

UNIVERSIDADE ESTADUAL DE GOIÁS
CÂMPUS CENTRAL
ANÁPOLIS DE CIÊNCIAS EXATAS E TECNOLÓGICAS HENRIQUE SANTILLO
MESTRADO STRICTO SENSU EM ENGENHARIA AGRÍCOLA

SABRINA DIAS DE OLIVEIRA

**ESTIMATIVA DA NECESSIDADE DE FÓSFORO E POTÁSSIO PARA O TOMATE
INDUSTRIAL UTILIZANDO REDES NEURAIS ARTIFICIAIS**

ANÁPOLIS- GO
2022

SABRINA DIAS DE OLIVEIRA

ESTIMATIVA DA NECESSIDADE DE FÓSFORO E POTÁSSIO PARA O TOMATE INDUSTRIAL UTILIZANDO REDES NEURAIS ARTIFICIAIS

Dissertação apresentada à Universidade Estadual de Goiás-UEG, Unidade Universitária de Ciências Exatas e Tecnológicas de Anápolis como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola – Engenharia de Sistemas Agroindustriais, para obtenção do título de MESTRE.
Orientadora: Profa. Dra. Sueli Martins De Freitas Alves.

ANÁPOLIS – GO
2022



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DE TESES E DISSERTAÇÕES NA BIBLIOTECA DIGITAL (BDTD)

Na qualidade de titular dos direitos de autor, autorizo a Universidade Estadual de Goiás a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UEG), regulamentada pela Resolução, **CsA n.1087/2019** sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

Dados do autor (a)

Nome Completo: Sabrina Dias de Oliveira
E-mail: sabrina9632oliveira@gmail.com

Dados do trabalho

Título: Estimativa da necessidade de fósforo e potássio para o tomate industrial utilizando redes neurais artificiais.

Tipo

() Tese (x) Dissertação

Curso/Programa: Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola.

Concorda com a liberação documento [x] SIM [] NÃO¹

Anápolis 31/01/2023
Local Data

Sabrina Dias de Oliveira

Assinatura do autor (a)

Lucy F. Costa

Assinatura do orientador (a)

¹ Casos de impedimento:

- Período de embargo é de um ano a partir da data de defesa
- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da Dissertação/Tese em livro.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UEG
com os dados fornecidos pelo(a) autor(a).

DSA118d Dias de Oliveira, Sabrina
Estimativa da necessidade de fósforo e potássio para o tomate industrial utilizando redes neurais artificiais / Sabrina Dias de Oliveira /; orientador Sueli Martins de Freitas Alves. --Anápolis, 2022.p.67.

Dissertação (Mestrado - Programa de Pós-Graduação Mestrado Acadêmico em Engenharia Agrícola) -- Câmpus-Anápolis CET, Universidade Estadual de Goiás, 2022.

1. Ciência Agrárias. 2.Fertilidade e correção do solo. 3. Inteligência Artificial. 4. Multilayer Perceptron. I. Alves, Sueli Martins de Freitas, orient. II. Estimativa da necessidade de fósforo e potássio para o tomate industrial utilizando redes neurais artificiais.

Pró-Reitoria de Pesquisa e Pós-Graduação
Coordenação do Programa de Pós-graduação *Stricto sensu* em Engenharia Agrícola

ATA DE DEFESA DA DISSERTAÇÃO – M.Sc

ATA DE DEFESA DE DISSERTAÇÃO PARA CONCESSÃO DO GRAU DE MESTRE EM ENGENHARIA AGRÍCOLA

REALIZADA EM **dezesseis de dezembro de dois mil e vinte e dois**

PROGRAMA de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola

CANDIDATO **Sabrina Dias de Oliveira**

BANCA EXAMINADORA:

1. Profa. Dra. **Sueli Martins de Freitas Alves (Orientador/UEG)**
2. Prof. Dr. **Francisco Ramos de Melo (UEG)**
3. Prof. Dr. **João Maurício Fernandes Souza (UniEvangélica)**

TÍTULO DA DISSERTAÇÃO: **“Estimativa da necessidade de fósforo e potássio para o tomate industrial utilizando redes neurais artificiais”**

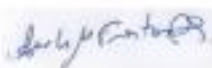
LOCAL: Anfiteatro do CEPEC - Centro de Pesquisa e Educação Científica da Universidade Estadual de Goiás, Campus Central – Sede Anápolis de Ciências Exatas e Tecnológicas.

