

Figura 9 - Análise de PCA. (a) representa a PCA do modelo geral; (b) representa a PCA da região de Coffee; (c) representa a PCA da região de Tifton; (d) representa a PCA da região de Berrien; (e) representa a PCA da região de Dougherty.



Fonte: do autor, 2023. PS: pressão de superfície; WS: velocidade do vento; UR: umidade relativa; QG: radiação solar; Tmax: temperatura máxima; Tmin: temperatura mínima; Tmean: temperatura média.

No modelo geral, somando os dois componentes, a PCA foi capaz de responder a 71,8% da variabilidade dos dados (Figura 9a). Já na divisão por regiões, a somatória dos componentes 1 e 2 foram responsáveis por 80,8%, 87,1%, 87,7% e 88,2% para Berrien (Figura 9d), Coffee

(Figura 9b), Dougherty (Figura 9e) e Tifton (Figura 9c) respectivamente. Esses resultados demonstram um aumento na capacidade da PCA em responder a variabilidade dos dados. Além disso, para a maturação do amendoim (PMI), foi observado que a T<sub>min</sub>, T<sub>max</sub>, T<sub>mean</sub> e Q<sub>g</sub> aparecem opostos ao PMI demonstrando que a tais variáveis climáticas afetam os valores de PMI, ou seja, na medida que a temperatura ou a radiação solar aumenta, menor serão os valores de PMI e conseqüentemente, a produtividade e qualidade dos grãos colhidos será afetada.

Sendo assim, a definição da época de cultivo torna-se um fator essencial para o desenvolvimento das plantas de amendoim. Todavia, os produtores devem se atentar a janela de semeadura que se inicia por volta de 10 de abril e se estende até no começo de julho. Nesta época de semeadura, são encontradas as condições climáticas ideais para a cultura do amendoim, sendo que a temperatura ótima para o crescimento é de 27,5 °C, podendo variar entre 29 °C a 33 °C (RUSSELE et al., 1984). Essas variáveis que podem interferir no desenvolvimento das plantas de amendoim podem ser estima (temperatura máxima, mínima, média e radiação solar) das por meio da plataforma do NASA POWER (Figura 5, 6, 7 e 8) com acurácia e precisão. Contudo, deve ser observado se as áreas de cultivo de amendoim não se sobrepõem devido à baixa resolução espacial de 0,5° x 0,625° de latitude e longitude (aproximadamente 55,6 x 69,4 quilômetros) para dados meteorológicos e 1° x 1° de latitude e longitude para dados de radiação solar (aproximadamente 111 x 111 quilômetros) dos dados em grid.

#### **4 CONCLUSÃO**

Com este estudo, foi possível evidenciar que os dados NASA-POWER quando avaliada a temperatura máxima, mínima, média do ar e a radiação solar, apresentaram boas relações com as estações meteorológicas de superfície. Dessa forma, podendo evidenciar o potencial uso da plataforma no monitoramento da maturação de amendoim, especialmente porque essas variáveis foram as que mais apresentaram relação com a maturação quando realizada a análise de PCA. Diferente do observado para a pressão de superfície, que apresentou bons ajustes dos modelos de regressão linear e pouca relação com a maturação na análise de PCA.

A velocidade do vento, foi a variável que apresentou o pior ajuste dos modelos de regressão linear em termos de acurácia e precisão. Visto que no seu cálculo é utilizada a velocidade do vento a 50 metros diferente do encontrado para a estação que é mensurada a 2 metros de altura. Além disso, os modelos apresentaram melhores desempenhos quando analisados por regiões, exceto para a região de Dougherty, que apresentou desempenho menor



do que nas demais regiões. O modelo geral se demonstrou acurado e preciso com valores próximos do observado por cada região, exceto para a velocidade do vento.

Entretanto, devido à baixa resolução espacial com grades maiores do que 50 quilômetros para dados meteorológicos e acima de 100 quilômetros para a radiação solar, restrições e possíveis interferências podem ser encontradas quando utilizados esse tipo de dado. Por exemplo na umidade relativa do ar que apresentou baixa correlação ( $r < 0,8$ ) quando comparada com as estações meteorológicas de superfície.

## REFERÊNCIAS

- ABOELKHAIR, H.; MORSY, M. Assessment of agroclimatology nasa power reanalysis datasets for temperature types and relative humidity at 2 m against ground observation over egypt. **Advances in Space Research**, 64, 129 – 142, 2019. Doi: [HTTPS://DOI.ORG/10.1016/J.ASR.2019.03.032](https://doi.org/10.1016/j.asr.2019.03.032)
- AGUIAR, J. T.; JUNIOR LOBO, M. Reliability and discrepancies of rainfall and temperatures from remote sensing and Brazilian ground weather stations. **Remote Sensing Applications: Society and Environment**, v. 18, 2020. Doi: <https://doi.org/10.1016/j.rsase.2020.100301>
- BAI, J., CHEN, X., DOBERMANN, A., YANG, H., CASSMAN, K. G., ZHANG, F. Evaluation of nasa satellite- and model-derived weather data for simulation of maize yield potential in china. **Agroclimatology**, v. 102, p. 9 – 16, 2010. Doi: 10.2134/agronj2009.0085
- BENGTSSON, L. *et al.* The HARMONIE – AROME model configuration in the ALADIN – HIRLAM NWP system. **Monthly Weather Review**, 145, 1919 – 1935, 2017. Doi: <https://doi.org/10.1175/MWR-D-16-0417.1>
- BINITA, K. C.; SHEPHERD, J. M. Gaither, C. J. Climate change vulnerability assessment in Georgia. **Applied Geography**, v. 62, p. 62 – 74, 2015. Doi: <https://doi.org/10.1016/j.apgeog.2015.04.007>
- BRANCH, W. D. Registration of ‘Georgia-06G’ peanut. **Journal of Plant Registration**, v. 1, p. 120 – 120, 2007. Doi: <https://doi.org/10.3198/jpr2006.12.0812crc>
- DUARTE, Y. C. N.; SENTELHAS, P. NASA/POWER and dailygridded weather datasets—how good they are for estimating maize yields in brazil? **Internacional Journal of Biometeorology**, v. 64, p. 319 – 329, 2020. Doi: <https://doi.org/10.1007/s00484-019-01810-1>
- GASO, D. V.; WIT, A.; BRUIN, S.; PUNTEL, L. A.; BERGER, A. G.; KOOISTRA, L. Efficiency of assimilating leaf area index into a soybean model to assess within-field variability. **European Journal of Agronomy**, v. 143, p. 1 – 9, 2023. Doi: <https://doi.org/10.1016/j.eja.2022.126718>
- JEGER, M. J. The impact of climate change on disease in wild plant populations and communities. **Plant Pathology**, v. 71, p. 111 – 130, 2022. Doi: <https://doi.org/10.1111/ppa.13434>
- JIMÉNEZ, S. I.; BUSTAMANTE, W. O.; IBARRA, M. A. I.; PABLO, M. J. P. Analysis of the NASA-POWER system for estimating reference evapotranspiration in the Comarca Lagunera, Mexico. **Ingeniería agrícola y biosistemas**, v. 13, n. 2, 2022. Doi: <https://doi.org/10.5154/r.inagbi.2021.03.050>
- KOPPEN, W., & GEIGER, R. Classificação climática de Koppen-Geiger. 1923.
- MALDONATO, W.; VALERIANO, T. T. B.; ROLIM, G. S. EVAPO: A smartphone application to estimate potential evapo-transpiration using cloud gridded meteorological data from NASA-POWER system. **Computers and Electronics in Agriculture**, v. 156, p. 87 – 192, 2019. Doi: <https://doi.org/10.1016/j.compag.2018.10.032>
- NEGM, A.; JABRO, J.; PROVENZANO, G. Assessing the suitability of American national Aeronautics and Space Administration (NASA) agro-climatology archive to predict daily meteorological variables and reference evapotranspiration in Sicily, Italy. **Agricultural and Forest Meteorology**, v. 244, p. 111 – 121, 2017. Doi: <https://doi.org/10.1016/j.agrformet.2017.05.022>

- PALMERO, F.; CARCEDO, A. J. P.; HARO, R. J.; BIGATTON, E. D.; SALVAGIOTTI, F.; CIAMPITTI, I. A. Modeling drought stress impacts under current and future climate for peanut in the semiarid pampas region of Argentina. **Field Crops Research**, v. 286, 2022. Doi: <https://doi.org/10.1016/j.fcr.2022.108615>
- Peanut Field Agronomic Resource Manager (PeanutFARM) (2023). <http://peanutfarm.org/>
- RICHARDSON, M. I.; NEWMAN, C. E. On the relationship between surface pressure, terrain elevation, and air temperature. Part I: The large diurnal surface pressure range at Gale Crater, Mars and its origin due to lateral hydrostatic adjustment. **Planetary and Space Science**, v. 164, p. 132 – 157, 2018. Doi: <https://doi.org/10.1016/j.pss.2018.07.003>
- RODRIGUES, G. C.; BRAGA, R. P. Evaluation of NASA POWER reanalysis products to estimatedaily weather variables in a hot summer mediterranean climate. **Agronomy MDPI**, v. 11, p. 1 – 17, 2021. Doi: <https://doi.org/10.3390/agronomy11061207>
- ROWLAND, D. L.; SORENSEN, R. B.; BUTTS, C. L.; FAIRCLOTH, W. H. Determination of Maturity and Degree Day Indices and their Success in Predicting Peanut Maturity. **Peanut Science**, v. 33, p. 125–136, 2006. Doi: [https://doi.org/10.3146/0095-3679\(2006\)33\[125:DOMADD\]2.0.CO;2](https://doi.org/10.3146/0095-3679(2006)33[125:DOMADD]2.0.CO;2)
- RUSSELLE, M. P.; WILHELM, W. W.; POWER, OLSON, R. A.; POWER, J. F. Growth analysis based on Degree Days. **Crop Science**, 24, 1984. Doi: <https://doi.org/10.2135/cropsci1984.0011183X002400010007x>
- SANTOS, A. F.; LACERDA, L. N.; ROSSI, C.; MORENO, L. A.; OLIVEIRA, M. F.; PILON, C.; SILVA, R. P.; VELLIDIS, G. Using UAV and multispectral images to estimate peanut maturity variability on irrigated and rainfed fields applying linear models and artificial neural networks. **Remote sensing**, v. 14, n. 93, 2022. Doi: <https://doi.org/10.3390/rs14010093>
- SANTOS, A. F.; CORRÊA, L. N.; LACERDA, L. N.; OLIVEIRA, D. T.; PILON, C.; SILVA, R. P. High-resolution satellite image to predict peanut maturity variability in commercial fields. **Precision Agriculture**, v. 22, p. 1464–1478, 2021. Doi: <https://doi.org/10.1007/s11119-021-09791-1>
- SOULÉ, P. T. Some Spatial Aspects of Southeastern United States Climatology. **Journal of Geography**, 97, 1988. Doi: <https://doi.org/10.1080/00221349808978894>
- SOUZA, J. C. B.; ALMEIDA, S. L. H.; OLIVEIRA, M. F.; SANTOS, A. F.; FILHO, A. L. B.; MENESES, M. D.; SILVA, R. P. Integrating satellite and UAV data to predict peanut maturity upon artificial neural networks. **Agronomy MDPI**, v. 12, p. 1 – 15, 2022. Doi: <https://doi.org/10.3390/agronomy12071512>
- STACKHOUSE, P. Metodologia: fonte de dados. **Nasa docs, NASA**, 2022. <https://power.larc.nasa.gov/docs/methodology/data/sources/>
- United States Department of Agriculture (USDA) (2020). <https://apps.fas.usda.gov/psdonline/reportHandler>.
- VALERIANO, T. T. B.; ROLIM, G. S.; BISPO, R. C.; MORAES, J. R. S. C.; APARECIDO, L. E. O. Evaluation of air temperature and rainfall from ECMWF and NASA gridded data for southeastern Brazil. **Theoretical and Applied Climatology**, v. 137, p. 1925 – 1938, 2019. <https://doi.org/10.1007/s00704-018-2706-z>
- VIRK, G.; PILON, C.; SNIDER, J. L. Impact of first true leaf photosynthetic efficiency on peanut plant growth under different early-season temperature conditions. **Peanut Science**, v. 46, p. 162 – 173, 2019. Doi: <https://doi.org/10.3146/PS19-8.1>

VOYANT, C.; MUSELLI, M.; PAOLI, C.; NIVET, M. L. Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. **Energy**, v. 1, p. 341 – 355, 2012. Doi: <https://doi.org/10.1016/j.energy.2012.01.006>

WEI, S. LI, K.; YANG, Y.; WANG, C.; LIU, C.; ZHANG, J. Comprehensive climatic suitability evaluation of peanut in Huang-Huai-Hai region under the background of climate change. **Nature**, v. 12, p. 1-18, 2022. Doi: <https://doi.org/10.1038/s41598-022-15465-3>


WILLIAMS, E. J.; DREXLER, J. S. A Non-Destructive Method for Determining Peanut Pod Maturity. **Peanut Science**, v. 8, p. 134–141, 1981. Doi: <https://doi.org/10.3146/i0095-3679-8-2-15>

WILLMOTT, C. J. *et al.* Statistics for the evaluation and comparison of models. **Journal of Geophysical research**, v. 90, p. 8995 – 9005, 1985. Doi: <https://doi.org/10.1029/JC090iC05p08995>


ZHANG, G.; LECLERC, M. Y.; SINGH, N.; TUBBS, R. S.; MONFORT, W. S. Impact of planting date on CO<sup>2</sup> fluxes, evapotranspiration and water-use efficiency in peanut using the eddy-covariance technique. **Agricultural and Forest Meteorology**, 326, 2022. Doi: <https://doi.org/10.1016/j.agrformet.2022.109163>

## ANEXO


Box plot comparativo entre estações meteorológicas de superfície (WS) e a plataforma NASA POWER (NP) dividido por estações do ano.




WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. PS: pressão de superfície (kPa).



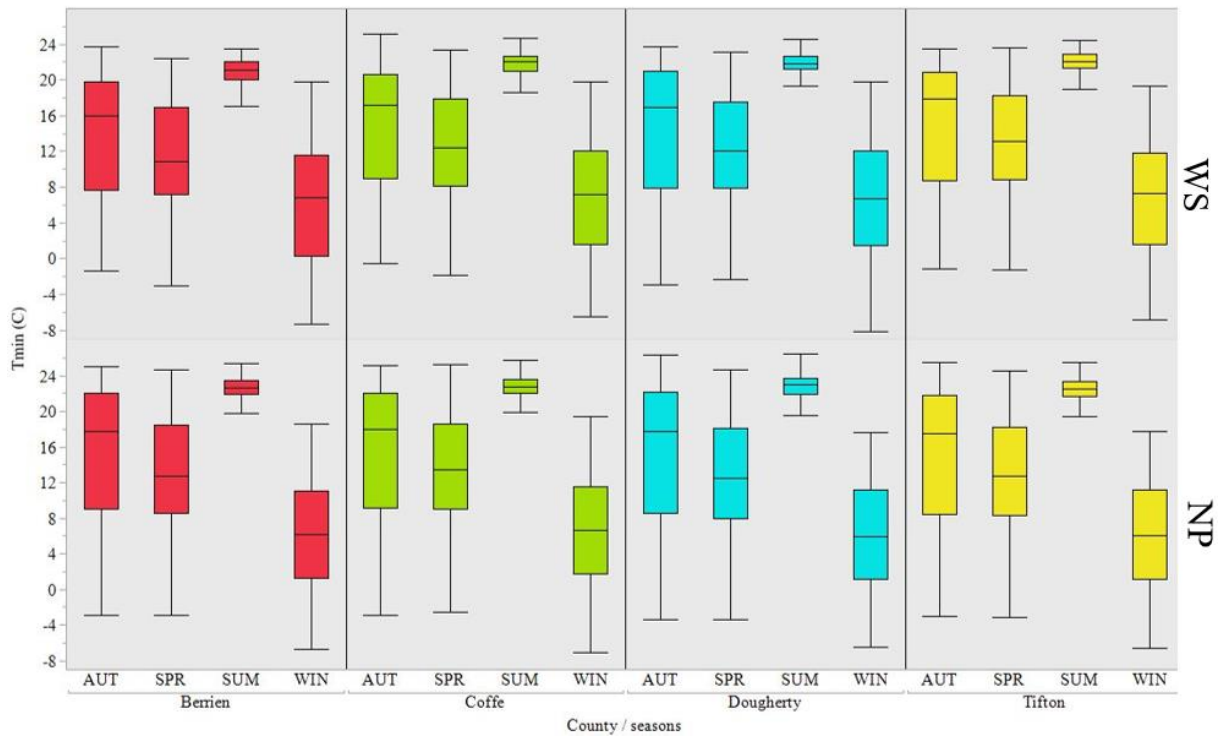
WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. WS: velocidade do vento ( $\text{m s}^{-1}$ ).




WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. Qg: radiação solar ( $\text{Mj m}^2 \text{ dia}^{-1}$ ).



WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. Tmax: temperatura máxima ( $^{\circ}\text{C}$ ).



WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. Tmin: temperatura mínima (°C).



WS: estações meteorológicas de superfície; NP: NASA-POWER. Estações do ano AUT: outono; SPR: primavera; SUM: verão; WIN: inverno. Tmean: temperatura média (°C).

## CAPÍTULO 2 – Aplicando inteligência artificial para identificar a maturação de amendoim usando variáveis climáticas e índices de vegetação

### RESUMO

Na cultura do amendoim o aumento da qualidade da matéria-prima e da produtividade é possível a partir da rigorosa análise de maturação da cultura. Nesse sentido, o objetivo do trabalho foi a utilizar redes neurais com arquitetura Perceptron de Multicamadas (MLP) para estimar a maturação de amendoim em função da localização das áreas a partir da associação de índices de vegetação (IVs) e dados climáticos. No estado de São Paulo foram utilizadas seis áreas e 20 pontos amostrais por área, em Minas Gerais apenas uma área de produção com 30 pontos amostrais e no estado da Geórgia 3 áreas com 24 pontos amostrais e 1 área com 12 pontos amostrais. Em todos os locais a maturação foi avaliada usando o método Hull-scrape, em MG e SP foram avaliadas 5 datas de maturação, GA 4, 5 e 6 datas para Tifton, Dougherty, Coffe e Berrien. Nos estados brasileiros a cultivar utilizada foi a OL3 enquanto que no estado da Geórgia a cultivar utilizada foi a GEORGIA-06G. Foram coletados os dados climáticos por meio da plataforma NASA-POWER na mesma época de avaliação da maturação. As variáveis climáticas de temperatura máxima (Tmax), mínima (Tmin) e média (Tmean) e radiação solar (Qg) foram baixadas e realizado o cálculo do acumulado de graus dias (AGD) para as diferentes áreas. Foram calculados os IVs NDVI, GNDVI, NLI, MNLI, RVI, RDVI, SAVI, OSAVI e EVI, além das bandas do vermelho (red) e do infravermelho (NIR). A calibração das redes MLP ocorreu a partir do uso de dois métodos de treinamento o *Backpropagation* e Levenberg-Marquardt. Foram combinados diferentes entradas, neurônios e épocas de treinamento para seleção dos melhores modelos para cada estado e para o modelo global. Para a seleção das variáveis de entrada foram realizadas a Análise de Componentes Principais (PCA) e a correlação de Pearson ( $p < 0,05$ ) para cada estado, além da utilização da análise sensível fornecida após o treinamento de cada modelo. O conjunto de dados foi dividido em 70% para treinamento, 20% para validação e 10% para teste. A avaliação das redes ocorreu a partir dos valores de RMSE, MAE e  $R^2$ . O melhor método de treinamento encontrado foi o Levenberg-Marquardt. Dentre as variáveis climáticas e IVs o AGD, Qg e o MNLI foram os que apresentaram os melhores resultados na calibração dos modelos. O amendoim é uma cultura muito responsiva a temperatura, variações na temperatura afetam diretamente o seu ciclo, produção de flores e vagens. O melhor ajuste encontrado na etapa de teste foi obtido para o estado da Geórgia com  $R^2$  de 0,943, RMSE 0,058 e MAE 0,041 seguido do Global, Minas Gerais e São Paulo. Os valores máximos de erro encontrados foram de 0,100 (RMSE) no estado de MG, o que representa um erro de 10% na estimativa da maturação. Tal fato pode ser atribuída a baixa variação dos IVs durante as épocas de avaliação, o que dificulta a generalização da rede para a situação. Além disso, são necessários mais estudos com outras cultivares de amendoim e sobre diferentes tipos de solo.

**Palavras-chaves:** Perceptron de Multicamadas. Radiação Solar. Temperatura. *Arachis hypogaea* L.



## 1 INTRODUÇÃO

O amendoim (*Arachis hypogaea* L.) é cultivado amplamente no mundo, sendo que nas Américas os Estados Unidos, Brasil e Argentina são os países que se destacam na produção. Nesses países, os estados da Geórgia, USA, de São Paulo, BR e de Córdoba, AR são responsáveis por 55%, 92% e 85% da produção nacional, respectivamente (USDA, 2023). Por se tratar de uma cultura que reflete na economia desses estados e países, adequar o manejo é a melhor forma de aumentar a produção e diminuir as perdas, principalmente quando as condições climáticas são levadas em conta, visto que o clima influencia na maturação e ciclo do amendoim.

A maturação das vagens de amendoim é um processo que ocorre aproximadamente 90 dias após a semeadura (BOOTE, 1972). Esse processo de maturação, está diretamente relacionado com a época de início da operação de arranquio, que deve começar quando os valores do índice de maturação (PMI) da cultura estiverem próximos 0,70 a 0,75 (SANTOS et al., 2021a, SOUZA et al. 2022). No entanto, por se tratar de uma planta de hábito de crescimento indeterminado a maturação encontrada entre as plantas e em uma mesma planta é variável ao longo da área, fato esse que não é contabilizado durante o processo de avaliação da maturação por métodos tradicionais (SANTOS et al., 2021b).

A metodologia tradicional descrita para a avaliação da maturação é a proposta por William e Drexler (1981) e Rowland et al. (2006), que utilizam do quadro de maturação para classificação das vagens e cálculo do PMI. No entanto, todo esse processo de avaliação se tornou oneroso, subjetivo e dependente da capacidade do técnico em diferenciar as classes de cores do quadro de maturação, para a tomada de decisão da época de entrada as máquinas no campo (SANTOS et al. 2021a). Apesar disso, muitos órgãos públicos e privados utilizam esse método ainda para avaliação da maturação das vagens.

Uma das formas de mapear esse efeito da variabilidade nas áreas de produção é a aplicação da inteligência artificial (IA). No uso da IA uma das suas subáreas que vem ganhando espaço são as aplicações das redes neurais artificiais. Tais redes são capazes de reconhecer os padrões e generalizar o resultado de forma precisa e acurada (SOOD; KUMAR; KUMAR, 2021), como é observado na cultura da soja (ABRAHAM et al., 2020), no trigo (GARG et al., 2016) e em frutíferas (KHAN et al., 2020).

Devido a essa capacidade de aprendizado dos algoritmos de inteligência artificial, são encontradas aplicações dos algoritmos na cultura do amendoim principalmente na estimativa da produtividade (SOUZA et al., 2022) e na identificação de doenças (XU et al., 2023).

Demonstrando o potencial das técnicas em serem aplicadas na maturação, principalmente quando associados com dados climáticos.

As formas de avaliar a maturação começaram a tomar outra direção. Um dos alvos de estudo foi a utilização de índices de vegetação na estimativa da maturação e mapeamento da variabilidade encontrada nos campos de produção (SANTOS et al., 2021a; SOUZA et al., 2022; SANTOS et al., 2019). Demonstrando o potencial dessas ferramentas (sensoriamento remoto e inteligência artificial) quando combinadas para realizar a estimativa da maturação. Apesar dos índices de vegetação serem bons indicativos da variabilidade encontrada nas áreas, as condições climáticas do local influenciam diretamente o ciclo da cultura. Uma das variáveis climáticas que apresenta grande influência no período reprodutivo é a temperatura (ONO, 1979; BOOTE, 1972). Além da temperatura, outra variável que tem a capacidade de afetar a biomassa, número de flores, produtividade e duração do ciclo da cultura é a radiação solar (RAO; MITTRA, 1987).

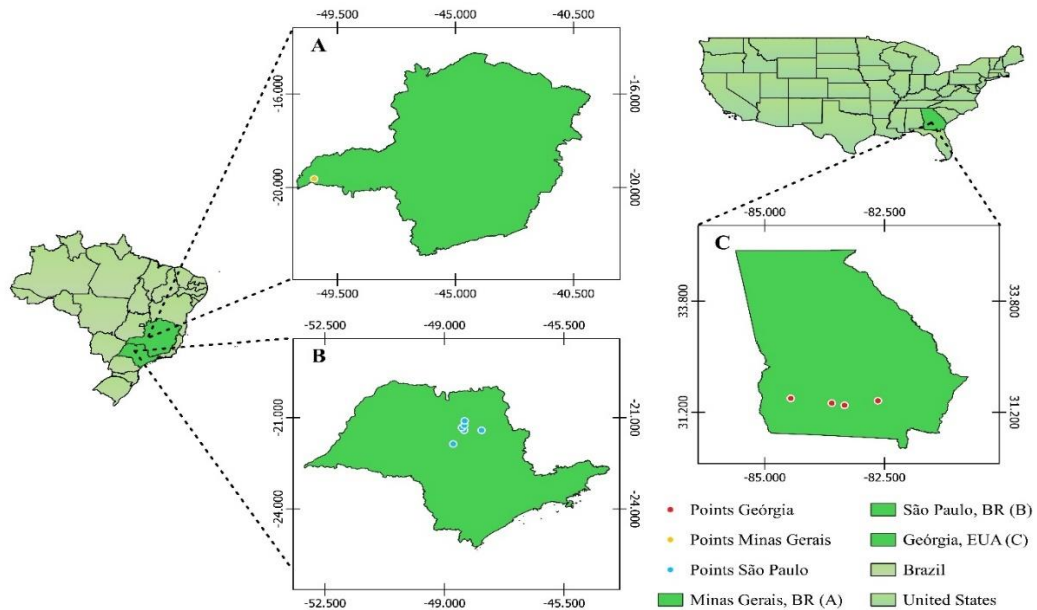
Dessa forma, devido à alta capacidade de generalização das redes neurais artificiais utilizar parâmetros climáticos juntamente com índices de vegetação são formas de melhorar as respostas com a estimativa da maturação do amendoim. Diminuindo as perdas de qualidade das vagens e aumentando a produtividade das regiões produtoras a partir da identificação da melhor época de início do arranquio. Além disso, por meio da aplicação dos algoritmos é possível mapear a variabilidade encontrada na maturação e descrever o momento ideal para realização do processo inicial de colheita o arranquio, minimizando as perdas no campo e melhorando a qualidade do produto colhido. Portanto, o objetivo do trabalho foi avaliar o desempenho de redes do tipo perceptron de multicamada (MLP) na estimativa da maturação de amendoim em diferentes locais a partir da associação de índices de vegetação e dados climáticos obtidos de plataformas remotas.