HORÁRIO DE INÍCIO: 14:00 horas, em sessão pública, após exposição de cerca de 40 minutos, o(a) candidato(a) foi arguido oralmente, pelos membros da banca, tendo demonstrado suficiência de conhecimento e capacidade de sistematização no tema de sua Dissertação, sendo aprovado por unanimidade.

Na forma regulamentar foi lavrada a presente Ata que é assinada pelos membros da banca, e pelo candidato.

Anápolis, 16 de dezembro de 2022.

Orientador:



Candidato(a):

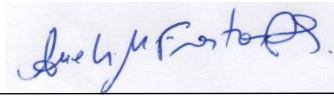


SABRINA DIAS DE OLIVEIRA

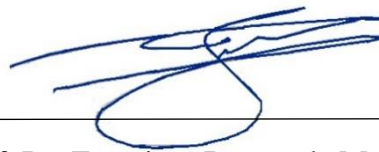
ESTIMATIVA DA NECESSIDADE DE FÓSFORO E POTÁSSIO PARA O TOMATE INDUSTRIAL UTILIZANDO REDES NEURAIS ARTIFICIAIS

Dissertação apresentada à Universidade Estadual de Goiás-UEG, Unidade Universitária de Ciências Exatas e Tecnológicas de Anápolis como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola – Engenharia de Sistemas Agroindustriais, para obtenção do título de MESTRE.

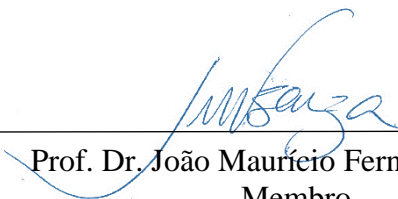
Aprovada em: 16, de dezembro, de 2022, pela banca examinadora constituída pelos professores:



Profa. Dra. Sueli Martins De Freitas Alves
Orientadora
UEG/CCET



Prof. Dr. Francisco Ramos de Melo
Membro
UEG/CCET



Prof. Dr. João Maurício Fernandes Souza
Membro
UniEVANGÉLICA

Aos meus pais, irmãos, sobrinho e ao meu filho Gael Dias de Oliveira,
minha razão de viver.

AGRADECIMENTOS

Primeiramente a Deus, pelo dom da vida e por me dar forças para conseguir superar todas as dificuldades encontradas até hoje.

A minha orientadora Prof.^a Dra. Sueli Martins de Freitas Alves, por toda paciência, dedicação, e ensinamentos que foram essenciais para a condução deste trabalho. Me sinto horada em ter o privilégio de ser orientada por uma mulher tão forte e admirável.

Aos professores e também amigos Carlos Eduardo Bento e Ivandro José pela paciência, disponibilidade e contribuição com a realização deste estudo.

À todos os amigos que fiz durante esta caminhada, em especial ao Victor Hugo, Diogo Santos e Amanda Prager com quem pude contar em momentos bons e difíceis.

À todos os professores do mestrado, em especial ao Prof. Dr. Francisco Ramos de Melo, Prof. Dr. Ivano Alessandro Devilla, e Profa. Dra. Roberta Passini. Gratidão pelos ensinamentos, paciência e palavras de incentivo.

À minha rede de apoio, composta pela minha irmã Alice Vitória, minha prima Lara Oliveira, minha tia Ana Maria, e a Vera Lúcia que me deram todo suporte nessa etapa final do trabalho.

À Universidade Estadual de Goiás - UEG, Campus Central – Sede Anápolis - Ciências Exatas e Tecnológicas Henrique Santillo, ao departamento de Engenharia Agrícola e ao Programa de Pós-Graduação em Engenharia Agrícola.

A todos aqueles que contribuíram, de alguma forma, para a realização deste trabalho. Muito obrigado!