## **2 MATERIAL E METÓDOS**

### **2.1 Área de estudo**

Para realização das análises e criação das redes neurais, foram utilizados 11 campos comerciais com a cultura do amendoim. Desses 11 campos 6 são localizados no estado de São Paulo, Brasil, (Frutal, Santa Gertrudes, Ibitinga, Capão da Cruz, Granja e Santa Adélia). Para o estado de Minas Gerais, Brasil um campo foi destinado a avaliação da maturação sendo este localizado em Iturama. Além desses campos no Brasil, no estado da Geórgia, EUA foram coletadas a maturação em 4 campos, Magnolia, Blaelock, Docia e Grand Canyon (Figura 1).


Figura 1 – Mapa de localização das regiões onde foram realizadas as coletas para a avaliação da maturação.



Fonte: do autor, 2023.

O clima dos diferentes locais é classificado como Aw com invernos secos e chuva de outono a abril para São Paulo e Minas Gerais e subtropical para o estado da Geórgia com verões quentes. A precipitação média anual encontrada nos diferentes locais apresentam poucas variações, com valores de 1346, 1433 e 1400 milímetros para Geórgia, Minas Gerais e São Paulo respectivamente. Por outro lado, com temperatura média anual de 30, 25 e 28,5°C e radiação solar média anual de 19,1, 17,28, 19,8  $\text{Mj m}^2 \text{dia}^{-1}$  para Minas Gerais, Geórgia e São Paulo respectivamente (Figura 2) (KOPPEN; GEIGER, 1928; ALVAREZ et al., 2014).

Figura 2 – Média de 10 anos (2011 – 2021) da temperatura ( $^{\circ}\text{C}$ ) e radiação solar ( $\text{Mj m}^2 \text{dia}^{-1}$ ) dos locais de estudo.



Fonte: do autor, 2023.

No estado da Geórgia, os campos de Magnolia e Docia eram irrigados sobre o sistema de pivô central e Blaelock e Grand Canyon não eram irrigados. O manejo da irrigação seguida as recomendações da plataforma PeanutFARM (<http://peanutfarm.org/>) a partir do acumulado de graus dias e das precipitações nas áreas produtoras. Nas demais áreas de Minas Gerais e São Paulo nenhum dos campos de avaliação da maturação eram irrigados. Além disso, na tabela 1 são apresentados as datas de avaliação da maturação no campo representada por dias após a semeadura (DAS) e o acumulado de graus dias (AGD) de cada época de avaliação. A última coluna da tabela refere-se à quantidade de pontos amostrais coletados nos campos de avaliação da maturação. A distância entre os pontos de coleta georreferenciados foi de 100 metros independentemente do local e estado, e as plantas eram coletadas em um raio de 1 a 5 metros do ponto georreferenciado.

Tabela 1 - Estado e nome do campo de avaliação da maturação do amendoim em dias após a semeadura (DAS) e o acumulado de graus dias (AGD) de cada época de avaliação.

Estado	Área	DAS	AGD	Altitude (metros)	Data de semeadura	Pontos
MG	Iturama	85, 92, 102, 111, 118	1092, 1185, 1310, 1413, 1501	541	23/10/2021	30
SP	Frutal	90, 97, 104, 111, 118	1217, 1319, 1409, 1492, 1592	613	27/10/2021	20
SP	Santa Adélia	90, 97, 104, 111, 118	1216, 1319, 1407, 1491, 1592	633	28/10/2021	20
SP	Santa Gertrudes	90, 97, 104, 111, 118	1275, 1375, 1464, 1566, 1656	630	02/11/2021	20
SP	Capão da Cruz	97, 104, 111, 118	1216, 1314, 1409, 1489, 1583,	572	25/10/2021	20
SP	Ibitinga	90, 97, 104, 111, 118	1237, 1318, 1415, 1517,	486	04/12/2021	20
SP	Granja	90, 97, 104, 111	1224, 1322, 1401, 1493	568	31/10/2021	20
GA	Blaelock	96, 104, 109, 116, 128, 135	1655, 1777, 1857, 1955, 2127, 2182	68	11/06/2018	24
GA	Magnolia	96, 107, 117, 126, 135	1867, 2034, 2182, 2326, 2441	62	06/11/2018	24
GA	Docia	115, 122, 129, 139	1589, 1798, 1921, 2023	113	29/04/2019	24
GA	Grand Canyon	103, 109, 117, 124, 131, 138, 145	1496, 1661, 1818, 1938, 2041, 2136, 2228	82	28/04/2019	12

Fonte: do autor, 2023. MG: estado de Minas Gerais, Brasil; SP: estado de São Paulo, Brasil; GA: estado da Geórgia, Estados Unidos. DAS: dias após a semeadura; AGD: acumulado de graus dias.


A cultivar utilizada no estado da Geórgia foi a Georgia-06G com ciclo de 140 dias (BRANCH, 2007) enquanto que no Brasil em ambos os estados foram utilizadas a cultivar desenvolvida pelo IAC a OL3 com ciclo variando de 125 – 130 dias (GODOY et al., 2018). Ambas as cultivares e independente do local, a semeadura foi realizada no espaçamento de 0,90 metros.

## 2.2 Cálculo da maturação

Nas áreas do estado de Minas Gerais (Iturama), São Paulo (Ibitinga, Santa Adélia, Santa Gertrudes, Frutal e Capão da Cruz) e no estado da Geórgia (Docia, Grand Canyon, Magnolia e Blaelock) o método adotado para avaliação da maturação foi classificando as vagens no quadro de maturação (WILLIAM; DREXLER, 1981) e a metodologia desenvolvida por Rowland et al. (2006).

Sendo assim, para cada ponto de coleta posicionado nos campos de produção e de acordo com a data de semeadura (DAS) apresentada na tabela 1 foi realizada a avaliação da maturação. Na avaliação da maturação foram coletadas de 8-12 plantas no campo em um raio de até 5 metros do ponto georreferenciado. As plantas foram ensacadas e levadas para o laboratório para a separação das vagens da planta ao final totalizando 180 – 200 vagens por ponto amostral para a classificação no quadro de maturação (Figura 3B). Com a quantidade correta de vagens, uma máquina de lavar de alta pressão foi utilizada para lavar a camada do exocarpo e expor o mesocarpo das vagens (Figura 3A) (ROWLAND et al., 2006).

Figura 3 - Vagens sendo lavadas sobre alta pressão para retirada do exocarpo (A) e classificação das vagens com o mesocarpo exposto (B).



Fonte: do autor, 2023.

A camada do mesocarpo é a região que apresenta a coloração para classificação no quadro de maturação desenvolvido por Williams e Drexler (1981), sendo está a segunda etapa do procedimento para avaliação da maturação. O quadro de maturação apresenta 6 classes definidas sendo elas: branco, amarelo I, amarelo II, laranja, marrom e preto. Quanto mais próximo da classe preta maior é o indicativo da maturação das vagens, dessa forma podendo inferir sobre a época de entrada das máquinas na área.

Com a classificação da maturação finalizada é possível calcular o índice de maturação do amendoim (*peanut maturity index*). O PMI é um valor obtido a partir da razão entre a soma das classes marrom e preta do quadro de maturação pelo número total de vagens classificadas no quadro. Os valores de PMI podem variar de 0 a 1, valores próximos de 0 as vagens estão imaturas enquanto que valores próximos de 1 indicam a maturação das vagens. No entanto de modo prático é adotado como momento ideal para início do arranquio quanto o PMI apresenta valores de 0,7 a 0,75, não ocorrendo perdas devido qualidade dos grãos e a baixa maturação (SANTOS et al., 2021a; SOUZA et al., 2022).

### 2.3 Coleta de dados climáticos

Um dos parâmetros de entradas da rede do tipo perceptron de multicamadas foi a utilização dos dados climáticos. O uso de dados climáticos é uma forma de apresentar a rede outras fontes que podem influenciar na maturação das vagens e no ciclo da cultura do amendoim. Dessa forma, as variáveis climáticas selecionadas para compor a entrada das redes foram a radiação global (Qg), temperatura máxima (tmax), mínima (tmin) e média (tmean) (Tabela 2).

Para a seleção das variáveis climáticas foram inseridos no mapa do programa NASA-POWER/ *Data access* as coordenadas geográficas de cada região de coleta da maturação, selecionando a data de semeadura e a última data de avaliação da maturação de cada área estudada, com o arquivo de saída no formato CSV.

Tabela 2 - Descrição das variáveis climáticas.

Variável climática	Unidade de medida	Modelo
Radiação Solar (Qg)	MJ m <sup>-2</sup> dia <sup>-1</sup>	GEWEX e CERES
Temperatura máxima (tmax)	°C	GMAO MERRA – 2 e GEOS – 4
Temperatura mínima (tmin)	°C	GMAO MERRA – 2 e GEOS – 4
Temperatura média (tmean)	°C	GMAO MERRA – 2 e GEOS – 4

Fonte: do autor, 2023. GMAO: *Global Modelling and Assimilation Office*; MERRA: *Modern-Era Retrospective analysis for Research and Applications*; GEOS: *Goddard Earth Observing System*.

Todos os dados climáticos foram obtidos pela plataforma da *National Aeronautics and Space Administration* (NASA) do programa *Prediction of Worldwide Energy Resource* (POWER). Os dados são fornecidos no formato de grid sendo que para fontes de radiação solar os grids são de 1°x 1° e para os dados de temperatura e meteorológicos, o grid de coleta utilizado é de 0,5° latitude 0,625° longitude (STACKHOUSE, 2021).

Para estimativa da radiação solar são utilizados os dados do GEWEX (*Global Energy and Water Changes*) e CERES (*Cloud and Earth Radiant Energy System*) juntamente com outros três satélites que fornecem informações a respeito da gases, vapores, água na atmosfera. A temperatura e outros dados climáticos (umidade, velocidade do vento, etc.) são obtidos a partir dos modelos GMAO (*Global Modelling and Assimilation Office*) MERRA-2 (*Modern-Era Retrospective analysis for Research and Applications*) e GEOS 5.12.4 (*Goddard Earth Observing System*) (STACKHOUSE, 2021).

### 2.3.1 Acumulado de graus dias (AGD)

Além dos dados climáticos utilizados como entrada para a calibração das redes, o acumulado de graus dias (AGD) foi calculado servindo como outro parâmetro de entrada. A cultura do amendoim possui alta correlação com o AGD (SOUZA et al., 2022; SANTOS et al., 2021a; SANTOS et al., 2019; ROWLAND et al., 2006). No cálculo do AGD (Equação 1) a temperatura máxima, mínima e a temperatura base (13,3 °C) foram consideradas (BAGNALL; KING, 1990).

$$AGD = \frac{(t_{max} - t_{min})}{2} - 13,3 \quad (1)$$

Em que:

AGD – acumulado de graus dias;

Tmax - temperatura máxima do dia;

Tmin – temperatura mínima do dia.

Os valores de temperatura máxima e mínima foram obtidos a partir da plataforma NASA POWER. O AGD foi calculado diariamente a partir da época de semeadura e para as entradas da rede foram utilizados os valores que coincidiram com a época de avaliação da maturação no campo.

## 2.4 Imagens de satélite e cálculo dos índices de vegetação

Além dos dados climáticos, foram selecionados nove índices de vegetação (IV's) e as bandas do vermelho (red) e do infravermelho (NIR) de cada sensor como entrada para as redes MLP. As bandas do red e do NIR são importantes pois apresentam os valores de reflectância naquele comprimento de onda, sendo possível de identificar a variações nas áreas. Para a seleção dos IV's (tabela 2) foram utilizados trabalhos já descritos na literatura que correlacionaram a maturação das vagens de amendoim e os índices de vegetação (SANTOS et al. 2021, SOUZA et al. 2022, SANTOS et al. 2022). Os IV's descritos na Tabela 3 foram todos calculados utilizando o software QGIS 3.26.

A extração dos valores médios dos IV's, ocorreu a partir da ferramenta polígonos de voronoi. Para cada data de avaliação da maturação foram realizados os cálculos dos IVs e extraídos os valores médios. Os polígonos de voronoi foram criados a partir da camada dos pontos georreferenciados, sendo esses polígonos irregulares com aproximadamente 1 hectare e não sobrepondo uns aos outros. Com essa camada de polígonos de voronoi foi possível realizar a extração dos valores dos pixels das imagens a partir da ferramenta estatística zonal. Na ferramenta estatística zonal a camada de entrada utilizada foram os IVs calculados e a camada vetorial os polígonos de voronoi. Assim, foi realizado o cálculo do valor médio dos pixels de cada IV dentro dos polígonos de voronoi e exportado os valores em formato .CSV. Ao final, os valores médios dos nove índices de vegetação e das bandas do vermelho e do infravermelho foram utilizados nos modelos de estimativa. Todo o procedimento foi realizado no software QGIS 3.26.

Tabela 3 - Descrição dos índices de vegetação (continua).

Índices de vegetação	Fórmula	Fonte
NDVI <sup>1</sup>	$\frac{(NIR - R)}{(NIR + R)}$	Rouse et al. (1973)
GNDVI <sup>2</sup>	$\frac{(NIR - G)}{(NIR + G)}$	Gitelson et al. (1996)
SAVI <sup>3</sup>	$\frac{1,5 \times (NIR - R)}{(NIR + R + 0,5)}$	Huete (1988)
OSAVI <sup>4</sup>	$\frac{1,16 \times (NIR - R)}{(NIR + R + 0,16)}$	Rondeaux et al. (1996)
MNLI <sup>5</sup>	$\frac{(NIR^2 - R) * (1,5)}{(NIR^2 + R + 0,5)}$	Gong et al. (2003)



NLI <sup>6</sup>	$\frac{(NIR^2 - R)}{(NIR^2 - R)}$	Goel e Qin (1994)
RVI <sup>7</sup>	$\frac{NIR}{R}$	Major et al. (1990)
RDVI <sup>8</sup>	$\frac{(NIR - R)}{(NIR + R)^{0,5}}$	Louis-roujean e Breon (1995)
EVI <sup>9</sup>	$\frac{2,5 \times (NIR - R)}{(NIR + 6 \times R - 7,5 \times B + 1)}$	Huete et al. (1997)

Fonte: do autor, 2023.<sup>1</sup>normalized difference vegetativo index; <sup>2</sup>green normalized difference vegetation index; <sup>3</sup>soil-ajusted vegetation index; <sup>4</sup>optimized soil-adjusted vegetation index; <sup>5</sup>modified non-linear vegetation index; <sup>6</sup>non-linear vegetation index; <sup>7</sup>ratio vegetation index; <sup>8</sup>re-normalized difference vegetation index; <sup>9</sup>enhanced vegetation index. NIR – infravermelho próximo; R – Vermelho; G – verde.

Para o cálculo dos índices descritos acima foram utilizadas imagens da plataforma PlanetScope (<https://www.planet.com/products/platform/>). A plataforma possui mais de 200 nanosatélites em órbita que são capazes de fornecer imagens diárias do globo terrestre com resolução espacial de 3 x 3 metros. As imagens podem ser baixadas a partir de três sensores, sendo o Dove Classic (PS2), Dove-R (PS2.SD) e SuperDove (PSB.SD).

No Entanto, para as áreas deste estudo foram utilizadas imagens provenientes do Dove-R (Geórgia e São Paulo) e o SuperDove para a Iturama, visto que a partir de maio de 2021 as imagens do SuperDove começaram a ser fornecidas pela plataforma. A principal diferença entre os sensores está na quantidade de bandas que são fornecidas, enquanto o Dove-R possui 4 bandas o SuperDove é capaz de fornecer 8 bandas (tabela 4).

Tabela 4 - Descrição das bandas do satélite PlanetScope.

Instrumento	Instrumento ID	Banda	Comprimento de onda (nm)
Dove-R	PS2.SD	B1 – blue	464 – 517
		B2 – green	547 – 585
		B3 – red	650 – 682
		B4 – NIR	846 – 888
SuperDove	PSB.SD	B2 – azul	465 – 515
		B4 – verde	547 – 583
		B6 – vermelho	650 – 680
		B8 – NIR	845 – 885

Fonte: do autor, 2023.

Além disso todas imagens apresentam correção para reflectância de superfície. A correção para eliminar os efeitos da atmosfera ocorre a partir da *Top-of-Atmosphere* (TOA) em que os *lookup tables* (LUTs) utilizam como entrada o modelo de código de transferência radiativa 6SV2.1 e realizam a correção para reflectância de superfície. Ao final as imagens

corrigidas são fornecidas com 16-bit no formato GEOTIFF e com os valores na escala de 10.000 (PLANET, 2023).

## 2.5 Análises de PCA e correlação

Os dados foram inicialmente submetidos a uma análise de *box-plot* para remoção dos valores descritos como outliers. A remoção ocorreu a partir do cálculo do limite superior e inferior do *box-plot* para cada estado (Geórgia, São Paulo e Minas Gerais) e para a união de todos os dados (Global), assim, os valores que ultrapassaram os limites foram removidos. Após a remoção dos valores descritos como outliers foram realizadas as análises prévias. Devido a quantidade de variáveis que foram listadas para compor a entrada das redes do tipo MLP foi realizado a análise de componentes principais (PCA) e análise de correlação de Pearson ( $p < 0,05$ ). Com a análise de PCA é possível identificar as variáveis que possuem maior relação com o PMI e com a correlação identificar a força entre a variável input com o a variável resposta, podendo essa relação ser negativa ou positiva (HOLLAND, 2019; TAYLOR, 1990). Sendo assim, a análise de PCA e a correlação de Pearson são uteis para avaliar as variáveis de entrada na rede e ajudar a selecionar as variáveis que apresentam maior relação com a maturação e diminuir a quantidade de variáveis de entrada para maximizar o desempenho da rede. Dessa forma as duas análises foram realizadas para cada local sem distinção por data de avaliação. Nas regiões que apresentavam mais de uma área, como no caso da Geórgia, EUA e do estado de São Paulo, BR a análise de PCA e correlação não foram divididas por local de avaliação da maturação, portanto contabilizou todas as áreas em uma única análise. Todas as análises descritas nesse paragrafo foram realizadas no software SAS© JMP pro 14 e os gráficos de análise de correlação foram plotados no software Excel.

## 2.6 Perceptron de Multicamadas (MLP)

O tipo de rede neural artificial utilizada no estudo foi a *multilayer perceptron* (MLP). Esse tipo de rede é capaz de resolver problemas lineares e não lineares apenas aprendendo com os dados e generalizando o aprendizado para a situação que é proposta (TAUD; MAS 2017). Sendo assim, para a rede atingir tal capacidade de aprendizado, foi utilizado o treinamento supervisionado em que são apresentadas as variáveis de entrada (*inputs*) e as de saída (*output*).

Como *output* para todos os modelos calibrados foram utilizados os valores de PMI e os *inputs* ou variáveis de entrada foram os parâmetros apresentados nas tabelas 1 e 2, o AGD, a

banda do vermelho (Red) e do infravermelho (NIR). Inicialmente foram inseridos todos os parâmetros de entrada (variáveis climáticas, IVs, AGD, banda do vermelho e do infravermelho), depois foram testadas diferentes combinações entre as variáveis de entrada. A combinação dos *inputs* ocorreu a partir da avaliação da análise sensitiva fornecida pelo software, pela análise de PCA e correlação de Pearson.

A ferramenta utilizada para criação das redes MLP foi a *created network* encontrada no software STATISTICA 7<sup>©</sup> (Statsoft Power Solutions, Inc. na aba Neural Networks). Dentro da ferramenta a rede do tipo MLP foi selecionada. Como padrão foram adotadas duas camadas ocultas para todas as áreas, variando apenas o número de neurônios dentro de cada camada oculta. O número de neurônios foi diferente para cada estado e para o modelo global. No entanto, foi adotado como padrão inicial a raiz quadrada do número de dados totais (N) como um valor inicial para selecionar a quantidade de neurônios para cada camada oculta. Na sequência foi retirado um neurônio de cada camada oculta até chegar na quantidade final de dois neurônios em cada camada oculta. Esse padrão de avaliação da quantidade de neurônios foi realizado para cada combinação e método de treinamento avaliando em cada etapa a acurácia e precisão dos modelos. Além disso, todas as redes criadas apresentavam como saída a função linear.

O próximo passo foi a escolha do método de treinamento. Os métodos utilizados de treinamento foram *Backpropagation* e o Levenberg-marquardt. Selecionado os métodos de treinamento, os algoritmos de treinamento foram aplicados separadamente e em conjunto (fase 1 e fase 2). Quando utilizada a fase 1 e fase 2 em conjunto os parâmetros de cada algoritmo foram configurados separadamente. Na fase 1 era definido o número de épocas e o tipo de treinamento (*Backpropagation* ou Levenberg-marquardt). Quando o número de épocas da fase 1 era terminada, a fase 2 inicializava com outro número de épocas e outro método de treinamento (*Backpropagation* ou Levenberg-marquardt), não utilizando o mesmo método de treinamento da fase 1 na fase 2. O número de época variou entre os modelos calibrados, no entanto, foi adotado como padrão para avaliar o comportamento da rede a quantidade de épocas variando de 500 a 8000 épocas. Dessa forma, para cada combinação de entrada foram testadas diferentes combinações de neurônios na camada oculta, o método de treinamento e o número de épocas.

Além disso, o conjunto de dados de cada área (Minas Gerais, São Paulo e Geórgia) e o modelo global foram divididos em 70% para treinamento, 20% para seleção e 10% para teste. O tamanho do conjunto de dados variou para cada região.

### 2.6.1 Treinamento da rede do tipo Perceptron de Multicamadas (MLP)

A escolha do método de treinamento é importante para o desempenho e agilidade da rede nas suas análises e na sua capacidade de generalização. Dessa forma, foram adotados dois métodos de treinamento *Backpropagation*, Levenberg-Marquardt. Os dois métodos foram escolhidos devido a sua praticidade de treinamento das redes e por apresentarem bons resultados na convergência.

O algoritmo de treinamento Levenberg-Marquardt conhecido como Minimização não linear dos mínimos quadrados é uma modificação do algoritmo de Gauss-Newton, juntamente com o método do gradiente descendente. O método Gauss-Newton utiliza a propriedade das convergências quadráticas. Essa propriedade é capaz de torna-lo rápido na convergência, porém, acaba sendo dependente da escolha dos pesos iniciais que vai afetar nos resultados finais (KERMANI; SCHIFFMAN; NAGLE, 2005).

Por outro lado, o algoritmo do gradiente descendente não depende da escolha dos pesos iniciais e sua velocidade de convergência é baixa, exigindo mais épocas. Além disso, em alguns casos não apresenta resultados satisfatórios com a generalização (KERMANI; SCHIFFMAN; NAGLE, 2005).

Na sua formula do algoritmo de Levenberg-Marquardt é adicionado um novo parâmetro  $\mu$  que garante que a matriz de inversão de Jacobi (J) sempre proceda um resultado. Além disso, quando o erro é aumentado o parâmetro  $\mu$  é multiplicado por um escalar teta e quando o erro diminui é dividido pelo escalar teta (REYNALDI; LUKAS; MARGARETHA, 2012; RANGANATHAN, 2004).

Em outras palavras,  $\mu$  se assemelha a taxa de aprendizado do algoritmo *backpropagation* quando no treinamento é aumentado a função de energia  $\mu$  é multiplicado por uma constante  $\mu_{inc} > 1$  que direciona o algoritmo para o gradiente descendente. Por outro lado, quando uma etapa resulta na diminuição da função de energia  $\mu$  é multiplicado  $\mu_{dec} = 1 / \mu_{inc}$  que direciona o treinamento para o algoritmo de Gauss-Newton (KERMANI; SCHIFFMAN; NAGLE, 2005). Dessa forma, o ajuste dos pesos durante o treinamento é dado por:

$$w_{n-1} = w_{(n)} - (J_{(n)}^T - J_{(n)} + \mu I)^{-1} J_{(n)}^T e_{(n)} \quad (2)$$

O segundo algoritmo utilizado para treinamento das redes MLP foi o *backpropagation*. O algoritmo realiza a correção dos pesos ( $w$ ) das entradas a partir dos valores obtidos na saída, comparando os valores de saída com o desejado. Sendo assim, após o resultado de saída o erro

é retropropagado e os pesos são corrigidos, ocorrendo novamente o treinamento da rede (RUMELHART; HINTON; WILLIAMS, 1986).

Redes que utilizam o algoritmo *backpropagation* como treinamento seguem uma direção negativa do gradiente dos somatórios dos quadrados dos erros em relação as variáveis de peso (REYNALDI; LUKAS; MARGARETHA, 2012). Além disso, dois parâmetros são de grande importância para atualização dos pesos da rede (equação 3), a taxa de aprendizado e o *momentum*.

$$w_{(t+1)} = w_t - \eta \frac{1}{2} \frac{\partial e^t e}{\partial x} \quad (3)$$

Em que,  $\eta$  representa a taxa de aprendizado. Na equação 4 é apresentada a equação de atualização dos pesos com a taxa de aprendizado e o *momentum*.

$$w_{(t+1)} = w_t - \eta \frac{1}{2} \frac{\partial e^t e}{\partial x} + \mu(w_t - w_{(t-1)}) \quad (4)$$

Um dos grandes problemas associados a esses parâmetros (taxa de aprendizado e *momentum*) é o fato de eles não serem tabelados ou apresentarem valores ideais, sendo seus valores dependentes de cada situação. No entanto, via de regra são adotados valores menores do que 0,01 para a taxa de aprendizado e quando seu valor aumentar o *momentum* diminui. Neste trabalho, os valores da taxa de aprendizado e *momentum* inicial e final adotados foram de 0,01 a 0,001 e 0,9 a 0,1, respectivamente.

Nas redes MLP, os vetores de entrada são associados a pesos sinápticos, responsáveis por armazenar os valores das conexões entre os nós (SANTOS et al., 2021b). No entanto, os valores de entrada são normalizados (equação 5). A normalização é um procedimento padrão que ocorre com a finalidade de transforma os dados para uma mesma escala, facilitando o processo de generalização pela rede.

$$y_i = \frac{x_i - x_{max}}{x_{max} + x_{min}} \quad (5)$$

Em que, os valores de  $x_i$  são os valores de entrada e  $x_{max}$  e  $x_{min}$  são os valores máximos e mínimos observados.

Portanto, para o funcionamento do treinamento do algoritmo *backpropagation*, os valores de saída de cada camada de neurônio são relacionados a função  $Y_k = g(U_k)$ . Sendo que  $Y_k$  será os valores de saída, enquanto que  $g$  representa a função de ativação de  $U_k$  e  $U_k$  representa a função sináptica, obtida pelos valores normalizados de entradas e os pesos sinápticos, descritos na equação 6:

$$U_k = \sum_j^i y_j w_{kj} \quad (6)$$

Em que,  $w_{kj}$  são os pesos sinápticos em cada  $y_j$  vetores de entrada com  $k$  neurônios.

No algoritmo de treinamento *backpropagation* diversas são as funções de ativação encontradas. No entanto uma que vem apresentando bons resultados com a maturação é a função tangente da hiperbólica (Equação 7) (SANTOS et al. 2021b; SOUZA et al. 2022).

$$g(U_k) = \frac{e^{U_k} - e^{-U_k}}{e^{U_k} + e^{-U_k}} \quad (7)$$

Em que,  $e$  representa o número Neperiano da função  $U_k$ .