RESUMO

Na agricultura é possível encontrar a aplicação das redes neurais artificiais (RNAs) em estudos visando prever atributos do solo, produtividade de culturas, entre outros, e dada a amplitude de utilização, as RNAs consistem em um método promissor para estimar indicadores referentes a qualidade do solo. Este estudo teve como objetivo desenvolver uma RNA para estimar as necessidades de fósforo (P) e potássio (K) em áreas de pivô central cultivadas com tomate industrial e reduzir a quantidade de amostras necessárias para a coleta de dados a campo. Os dados foram coletados utilizando uma grade amostral de 60x60m, totalizando 120 pontos amostrais. Foram treinados 2 modelos de rede, o primeiro com o objetivo de estimar a necessidade de fósforo e a necessidade de potássio em áreas de pivô central e o segundo com o intuito de reduzir a quantidade de amostras necessárias para a coleta de dados em campo, em que para o treinamento foi utilizado o algoritmo *back-propagation*, com topologia do tipo Perceptron de Múltiplas Camadas (MLP). Posteriormente foi realizada a análise geostatística e ajustado o modelo de semivariograma para os dados de necessidade de P e K estimados pela tabela de recomendação de fertilizantes, em função da análise de solo, e os estimados pela RNA modelo 2, em que foram elaborados os mapas de isolinhas e avaliada a acurácia dos mapas através dos índices de Kappa e Exatidão global. Para os dois modelos treinados foram observados bons ajustes com valores de R² superiores a 0,90 na fase de validação externa, baixos valores de EQM (erro quadrático médio), correlação acima de 91% e um ótimo desempenho das RNAs, em que a precisão das redes escolhidas foram confirmadas pelo Teste-t, para ambos os modelos treinados. Foi possível estimar as necessidades de P e K e a adaptação da técnica de vizinhança possibilitou uma redução de 40% no número de amostras necessárias para a coleta de dados a campo, possibilitando se obter estimativas das necessidades de P e K, visando uma possível aplicação dos nutrientes a taxa variável, contribuindo com a redução de custos. O índice de Kappa e Exatidão global propiciaram a avaliação da acurácia dos mapas elaborados, em que foi constatada média e alta acurácia entre os mapas de necessidades de P e K, respectivamente, e valores de exatidão global superiores a 85%. Com a redução do número de amostras a rede consegue obter estimativas válidas de P e K para serem usadas no estudo da variabilidade espacial do solo.

Palavras-chave: Agricultura de precisão; Neurônios artificiais; *Solanum lycopersicum*; Adubação.

ABSTRACT

In agriculture, it is possible to find the application of artificial neural networks (ANNs) in studies aimed at predicting attributes of crop productivity, among others, and given the breadth of use, ANNs consist of a promising method to estimate indicators related to soil quality. This study aimed to develop an ANN to estimate the needs of phosphorus (P) and potassium (K) in central pivot areas cultivated with industrial tomatoes and to reduce the amount of samples required for field data collection. The data were collected using a sample grid of 60x60m, totaling 88 sampling points. Two network models were trained, the first aiming at estimating the need for phosphorus and the need for potassium in central pivot areas and the second aiming at reducing the amount of samples needed for data collection in the field, in which the back-Propagation algorithm was used for the training, with Multiple Layer Perceptron (MLP) topology. Subsequently, a geostatistical analysis was performed and the semivariogram model was adjusted for the P and K requirement data estimated by the fertilizer recommendation table, based on the soil analysis, and those estimated by the ANN model 2, in which the maps were prepared. of isolines and evaluated the accuracy of the maps through the Kappa and Global Accuracy indices. For the two trained models, good adjustments were observed with R^2 values greater than 0.90 in the external validation phase, low EQM values (mean squared error), correlation above 91% and excellent performance of the ANNs, in which the precision of the chosen networks were confirmed by the t-Test, for both trained models. It was possible to estimate the needs of P and K and the adaptation of the neighborhood technique enabled a 40% reduction in the number of samples needed for the collection of field data, making it possible to obtain estimates of the needs of P and K, aiming at a possible application of nutrients at a variable rate, contributing to cost reduction. The Kappa index and global accuracy allowed the evaluation of the accuracy of the prepared maps, in which medium and high accuracy was found between the P and K needs maps, respectively, and global accuracy values greater than 85%. By reducing the number of samples, the network is able to obtain valid estimates of P and K to be used in the study of soil spatial variability.

Keywords: Precision agriculture; Artificial neurons; *Solanum lycopersicum*; Fertilization.