### 2.6.2 Avaliação das redes

Para a avaliação das redes MLP criadas, foram observados os valores a raiz quadrada do erro médio (RMSE) (equação 8) e do erro médio absoluto (MAE) (equação 9) como medidas de acurácia. Além disso, como medida de precisão foi calculado o coeficiente de determinação ( $R^2$ ) (equação 10) entre os valores observados e preditos.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{obs} - y_{est})^2}{n}} \quad (8)$$

Em que, RMSE é a raiz quadrada do erro médio,  $y_{obs}$  é o valor observado,  $y_{est}$  é o valor estimado pelo modelo,  $n$  é o número de dados.

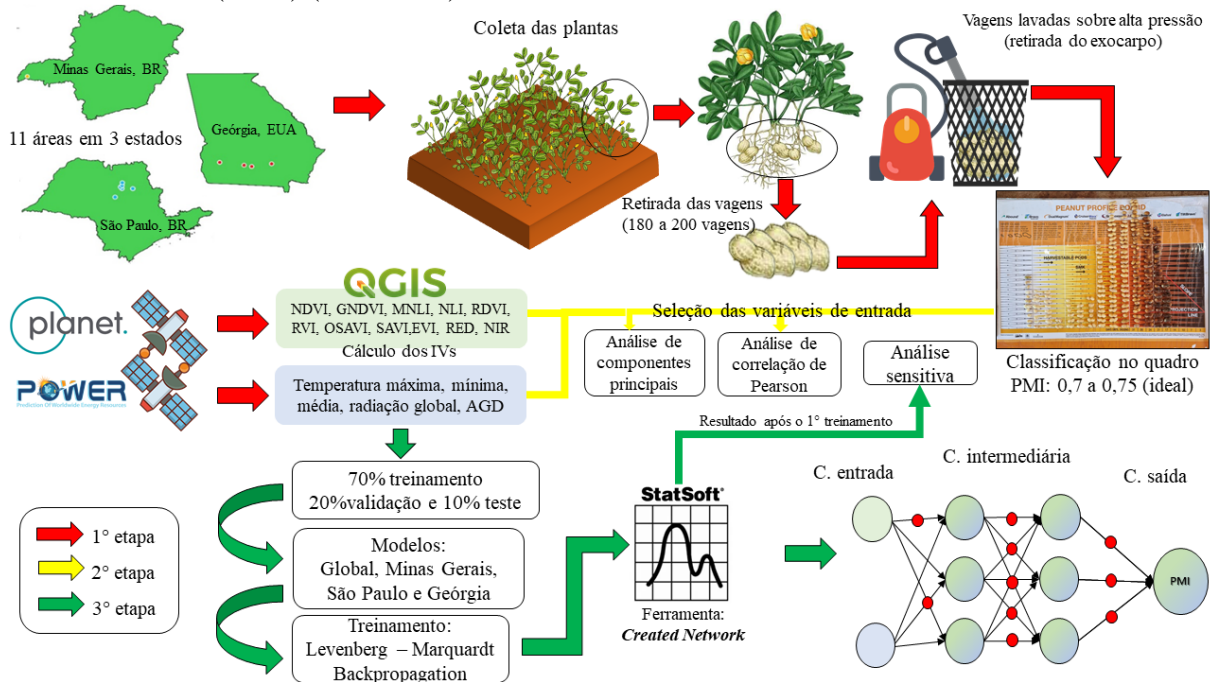
$$MAE = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i) \quad (9)$$

Em que, MAE é o erro absoluto médio,  $n$  é o número de dados,  $Y_i$  é o valor observado no campo,  $\underline{Y_i}$  é o valor estimado pelo modelo.

$$R^2 = \frac{\sum_{i=1}^N (Y_{est_i} - \bar{Y})^2}{(Y_{obs_i} - \bar{Y})^2} \quad (10)$$

Em que,  $Y_{est}$  é o valor estimado e  $Y_{obs}$  é o valor observado  $\bar{Y}$  é a média das observações. De modo geral é possível observar no fluxograma 1 as principais etapas de coleta e análise dos dados, bem como como ocorreu a criação das redes do tipo MLP.

Fluxograma 1 - Etapas realizadas de coleta (seta vermelha), análises prévias dos dados (seta amarela) e calibração das redes neurais do tipo perceptron de multicamadas (MLP) (seta verde).



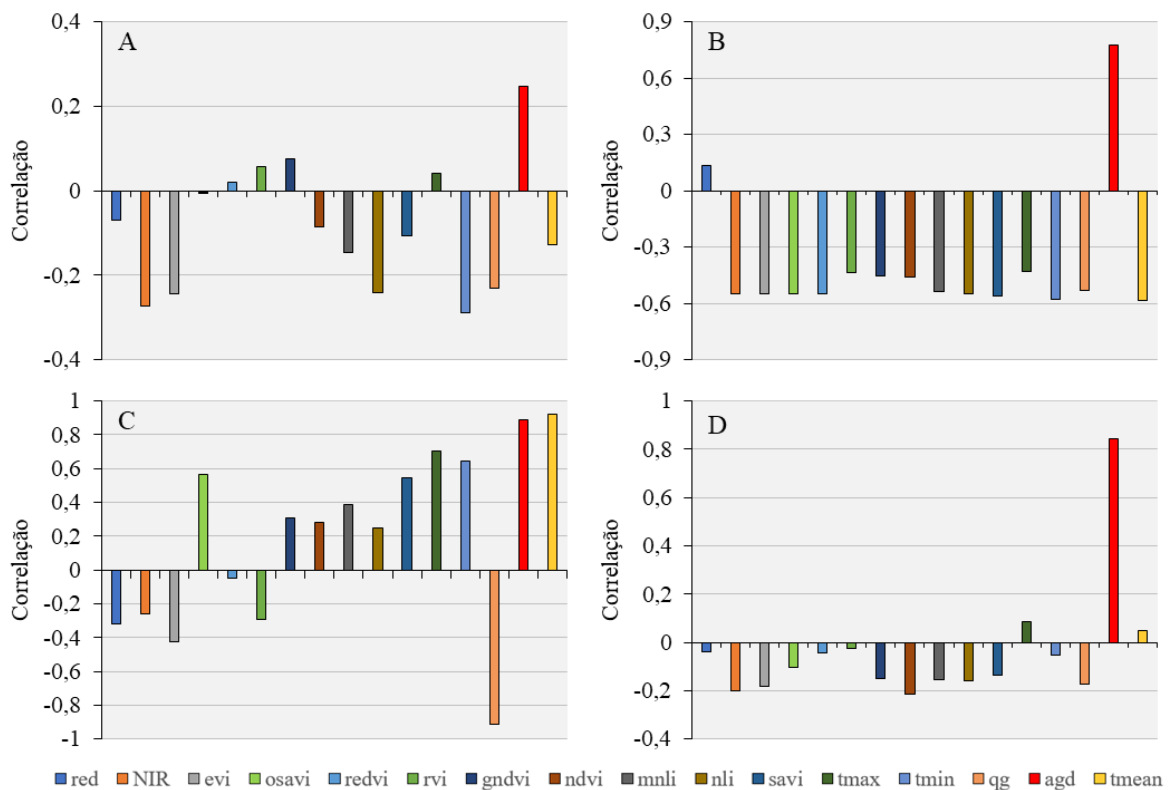
### 3 RESULTADOS E DISCUSSÃO

Os melhores resultados com a correlação de Pearson ( $p < 0,05$ ) foram obtidos para o Estado da Geórgia (Figura 4B), seguido do Estado de Minas Gerais (Figura 4C), todos as áreas ou modelo global (Figura 4A) e São Paulo (Figura 4D). Dentre as variáveis climáticas selecionadas o AGD foi a variável que apresentou os maiores valores de correlação, sendo esses valores positivos em todas as áreas. Além disso, foi observado que para o Qg e tmin a correlação foi negativa, exceto para o estado de Minas Gerais em que a tmin foi positiva (Figura 4C). Tal

fato pode ser atribuído as condições climáticas que são encontradas no local de estudo, visto que em Minas Gerais são encontrados os maiores valores de temperatura média. Além disso, as condições climáticas durante o ciclo da cultura eram favoráveis o que pode levar ao prolongamento do ciclo do amendoim. Diferente do observado nos outros locais em que foi possível observar uma inversão nos valores de correlação.

O amendoim é uma cultura responsiva a temperatura do ar principalmente no desenvolvimento das vagens que varia de 20 – 25 °C. Dessa forma, no cálculo do AGD a temperatura máxima e mínima é inclusa obtendo uma relação positiva entre o AGD e o PMI (ROWLAND et al., 2006; SOUZA et al., 2022) indicando que na medida que a planta acumula graus dias a maturação aumenta. Além disso, a combinação do AGD com os IVs é uma forma de aumentar a precisão e acurácia dos modelos calibrados (SANTOS et al., 2022).

Figura 4 - Análise de correlação de Pearson para os dados utilizados para criação dos modelos de MLP.



Fonte: do autor, 2021. A – União de todos os estados; B – estado da Geórgia, EUA; C – estado de Minas Gerais, Brasil; D – estado de São Paulo, Brasil.

Os índices de vegetação apresentaram baixos valores de correlação quando comparados com as variáveis climáticas. Os menores valores foram observados para a banda do vermelho,



NIR, REDVI, GNDVI E NDVI. Por outro lado, os maiores valores de correlação foram observados para o NLI, MNLI e o EVI.

O NLI é um índice capaz de minimizar os efeitos de brilho do solo e do ângulo foliar (GOEL; QIN, 1994). O MNLI foi proposto como uma melhoria do NLI, contabilizando ainda o fator solo (L) encontrado no SAVI também (GONG et al., 2003). Dessa forma, devido ao fato de minimizarem os efeitos perturbadores do ambiente (dossel, solo, etc.) esses índices apresentam melhores respostas com a maturação do amendoim (PMI). Diferentemente de outros IV que não apresentam correções para os efeitos perturbadores, sendo encontrados problemas até mesmo com a saturação do IV como o NDVI (CARNEIRO et al., 2019).

Além disso, os índices descritos apresentaram correlação negativa, exceto para o estado de Minas Gerais (Figura 4C). Com essa correlação negativa é possível identificar a relação dos IVs com a maturação do amendoim (PMI), em que conforme os valores dos IVs aumentam a maturação diminui. Em outras palavras, esse fenômeno está diretamente relacionado a três fatores biofísicos da planta, os pigmentos foliares, a estrutura das células e o conteúdo de água ou a turgidez das folhas. No mesófilo paliçádico das folhas são encontrados dentro dos cloroplastos os pigmentos foliares. Esses pigmentos foliares são representados por dois de grande importância nas folhas a clorofila *a* e *b*. A clorofila *a* apresenta uma região de absorção de energia eletromagnética de 430 nanômetros (nm)(azul) e 660 nm (vermelho), enquanto que a clorofila *b* apresenta uma região de absorção em 450 nm (azul) e 65 nm (vermelho) (JENSEN, 1983). Quando as plantas estão sobre estresse (hídrico, salino e etc.) ou próximo da maturação fisiológica a produção de clorofila diminui, com isso, são encontradas altas reflectância na região do vermelho, podendo identificar a época de senescência da planta ou potenciais estresses que são encontrados na área de produção (JENSEN, 1983). Além disso, a faixa do NIR de 740 nm a 1100 nm é controlada principalmente pelo mesófilo esponjoso que apresenta espaços de ar intracelulares. Nesses espaços são encontradas as regiões que ocorrem as trocas gasosas do oxigênio e dióxido de carbono o que leva a fotossíntese pela planta e produção de biomassa. Portanto, tal região do espectro eletromagnético (NIR) é alvo de grande estudo no desenvolvimento de técnicas para avaliar a produção de biomassa (JENSEN, 1983). Essa relação encontrada entre as diferentes partes do espectro eletromagnético fica mais evidente quando são combinadas em índices de vegetação o que os torna mais sensível na captação dos diferentes valores de reflectância.

Dessa forma é possível inferir que na medida que o amendoim começa a entrar no processo de maturação a produção de pigmentos foliares especialmente as clorofilas começam a diminuir, assim como, quanto mais próxima do final do ciclo maior é a senescência da planta

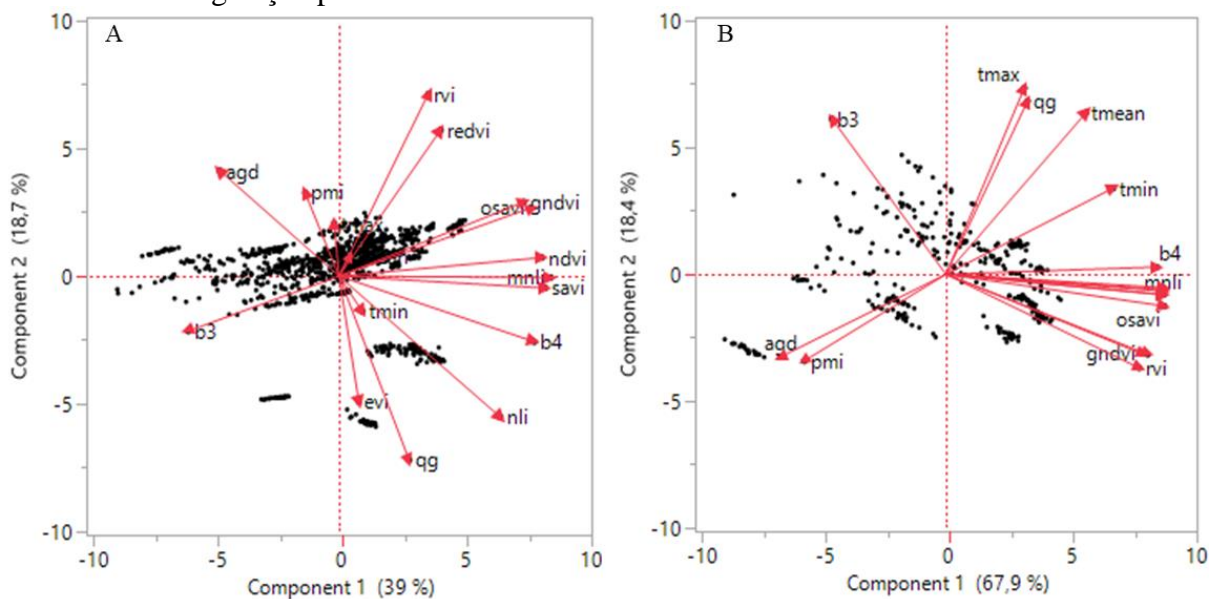
e conseqüentemente é observada a queda nas trocas gasosas e os valores dos IVs começam a diminuir, essa diminuição nos valores dos IVs representa a possível época para início do arranquio do amendoim.

Após a correlação foi realizada a análise de PCA podendo observar quais variáveis apresentaram relação com a maturação. A análise foi capaz de explicar a variabilidade dos dados em 57,7% para todos os Estados (Figura 5A), 86,3% para o Estado da Geórgia (figura 5B), 79,2% para o Estado de Minas Gerais (Figura 5C) e em 69,8% para o estado de São Paulo.

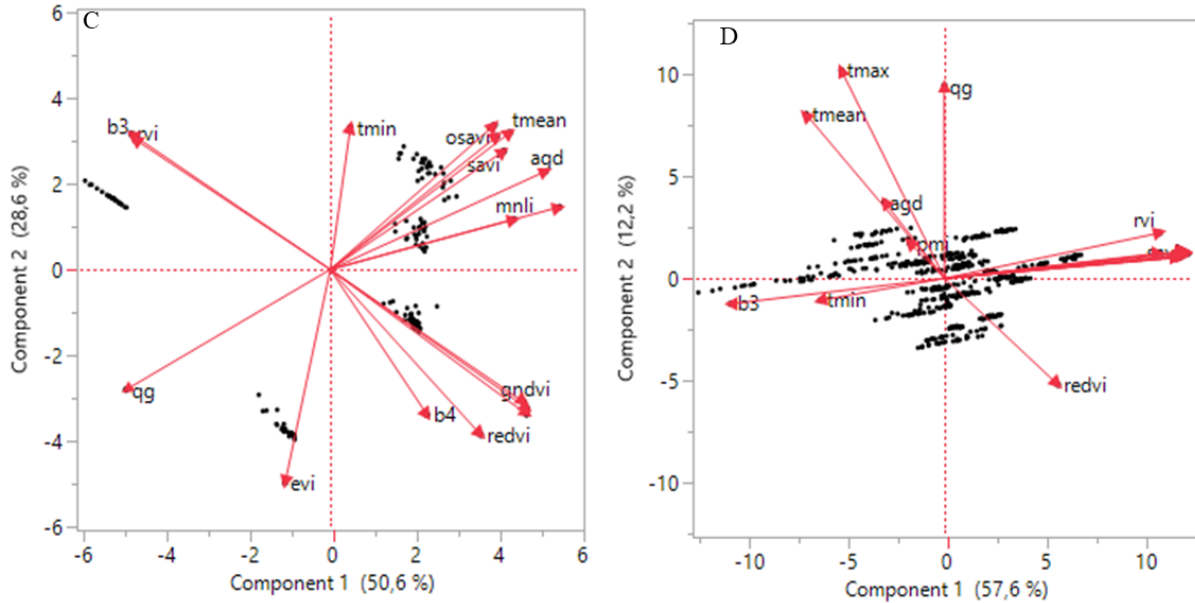
O AGD foi a única variável que apareceu em todas as análises no mesmo sentido do PMI. No estado da Geórgia (Figura 5A) as variáveis climáticas e os índices de vegetação com exceção do AGD ficaram opostos ao PMI. No estado de São Paulo (Figura 5D) a tmax e tmean e em Minas Gerais (Figura 5C) a tmean, tmin, SAVI, OSAVI, MNLIforam as variáveis que apresentaram o mesmo sentido do PMI e AGD. No modelo geral (Figura 5A) a banda do NIR, NLI, Qg, EVI, tmin foram as principais variáveis que estavam opostas ao PMI.

Sendo assim, com a análise de PCA e correlação, juntamente com a análise sensitiva das redes foi possível identificar e selecionar as variáveis que apresentaram maior relação com a maturação. Dessa forma, realizando a combinação das variáveis com o intuito de reduzir a quantidade de entradas e obter valores ideais de precisão e acurácia.

Figura 5 – Análise de componentes principais (PCA) entre as variáveis climáticas e os índices de vegetação para cada modelo calibrado.



Fonte: Do autor, 2023. A – União de todas as áreas (Global); B – estado da Geórgia, EUA.



Fonte: do autor, 2023. C – Estado de Minas Gerais, Brasil; D – Estado de São Paulo, Brasil.

A partir das 16 variáveis de entrada foram testados diversos modelos do tipo MLP na estimativa da maturação. A melhor rede para o estado de Minas Gerais foi obtida com duas camadas ocultas com sete neurônios em cada camada e o método de treinamento Levenberg-Marquardt com oito variáveis de entrada (tabela 4). No Estado de São Paulo (tabela 4) a rede com quatro variáveis de entrada e duas camadas ocultas de nove neurônios cada foi possível estimar a maturação. No Estado da Geórgia (tabela 4) a melhor rede utilizou dois métodos de treinamento, descritos como fase 1 (F1) e fase 2 (F2). Em cada fase é definido o número de épocas, quando o número de épocas na F1 chega ao final o algoritmo troca o método de treinamento e a F2 é iniciada. Neste caso a F1 utilizou o algoritmo *backpropagation* e na F2 o algoritmo Levenberg-Marquardt. Dessa forma é possível melhorar a estimativa do PMI pelo algoritmo de treinamento, conseguindo selecionar uma menor quantidade de variáveis de entrada.

No modelo geral, contendo todos as áreas o método de treinamento que obteve os melhores resultados foi o Levenberg-Marquardt, com duas camadas ocultas de 13 neurônios e três *inputs* (tabela 4). Além disso, em todos as redes calibradas o AGD e o Qg, exceto para São Paulo foram as variáveis mais utilizadas. Apesar disso, foi observado que para cada Estado foram selecionados diferentes IVs, com destaque apenas para o MNLI que apareceu na Geórgia e em São Paulo.

Tabela 4 – Topologia das redes perceptron de multicamadas, variáveis de entrada utilizadas e métodos de treinamento.

Estado	Camadas	Neurônios	Épocas	Treinamento	Inputs <sup>2</sup>
Minas Gerais	2	7:7	2800	Levenberg-marquardt	Red, NIR, NDVI, GNDVI, tmax, tmean, Qg e AGD
Geórgia	2	9:9	500; 500	<i>Backpropagation</i> <sup>1</sup> (F1*), Levenberg-marquardt (F2**)	AGD, Qg e MNLI
São Paulo	2	9:9	500	Levenberg-marquardt	RDVI, MNLI, Tmax e AGD
Global	2	13:13	6000	Levenberg-marquardt	AGD, Qg e NLI

Fonte: do autor, 2023. \*F1 – fase 1 com o uso do algoritmo de treinamento *backpropagation*; \*\*F2 - fase 2 com o uso do algoritmo de treinamento Levenberg-marquardt.<sup>1</sup> taxa de aprendizado inicial e final de 0,009 e 0,01, *momentum* inicial e final de 0,7 a 0,8. <sup>2</sup> variáveis de entrada que apresnetaram os melhores resultados no treinamento.

O melhor método de treinamento utilizado pelos algoritmos foi o Levenberg-Marquardt. Esse método de treinamento é um intermediário que utiliza o método do Gradiente Descendente e o método Gauss-Newton. Por combinar os dois lados positivos de cada método, esse tipo de treinamento acaba sendo eficiente em realizar a convergência. Fato esse que foi observado na comparação entre diferentes métodos de treinamento para estimativa da produção de trigo, em que o Levenberg-marquardt e regularização bayesiana foram mais eficientes (GARG et al., 2016). Por outro lado, uma das limitações desse algoritmo de treinamento é o fato de realizar apenas tarefas de regressão (KERMANI; SCHIFFMAN; NAGLE, 2005), entretanto na predição de frutas e comparando diferentes métodos de treinamento resultados similares de precisão foram encontrados quando comparado com o Backpropagation (KHAN et al., 2020).

O que pode levar a valores acurados e precisos na estimativa da maturação pelos modelos são as variáveis de entrada utilizadas. Sendo assim, umas das formas de reduzir a subjetividade do quadro de maturação é utilizar IVs para o mapeamento da variabilidade da área (SANTOS et al., 2021). Além disso, quando as variáveis climáticas são incluídas ao modelo melhor é a simulação do efeito do clima na maturação. Visto que altas temperaturas podem acelerar o ciclo da cultura, diminuindo a área foliar, biomassa e acelerando a maturação (ZHANG et al., 2022).

Um dos fatores que levou a diferenciação entre os IVs foi a época de avaliação da maturação. No Estado de Minas Gerais a maturação começou a ser avaliadas aos 85 dias após a semeadura, finalizando aos 118 dias após a semeadura, ou seja, mesmo na última data de avaliação os IVs apresentavam altos valores (dados não apresentados). Esses altos valores dos

índices são associados ao alto acumulado de biomassa que é captado pelo cálculo dos IVs (CARNEIRO et al., 2019; QI et al., 2020; SANTOS et al., 2021; SOUZA et al., 2022)

No Estado de São Paulo, mesmo apresentando a correlação negativa entre os IVs e o PMI, os valores da correlação ainda eram baixos. Por outro lado, o Estado da Geórgia foi o que apresentou os melhores resultados de correlação, conseqüentemente com o melhor modelo para a estimativa da maturação. Nesse sentido, podendo levar ao prolongamento do ciclo da cultura devido as condições climáticas encontradas nas áreas principalmente com a boa disponibilidade de água e temperaturas ideais durante o cultivo. Além disso, no estado da Geórgia foram utilizadas cultivar que apresenta um ciclo maior do que as encontradas no Brasil o que fica evidente também pelo AGD. Como a cultivar de amendoim semeada nos estados do Brasil é mais precoce (OL3) tem se a necessidade de realizar mais avaliações da maturação das vagens afim de encontrar o momento ideal de arranquio. Visto que a correlação positiva indica que aquela época ainda não era o momento ideal para a realização do processo mecanizado de arranquio. Santos et al. (2021b) verificou isso a partir do uso do modelo de Gompertz, no momento em que ocorre o declínio dos valores dos IVs associados ao início da senescência da planta a maturação está próxima do ideal e é possível realizar o arranquio do amendoim. Carneiro et al. (2019) pode constatar que a queda nos valores dos índices de vegetação nas cartas de controle indica o início do processo de senescência da planta de amendoim.

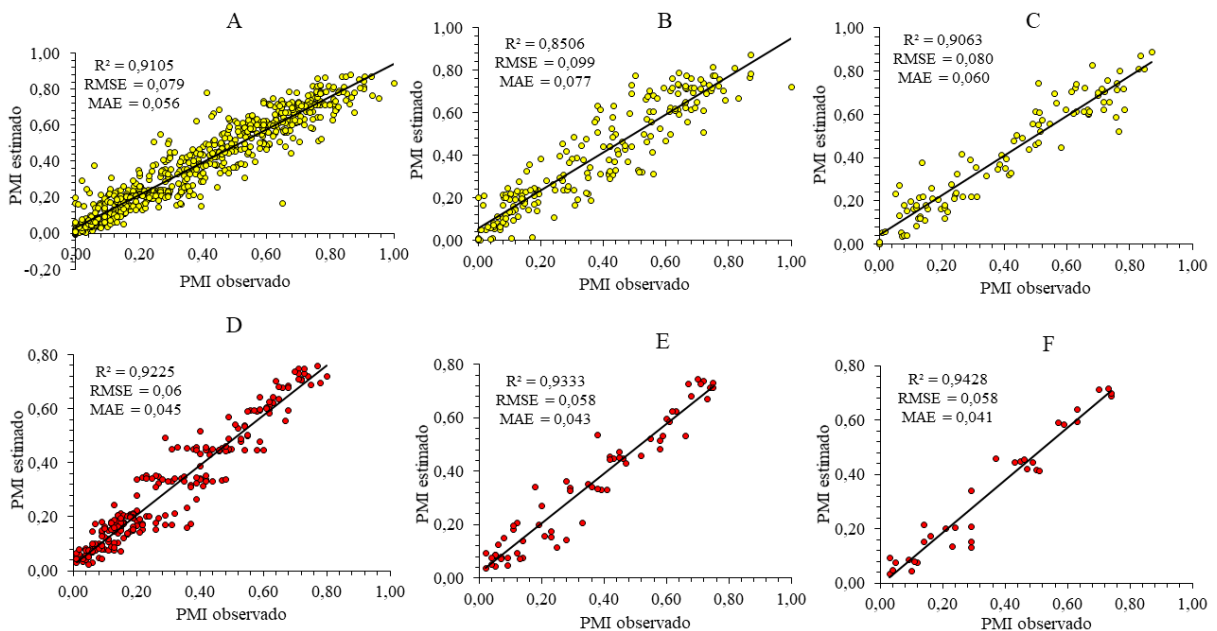
No entanto determinar uma época específica ainda é um dos problemas enfrentados principalmente pelo fato do amendoim apresenta hábito de crescimento indeterminado e o seu ciclo ser influenciado pelas condições da área (SANTOS et al., 2021b). Contudo, a alta capacidade dos IVs em captar a variabilidade das áreas, está associado as bandas do NIR e do vermelho que são utilizadas na sua fórmula. Essas duas bandas espectrais interagem com os pigmentos foliares e o conteúdo celular (JENSEN, 2011). Dessa forma quando a planta está estressada os valores de reflectância entre as fórmulas se alteram e isso é refletivo nos valores do IVs. Portanto, quanto maior os valores de reflectância do NIR e menor o do vermelho, maiores são os valores dos IVs, indicando a fotossíntese pela planta e acúmulo de biomassa (JENSEN, 2011).