LISTA DE FIGURAS

Figura 1- Ilustração da Lei do mínimo de Liebg.	20
Figura 2 - Neurônio artificial proposto por McCulloch e Pitts em 1943.....	25
Figura 3 - Rede Multicamadas com 2 camadas ocultas (Perceptron multicamadas).	26
Figura 4 – (a) Localização de Corumbá de Goiás em Goiás e da área experimental; (b) Área experimental.	29
Figura 5- (a) Grade amostral da área experimental. (b) Área experimental dividida em áreas.	30
Figura 6 - Esquema representativo da adaptação da técnica de vizinhança.	33
Figura 7 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial.....	43
Figura 8 - Comparativo dos valores geral de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS) e estimado pela rede neural artificial (RNA).....	46
Figura 9- Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial.....	48
Figura 10 - Comparativo geral entre as redes selecionadas para os valores OBS (obtidos utilizando a tabela de recomendação de fertilizantes, em função da análise de solo) e valores estimados pela rede neural artificial (RNA) modelo 2 para a (a) necessidade de fósforo e (b) necessidade de potássio, para a cultura do tomate industrial.	50
Figura 11 - (a) Esboço da grade amostral com a presença dos 72 pontos utilizados como referência para obter as estimativas de necessidade de fósforo (P) e necessidade de potássio (K); e (b) Esboço da grade amostral com a presença dos 48 pontos que podem ser estimados pelo modelo 2.	52
Figura 12 - Esboço representativo da (a) grade amostral com a presença dos 120 pontos coletados a campo (OBS); e (b) grade amostral com a presença dos 72 pontos coletados a campo e 48 que podem ser estimados pela rede neural artificial (RNA) modelo 2 (OBS+RNA).....	53

Figura 13- Mapas de isolinhas da (a) Necessidade de fósforo (P) estimada utilizando a tabela de recomendação de fertilizantes, em função da análise de solo; (b) necessidade fósforo (P) estimada pela rede neural artificial (RNA) modelo 2; (c) Necessidade de potássio (K) estimada pela rede neural artificial (RNA) modelo 2.....56

LISTA DE TABELAS

Tabela 1 - Critério para definição de fertilidade do solo para hortaliças.	22
Tabela 2 - Recomendações de adubação fosfatada e potássica, de plantio, para o tomate industrial.	22
Tabela 3 - Recomendação de adubação para o tomate industrial no cerrado.	23
Tabela 4 - Recomendação de adubação para o tomate industrial no cerrado.	31
Tabela 5 - Valores para identificar a área em que o ponto amostral está localizado.	32
Tabela 6 - Parâmetros utilizado para realizar treinamento MLP.	35
Tabela 7 - Análise do índice de desempenho da RNA.	38
Tabela 8 - Estatística descritiva dos atributos químicos de solo na profundidade de (0 - 20 m) e necessidade de fósforo (P) e potássio (K).	41
Tabela 9 - Resultados dos indicadores estatísticos para estimativas da necessidade de fósforo (P) e potássio (K) das redes selecionadas.	44
Tabela 10 - Teste-t para os valores de necessidade de fósforo (P) e necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS) e estimado pela rede neural artificial (RNA).	47
Tabela 11 - Resultados dos indicadores estatísticos das redes selecionadas, para redução dos pontos necessários para coleta de amostras.	49
Tabela 12 - Teste-t para os dados de necessidade de fósforo (P) e potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA).	51
Tabela 13 - Estatística descritiva da necessidade de fósforo (P) e potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA) modelo 2.	55
Tabela 14 - Modelos teóricos de semivariograma ajustados para os atributos de necessidade de fósforo (P) e necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA) modelo 2.	55
Tabela 15 - Resultados dos índices de acurácia Kappa e Exatidão Global.	57