Essa variação nos valores dos IVs foi observada por Carneiro et al. (2019) em que no início do estágio reprodutivo (R1) são encontrados altos valores de biomassa e baixos de maturação e ao final do ciclo ocorre queda dos valores de biomassa e aumento dos valores de maturação. Portanto, o uso dos índices de vegetação são fortes indicativos de escolha da época de arranquio do amendoim.

Associado aos IVs, a radiação é outro parâmetro que afeta diretamente a fotossíntese pela cultura. A baixa irradiância que chega na cultura leva ao prolongamento do estágio vegetativo e consequentemente encurtando o estágio reprodutivo afetando a produtividade e diminuindo a matéria seca das plantas (SINGH, 2004; RAO; MITTRA, 1988). Além disso, a uma relação direta entre a radiação solar e a temperatura, isto é, na medida que a radiação solar aumenta a temperatura também aumenta.

Nas Figuras 6 e 7 são apresentados os resultados dos modelos calibrados para cada estado e o global, divididos em treinamento, seleção e teste. Para cada etapa do treinamento do modelo os dados foram divididos em 70% para treinamento, 20% para seleção e 10% para o teste. Dentre os modelos calibrados, o modelo para o Estado da Geórgia (Figura 6D, E e F) foi o que apresentou os melhores ajustes de  $R^2$ , RMSE e MAE para o treinamento, seleção e teste.

Figura 6 - Gráfico entre os valores observados e preditos do treinamento, seleção e teste de cada modelo da rede MLP calibrado.

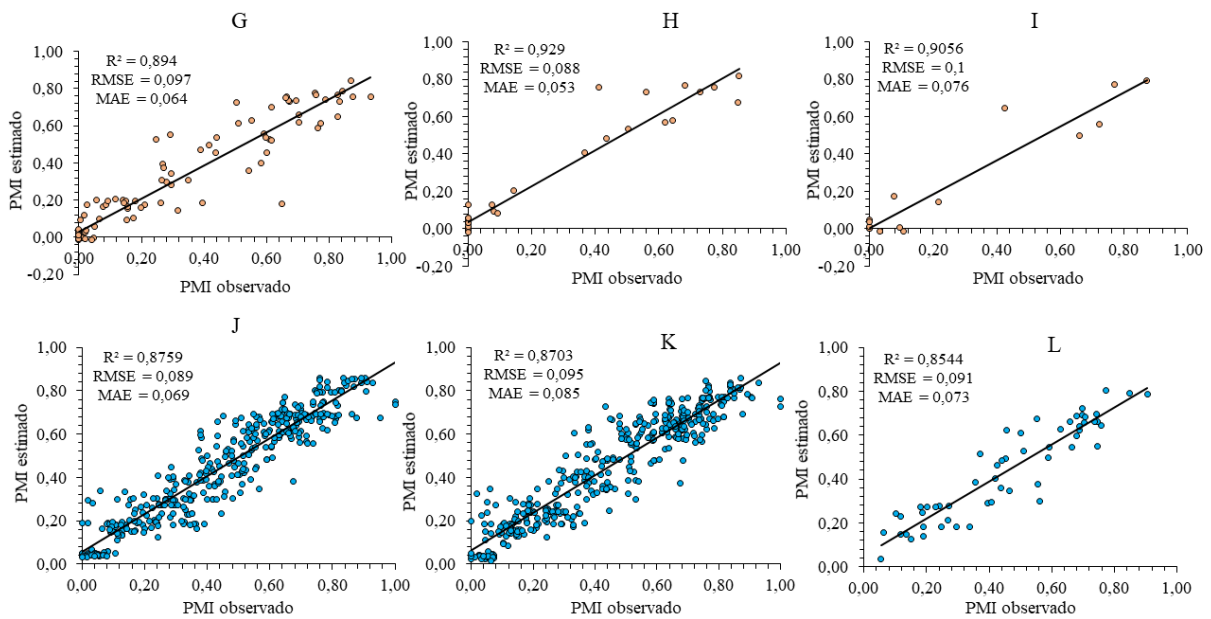


Fonte: Do autor, 2023. A, B e C – treinamento, seleção e teste do modelo com todos os estados; D, E e F - treinamento, seleção e teste do modelo calibrado para o estado da Geórgia.

Nos demais modelos é possível observar pouca variação entre o melhor modelo (Geórgia) e os demais modelos nos valores de precisão ( $R^2$ ). No Estado de Minas Gerais (Figura 7G, H e I) e no modelo Global (figura 6A, B e C) houve uma redução de 4% no valor de  $R^2$  para o teste, enquanto que para o Estado de São Paulo (figura 7J, K e L) foi observada queda 9,4% nos valores de teste em comparação ao valor de  $R^2$  de 0,943 do estado da Geórgia (Figura 6D, E e F). Apesar da redução nos valores de precisão a utilização de dados climáticos e índices

de vegetação obtidos de forma remota foram satisfatórios, uma vez que a estimativa de maturação de amendoim utilizando o modelo SAFER (*Simple Algorithm for Evapotranspiration Retrieving*) e dados de estações meteorológicas de superfície para o cálculo da evapotranspiração e PMI do amendoim com a finalidade de encontrar o momento ideal de arranquio das plantas foram obtidos valores de  $R^2$  máximo de 0,748 (ALMEIDA et al., 2023).

Figura 7 - Gráfico entre os valores observados e preditos do treinamento, seleção e teste de cada modelo da rede MLP calibrado.



Fonte: do autor, 2023. G, H e I - treinamento, seleção e teste do modelo calibrado para o estado de Minas Gerais; J, K e L - treinamento, seleção e teste do modelo calibrado para o estado de São Paulo.

Além da precisão é importante destacar a acurácia entre os modelos, sendo que os menores valores de erro RMSE foram encontrados para a Geórgia (Figuras 6D, E e F) seguido de Global (Figuras 6A, B e C), São Paulo (Figuras 7D, E e F) e Minas Gerais (Figuras 7A, B e C). Os maiores erros foram de 0,1 quando o modelo utilizou as entradas banda espectral do vermelho, NIR, NDVI, GNDVI, tmax, tmean, Qg e AGD no estado de Minas Gerais na etapa de teste. Por outro lado, no estado de São Paulo o maior erro foi de 0,091 na mesma etapa. Os valores de erro máximo encontrados neste trabalho são menores ou igual a 10%, isso independente dos parâmetros de entrada, método de treinamento e os locais.

No entanto, a utilização de plataformas remotas de monitoramento global são ferramentas que apresentam um bom desempenho na estimativa da maturação de amendoim. Visto que em outros estudos utilizando IVs obtidos por imagens de drones na estimativa da maturação de amendoim, os valores máximos encontrados com o erro (RMSE) variam entre

6,3% e 9,4% para o teste (SANTOS et al., 2022; OLIVEIRA et al., 2019) podendo chegar a 22% de erro (MAE) (SOUZA et al., 2022). Além disso, quando combinados os IVs obtidos por imagens de satélite com algoritmos de MLP a máxima acurácia (MAE) encontrada foi de 12% (SOUZA et al., 2022). Sendo assim, as plataformas remotas se destacam principalmente pela facilidade de acesso e coleta de dados. Além disso, o fato de incluir os dados climáticos aumenta a capacidade dos modelos em estimar a maturação de amendoim, visto a grande influência das variáveis climáticas na cultura do amendoim.

Dessa forma, a utilização de plataformas online e gratuita de coleta de dados climáticos e imagens de alta resolução de satélite são alternativas para estimar o PMI. Nesse sentido, países que não dispõem de uma rede de estações meteorológicas ou sensores de coleta a nível terrestre podem optar pela utilização das plataformas remotas como a NASA-POWER e associar esses dados com índices de vegetação obtidos de plataformas orbitais.

Outro fato que justifica o desempenho dos modelos na estimativa da maturação de amendoim está no número de amostras coletados e na correlação das variáveis de interesse. Por mais que o número de amostras seja pequeno a correlação das variáveis com a maturação das vagens de amendoim é um parâmetro chave para a boa convergência do algoritmo (MEHROTRA; MOHAN; RANKA, 1991). Outro ponto que merece destaque são os problemas de *overtting* que podem ser encontrados quando são observadas baixas quantidades de amostras. No entanto, neste trabalho é possível observar resultados similares de precisão e acurácia entre o treinamento, seleção e teste dos modelos para cada estado e para o modelo Global. Esse fato demonstra que os modelos calibrados não apresentaram *overfitting* mesmo com baixo número de amostras.

Dessa forma, mesmo com um alto número de amostras como no modelo Global, a correlação entre as variáveis e a variabilidade dos índices são fatores que devem ser levados em conta para a melhoria dos valores de acurácia e precisão dos modelos. O que fica evidenciado pelo modelo criado para a Geórgia em que bons ajustes foram encontrados a partir da grande variação entre os IVs durante as épocas de coleta de maturação, principalmente para o MNLI que variou de 0,58 a 0,06 entre a primeira e a última data de coleta da maturação no campo. Essa variabilidade é observada também quando são aplicados modelos de crescimento na avaliação da maturação, no momento em que ocorre queda dos valores do IVs a planta começa a entrar em senescência, sendo esse o momento de iniciar o arranquio (SANTOS et al., 2021b).

Apesar disso diversos outros fatores podem afetar a maturação das vagens e o ciclo de desenvolvimento da cultura, em especial o tipo de solo e a época de semeadura. Solos arenosos possuem maior aeração com menor resistência do ginóforo a penetração, conseqüentemente



menor é a retenção de água. Já os solos argilosos maior é a retenção de água e maior é a sua fertilidade, porém as exigências são altas na sua estruturação visto que podem dificultar a penetração do ginóforo (NETO; COSTA; CASTRO, 2012). Dessa forma, em solos de textura arenosa e sob condições ideais de precipitação e temperatura podem propiciar um melhor desenvolvimento na cultura.

Essa influência do solo no desenvolvimento e maturação das vagens também foi observado por Almeida et al. (2023) em que o baixo desempenho do modelo SAFER pode ter sido influenciado pelas condições de solo da área de estudo. Nesse sentido, o mesmo pode ser observado entre o estado de Minas Gerais e o de São Paulo, visto que são regiões em que os solos apresentam modificações na sua textura. Além disso essas condições da área enfatizam a grande subjetividade do método tradicional em avaliar a maturação do amendoim. Durante a calibração dos algoritmos tais características não são diferenciadas, o que pode levar a diminuição dos parâmetros de acurácia e precisão do modelo.

Apesar do uso de variáveis climáticas e IVs neste trabalho, em trabalhos futuros a inclusão ou diferenciação das regiões de acordo com o tipo de solo podem obter maiores respostas com a maturação a partir da aplicação de redes neurais artificiais. Dessa forma, é possível realizar o agrupamento de regiões similares quanto a textura de solo e realizar a estimativa da maturação com maior acurácia e precisão. Assim, os modelos calibrados são capazes de ajudar os produtores, extensionistas e pesquisadores na determinação da melhor época de avaliação da maturação, diminuindo as perdas no campo e aumentando a qualidade dos grãos colhidos. No entanto, são necessários estudos para avaliar a influência outros genótipos de amendoim na maturação das vagens.

#### **4 CONCLUSÃO**

A aplicação de índices de vegetação e as variáveis climáticas conjuntamente foram eficientes na criação dos modelos de redes neurais artificiais do tipo MLP para os diferentes locais. Dentre os resultados o modelo criado para o Estado da Geórgia apresentou os melhores ajuste de acurácia  $RMSE = 0,058$ ,  $MAE = 0,041$  e precisão  $R^2 = 0,943$  para o teste, seguido do modelo global com  $R^2$  de  $0,906$ ,  $RMSE = 0,080$  e  $MAE = 0,060$ , modelo para Minas Gerais com  $R^2$  de  $0,906$ ,  $RMSE = 0,1$  e  $MAE = 0,076$  e o modelo para o estado de São Paulo com  $R^2$  de  $0,854$ ,  $RMSE = 0,091$  e  $MAE = 0,073$ .

Por outro lado, com o modelo geral foram obtidos resultados satisfatórios na estimativa da maturação descritos pelos valores de precisão e acurácia. Com o modelo global é possível

estimar a maturação da cultura em qualquer local de produção e eliminando a subjetividade do método tradicional de avaliação da maturação do amendoim.

## **CONSIDERAÇÕES FINAIS**

A partir do estudo foi possível observar e avaliar as plataformas orbitais NASA-POWER e PlanetScope. Ambas as plataformas são utilizadas para finalidades diferentes, na plataforma NASA-POWER é possível realizar a coleta de diversas variáveis climáticas do globo terrestre de, enquanto que a PlanetScope é capaz de fornecer imagens com alta resolução espacial (3 x 3 metros) do globo terrestre diariamente. Ambas as plataformas são orbitais e são ferramentas úteis para serem cada vez mais utilizadas na pesquisa e por produtor rurais no monitoramento das condições das lavouras.

Neste estudo, foi possível observar que a plataforma NASA-POWER apresenta uma boa relação em estimar as variáveis climáticas Temperatura máxima, mínima e média, radiação solar e pressão de superfície. Por outro lado, outras variáveis como umidade relativa e velocidade do vento os modelos matemáticos não são acurados e precisos, demonstrando a necessidade de calibração dos modelos para a estimativa desses parâmetros climáticos. Apesar disso, a plataforma é de livre acesso o que permite obter informações sobre as demais variáveis em qualquer lugar do globo terrestre. Visto que em certos países não são encontradas redes de estações meteorológicas que realizam a coleta das informações, o que pode ser substituída eventualmente pela plataforma NASA-POWER. Em relação a cultura do amendoim, foi possível observar que a temperatura é descrita como um dos principais fatores que afetam seu ciclo de produção. Tal variável pode ser monitorada a partir da plataforma com boa acurácia e precisão, além de ser empregada para o cálculo do acumulado de graus dias que apresenta boa relação com a maturação do amendoim.

Quando os dados climáticos foram incluídos com os índices de vegetação obtidos pela plataforma PlanetScope foi possível analisar mais precisamente a influências desses fatores na maturação do amendoim. Essa análise realizada pela rede neural artificial do tipo perceptron de multilaminadas (MLP) demonstrou que é possível estimar a maturação com acurácia e precisão especialmente para o estado da Geórgia que apresentou os melhores resultados. Além disso, utilizar dados de plataformas orbitais incluídos a modelos de redes neurais artificiais é uma forma de melhorar a forma de avaliação da maturação frente ao método tradicional e diminuir as perdas no campo.

## REFERÊNCIAS

- ABRAHAM, E. R. et al. Time series prediction with artificial neural networks: an analysis using Brazilian soybean production. **Agriculture MDPI**, v. 10, n. 10, 2020. Doi: <https://doi.org/10.3390/agriculture10100475>
- ALMEIDA, S. L. H. *et al.* Performance of the SAFER model in estimating peanut maturation. **European Journal of Agronomy**, v. 147, 2023. Doi: <https://doi.org/10.1016/j.eja.2023.126844>
- ALVAREZ, C. L.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALES, J. L. M.; SPAROVEK, G. Koppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711 – 728, 2014. Doi: <http://dx.doi.org/10.1127/0941-2948/2013/0507>
- BAGNALL, D. J.; KING, R. W. Response of peanut (*Arachis hypogaea*) to temperature, photoperiod and irradiance 1. Effect on flowering. **Field Crops Research**, v. 26, p. 263 – 277. DOI: [https://doi.org/10.1016/0378-4290\(91\)90004-F](https://doi.org/10.1016/0378-4290(91)90004-F)
- BOOTE, J. K. Growth stages of peanut (*Arachis hypogaea* L). **Peanut Science**, v. 9, p. 35 – 40, 1982. Doi: <https://doi.org/10.3146/i0095-3679-9-1-11>
- BRANCH, W. D. (2007). Registration of 'Georgia-06G' peanut. **Journal of Plant Registration**, v. 1, p. 120 – 120. 2007. <https://doi.org/10.3198/jpr2006.12.0812crc>
- CARNEIRO, F. M.; FURLANI, C. E.; ZERBATO, C.; MENEZES, P. C.; GÍRIO, L. A. S. Correlations among vegetation indices and peanut traits during different crop development stages. **Engenharia Agrícola**, v. 39, p. 33 – 40, 2019. Doi: <https://doi.org/10.1590/1809-4430-Eng.Agric.v39nep33-40/2019>
- GARG, B.; KIRAR, N.; MENON, S.; SAH, T. A performance comparison of different back propagation neural networks methods for forecasting wheat production. **CSI Transactions on ICT**, v. 4, p. 305 – 311, 2016. Doi: [10.1007/s40012-016-0096-x](https://doi.org/10.1007/s40012-016-0096-x)
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289 – 298, 1996. Doi: [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- GODOY, I. J. *et al.* Cultivares de amendoim oleicos: uma inovação para o mercado produtor e consumidor brasileiro. **Boletim Técnico, IAC**, v. 70, 2018. Disponível em: <http://oagronomico.iac.sp.gov.br/?p=1148>
- GOEL, N.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. **Environmental Science, Mathematics**, 1994. Doi: <https://doi.org/10.1080/02757259409532252>
- GONG, P.; PU, R.; BIGING, G. S.; LARRIEU, M. R. Estimation of forest leaf area index using vegetation indices derived from Hyperion Hyperspectral data. **IEEE transactions on geoscience and remote sensing**, v. 41, n. 6, 2003. Doi: <https://doi.org/10.1109/TGRS.2003.812910>

HOLLAND, S. M. Principal Components Analysis (PCA). **University of Georgia**, 2019. Disponível em: <http://strata.uga.edu/software/pdf/pcaTutorial.pdf>

HUETE, A. R. Soil-adjusted vegetation index. **Remote Sensing of Environment**, v. 25, n. 3, p. 295 – 309, 1988. Doi: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440 – 451, 1997. Doi: [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)

JENSEN, J. R. Biophysical remote sensing. **Annals of the association of American Geographers**, v. 73, n. 1, p. 111 – 132, 1983. Doi: <https://doi.org/10.1111/j.1467-8306.1983.tb01399.x>

JENSEN, J. R. Sensoriamento remoto da vegetação. In: Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Parênteses editora, capítulo 11, 2011.

KERMANI, B. G.; SCHIFFMAN, S. S.; NAGLE, H. T. Performance of the Levenberg–Marquardt neural network training method in electronic nose applications. **Sensors and actuators B**, v. 110, p. 13 – 22, 2005. Doi: [10.1016/j.snb.2005.01.008](https://doi.org/10.1016/j.snb.2005.01.008)

KHAN, T.; QIU, J.; ALI QURESHI, M.A.; IQBAL, M.S.; MEHMOOD, R.; HUSSAIN, W. Agricultural Fruit Prediction Using Deep Neural Networks. **Procedia Comput. Sci.** v. 174, p. 72–78, 2020. <https://doi.org/10.1016/j.procs.2020.06.058>

MAJOR, D. J.; BARET, F.; GUYOT, G. A ratio vegetation index adjusted for soil brightness. **International Journal of Remote Sensing**, v. 11, n. 5, 1990. Doi: <https://doi.org/10.1080/01431169008955053>

MEHROTRA, K. G.; MOHAN, C. K.; RANKA, S. Bounds on the number of samples needed for neural learning. College of Engineering and Computer Science, 1991. Doi: <https://doi.org/10.1109/72.97932>

FERRARI NETO, J. F.; COSTA, C. H. M.; CASTRO, G. S. A. Ecofisiologia do amendoim. *Scientia Agraria Paranaensis*, v. 11, n. 4, p. 1 -13, 2012. Doi: <https://doi.org/10.18188/sap.v11i4.6033>

OLIVEIRA, M. F.; SANTOS, A. F.; LACERDA, L. N.; SILVA, R. P.; VELLIDIS, G. Estimativa da maturação de amendoim utilizando sensoriamento remoto e redes neurais artificiais. **Anais do XVII encontro sobre a cultura do amendoim**, v. 3, 2019. Doi: [10.17648/amendoim-2019-107243](https://doi.org/10.17648/amendoim-2019-107243)

ONO, Y. Flowering and fruiting of peanut plants. **Japan Agricultural Research Quarterly**, v. 13, n. 4, 1979. Disponível em: [https://www.jircas.go.jp/sites/default/files/publication/jarq/13-4-226-229\\_0.pdf](https://www.jircas.go.jp/sites/default/files/publication/jarq/13-4-226-229_0.pdf)

PLANET. Constellation and sensor overview. PLANET developers, 2023. Disponível em: <https://developers.planet.com/docs/data/planetscope/#:~:text=PlanetScope%2C%20operated%20by%20Planet%2C%20is,3%20meters%20per%20pixel%20resolution.>

QI, H. *et al.* Estimation of Peanut Leaf Area Index from Unmanned Aerial Vehicle Multispectral Images. **Sensors**, v. 20, n. 23, 2020. Doi: <https://doi.org/10.3390/s20236732>

RANGANATHAN, A. The Levenberg-marquardt algorithm. **Tutorial on LM algorithm**, v. 11, n. 1, p. 101 – 110, 2004. Disponível em: [https://sites.cs.ucsb.edu/~yfwang/courses/cs290i\\_mvlg/pdf/LMA.pdf](https://sites.cs.ucsb.edu/~yfwang/courses/cs290i_mvlg/pdf/LMA.pdf)

RAO, L. J. MITTRA, B. N. Growth and yield of peanut as influenced by degree and duration of shading. **Journal Agronomy & Crop Science**, v. 160, p. 206 – 265, 1988. Doi: <https://doi.org/10.1111/j.1439-037X.1988.tb00327.x>

REYNALDI, A.; LUKAS, S.; MARGARETHA, H. Backpropagation and Levenberg-marquardt algorithm for training finite element neural network. **UKSim-AMSS 6<sup>TH</sup> European Modelling Symposium**, 2012. Doi: 10.1109/EMS.2012.56

RONDEAUX, G.; STEVEN, M. D.; FREDERIC, B. Optimization of soil-adjusted vegetation index. **Remote Sensing of Environment**, v. 55, n. 2, p. 95 – 107, 1996. Doi: [http://dx.doi.org/10.1016/0034-4257\(95\)00186-7](http://dx.doi.org/10.1016/0034-4257(95)00186-7)

ROUJEAN, J.; BREON, F. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote Sensing of Environment**, v. 51, n. 2, p. 375 – 384, 1995. Doi: [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)

ROUSE, J. W.; HASS, R. H.; SHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **NASA**, v. 1, 1974. Disponível em: <https://ntrs.nasa.gov/citations/19740022592>

ROWLAND, D. L. *et al.* Determination of Maturity and Degree Day Indices and their Success in Predicting Peanut Maturity. **Peanut Science**, p. 125–136, 2006. DOI: [https://doi.org/10.3146/0095-3679\(2006\)33\[125:DOMADD\]2.0.CO;2](https://doi.org/10.3146/0095-3679(2006)33[125:DOMADD]2.0.CO;2)

SANTOS, A. F. *et al.* Using uav and multispectral images to estimate peanut maturity variability on irrigated and rainfed fields applying linear models and artificial neural networks. **Remote sensing**, v. 14, n. 93, 2021b. DOI: <https://doi.org/10.3390/rs14010093>

SANTOS, A. F.; SILVA, R. P.; ZERBATO, C.; MENEZES, P. C.; KAZAMA, E. H.; PAIXÃO, C. S. S.; VOLTARELLI, M. A. Use of real-time extend GNSS for planting and inverting peanuts. **Precision Agriculture**, 20, p. 840 - 856, 2019. DOI: <https://doi.org/10.1007/s11119-018-9616-z>

SINGH, A. L. Growth and Physiology of Groundnut. **Groundnut Research in India National Research Center for Groundnut (ICAR)**, p. 1 - 35, 2004. Disponível em: [https://www.researchgate.net/profile/Amrit-Singh-2/publication/284027853\\_Growth\\_and\\_physiology\\_of\\_Groundnut/links/57726f8408aeec38953e0be/Growth-and-physiology-of-Groundnut.pdf](https://www.researchgate.net/profile/Amrit-Singh-2/publication/284027853_Growth_and_physiology_of_Groundnut/links/57726f8408aeec38953e0be/Growth-and-physiology-of-Groundnut.pdf)

SOOD, A.; KUMAR, R. S.; KUMAR, A. S. Artificial intelligence research in agriculture: a review. **Online information review: artificial intelligence in agriculture**, p. 01–22, 2021. DOI: <https://doi.org/10.1108/OIR-10-2020-0448>

SOUZA, J. C. B.; ALMEIDA, S. L. H.; OLIVEIRA, M. F.; SANTOS, A. F.; FILHO, A. L. B.; MENESES, M. D.; SILVA, R. P. Integrating satellite and UAV data to predict peanut maturity upon artificial neural networks. **Agronomy MDPI**, v. 12, p. 1 – 15, 2022. DOI: <https://doi.org/10.3390/agronomy12071512>

STACKHOUSE, P. JR. NASA POWER: data sources. **NASA POWER docs**, 2021. Disponível em: <https://power.larc.nasa.gov/docs/methodology/data/sources/>

TAUD, H.; MAS, J. F.; Multilayer Perceptron (MLP). **Geoinformation and Cartography**, p. 451 – 455, 2017. Doi: [10.1007/978-3-319-60801-3\\_27](https://doi.org/10.1007/978-3-319-60801-3_27)

TAYLOR, R. Interpretation of the correlation coefficient: a basic review. **JDMS**, v. 1, p. 35 – 39, 1990. Doi: <https://doi.org/10.1177/875647939000600106>

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Peanut explorer. USDA, 2023. Disponível em: <https://ipad.fas.usda.gov/cropexplorer/cropview/commodityView.aspx?cropid=2221000>

WILLIAMS, E. J.; DREXLER, J. S. A Non-Destructive Method for Determining Peanut Pod Maturity. **Peanut Science**, v. 8, n. 2, p. 134–141, jul. 1981. DOI: <https://doi.org/10.3146/i0095-3679-8-2-15>

XU, L.; CAO, B.; NING, S.; ZHANG, W.; ZHAO, F. Peanut leaf disease identification with deep learning algorithms. **Molecular breeding**, v. 43, n. 25, 2023. Doi: <https://doi.org/10.1007/s11032-023-01370-8>

ZHANG, G.; LECLERC, M. Y.; SINGH, N.; TUBBS, R. S.; MONFORT, W. S. Impact of planting date on CO<sub>2</sub> fluxes, evapotranspiration and water-use efficiency in peanut using the eddy-covariance technique. **Agricultural and Forest Meteorology**, v. 326, 2022. Doi: <https://doi.org/10.1016/j.agrformet.2022.109163>