SUMÁRIO

1 INTRODUÇÃO	15
2 REVISÃO DE LITERATURA.....	18
2.1 TOMATE INDUSTRIAL.....	18
2.2 FERTILIDADE DO SOLO	18
2.3 AGRICULTURA DE PRECISÃO.....	23
2.4 REDES NEURAIS ARTIFICIAIS	24
3 MATERIAL E MÉTODOS	29
3.1 CARACTERIZAÇÃO E LOCALIZAÇÃO DA ÁREA DE ESTUDO	29
3.3 DETERMINAÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO.....	30
3.4 NECESSIDADE DE FÓSFORO E POTÁSSIO.....	30
3.5 ESTATÍSTICA DESCRITIVA	31
3.6 REDE NEURAL ARTIFICIAL	31
3.6.1 Modelo 1: Necessidades de fósforo (P) e potássio (K)	31
3.6.1.1 Alimentação de dados.....	32
3.6.1.1.1 Varáveis de entrada	32
3.6.1.1.2 Variáveis de saída.....	32
3.6.1.1.3 Separação dos conjuntos.....	33
3.6.2 Modelo 2: Redução de pontos necessários para a coleta de amostras	33
Aplicando a adaptação da técnica para a inserção de dados da RNA é possível reduzir o número de amostras coletadas a campo em 40%, uma vez que de 120 pontos foram utilizados apenas 72 pontos para obter as estimativas.	34
3.6.2.1 Variáveis de entrada	34
3.6.2.2 Variáveis de saída.....	34
3.6.2.3 Separação dos conjuntos.....	35
3.6.3 Critérios de treinamento das RNAs	35
3.6.4 Normalização dos dados.....	35
3.6.5 Escolha da Melhor RNA	36
3.6.6 Desnormalização dos dados	36
3.7 VALIDAÇÃO DO MODELO	36
3.8 TESTE PARA COMPARAÇÃO DAS MÉDIAS.....	39
4 RESULTADOS E DISCUSSÃO	41
4.1 ANÁLISE DESCRITIVA DOS DADOS	41

4.2 REDE NEURAL ARTIFICIAL	42
4.2.1 Modelo 1: Rede neural artificial para estimativas da necessidade de fósforo (P) e potássio (K).....	42
4.2.1.1 Rede selecionada	44
4.2.1.2 Necessidade de fósforo (P) e potássio (K)	46
4.2.2 Modelo 2: Rede neural artificial para redução do número de pontos necessários para coleta de amostras.....	47
4.2.2.1 Rede selecionada	49
4.2.2.2 Redução de amostras de coleta de dados visando estimativas para análise geoestatística.....	50
4.3 ANÁLISE GEOESTATÍSTICA PARA OS DADOS DE NECESSIDADE DE FÓSFORO E POTÁSSIO, MAPAS DE NECESSIDADE DE FÓSFORO E POTÁSSIO E ACURÁCIA DOS MAPAS.....	53
5 CONCLUSÃO	58
REFERÊNCIAS	59

1 INTRODUÇÃO

Considerado um recurso natural de extrema importância para o desenvolvimento da vida, o solo é apontado como um sistema dinâmico e tridimensional, composto por frações sólidas, líquidas e gasosas, que são constituídas por materiais minerais e orgânicos (SANTOS, 2018; SILVA et al., 2020). Os solos do cerrado brasileiro apresentam forte potencial para o cultivo agrícola, isso devido a sua riqueza física. Entretanto, em razão de seu acentuado grau de intemperismo, são considerados solos naturalmente ácidos, apresentam baixa disponibilidade de fósforo e reserva escassa de potássio, resultando em uma baixa fertilidade natural (MATIAS et al., 2019; SEVERIANO et al., 2011; SANO et al., 2019).

A deficiência nutricional do solo é um fator limitante ao desenvolvimento de culturas como o tomateiro, que é extremamente exigente em nutrientes minerais (SILVA et al., 2012). O tomate (*Solanum lycopersicum*) é uma hortaliça bastante difundida no Brasil e no mundo. Os frutos da cultura são destinados tanto para o consumo *in natura*, quanto ao seguimento industrial para a produção de atomatados (extratos e molhos) (LUZ et al., 2016). O Brasil está entre os maiores produtores de tomate com a finalidade industrial (SILVA et al., 2018), sendo o estado de Goiás o representante na produção da cultura, atingindo uma produção de 1,1 milhões de toneladas no ano de 2021 segundo dados da SEAPA (Secretaria de Estado de Agricultura, Pecuária e Abastecimento). Visando melhorias na produtividade da cultura, são empregadas técnicas, como a aplicação de corretivos e fertilizantes, com o intuito de propiciar a restituição dos atributos químicos do solo, isso devido a maioria dos solos não fornecerem a quantidade de nutrientes necessários para o desenvolvimento do tomateiro (PERES et al., 2020).

Nutrientes como potássio (K) e fósforo (P) são essenciais ao desenvolvimento e crescimento de culturas como o tomateiro com fins industriais. O K é o elemento requerido em maior quantidade pela cultura do tomate, atua em processos internos da planta como a ativação enzimática, síntese proteica e está relacionado ao processo de fotossíntese, já o P promove o crescimento e desenvolvimento das raízes, propiciando uma melhor qualidade de frutos, mesmo sendo extraído em menores quantidades pela planta (SILVA et al., 2018; NETA et al., 2020).

Fatores como o entendimento do estado nutricional do solo por meio da análise química, a textura e potencial produtivo da cultura são essenciais na determinação das quantidades ideais de nutrientes a serem empregados ao solo (SILVA et al., 2012). As necessidades de fósforo e potássio devem ser baseadas na quantidade de nutrientes presentes no solo verificada por meio da análise do mesmo (SEGATTO et al., 2020). A análise química

é uma ferramenta tradicional que possibilita quantificar a disponibilidade dos nutrientes. Posteriormente a realização da análise química são utilizadas tabelas de recomendações para verificar a classe de fertilidade e definir a dose ideal a ser aplicada (PREZOTTI, 2015).

As grandes áreas apresentam heterogeneidade, sendo necessário a aplicação de técnicas que propiciem o estudo da variabilidade presente no solo, e com isso tem-se a agricultura de precisão (AP). A AP consiste em um conjunto de ferramentas que possibilitam o manejo racional de insumos agrícolas e o estudo do solo por meio dos princípios da geoestatística (SILVA et al., 2020).Dentre as técnicas da AP tem se a amostragem georreferenciada, que por meio de grades amostrais, possibilita a caracterização dos atributos químicos do solo e conseqüentemente o uso racional de insumos (CHERUBIM et al., 2015). Nesta técnica as amostras de solo são coletadas em pontos específicos, possibilitando o estudo de grandes áreas e posteriormente auxiliando no manejo da fertilidade do solo e das plantas, favorecendo as etapas de cultivo como a recomendação de corretivos e fertilizantes (VERGARA et al., 2019).

Apesar dos avanços da AP, em relação ao estudo do solo, ainda existem lacunas relacionadas a caracterização da variabilidade presente no mesmo, visto que a acurácia dependera da dimensão da malha amostral e da densidade de pontos amostrais coletados (CHERUBIM et al., 2014). Para que a distribuição de um atributo possa ser representada espacialmente, ou seja realizada a aplicação de insumos a taxa variável, é fundamental que seja coletado um número significativo de amostras de solo, sendo necessário grandes disponibilidades financeiras e mão de obra, fato que leva os produtores a optarem pelo manejo convencional da fertilidade do solo (PERES et al., 2020). Souza et al. (2014) preconiza a coleta mínima de 100 pontos amostrais para uma área de 36 hectares, visando uma melhor precisão dos mapas temáticos gerados posteriormente a amostragem georreferenciada.

Dentro desse contexto, a aplicação de novas tecnologias, como as redes neurais artificiais (RNAs) se apresentam como um método econômico e viável na resolução de problemas da agricultura (DORNELLES et al., 2018). As RNAs são sistemas computacionais que simulam o funcionamento dos neurônios humanos e possibilitam a resolução de inúmeros problemas com facilidade e viabilidade (MARTINIANO et al., 2016). O processo de aprendizagem da rede é realizado por meio de algoritmos de treinamento (TEODORO et al., 2015). Segundo Fleck et al. (2016) a RNA é uma junção de várias áreas, sendo elas: neurociência, matemática, física, estatística, ciência da computação e engenharia.

Estudos visando contribuir com a aplicação das redes neurais artificiais no âmbito da agricultura são constantes. Bittar et al. (2018) realizaram um estudo com o objetivo de estimar

os atributos físicos e químicos de solo utilizando redes neurais artificiais. Freitas (2018) avaliou o índice de assertividade da RNA desenvolvida por Bittar (2016). Guimarães et al. (2018) avaliou o potencial da RNA na predição da produtividade em palma forrageira. Barbosa et al. (2022) desenvolveu uma RNA para estimar a necessidade de calagem em áreas de pivô central. Rocha et al. (2022) desenvolveu uma rede com o intuito de obter estimativas do índice de área foliar (IAF) na cultura do tomate industrial irrigado por pivô central. Tendo em vista a importância de estudos visando potencializar a produtividade e o rendimento econômico do tomate industrial no estado de Goiás, torna-se interessante o desenvolvimento de pesquisas que contribuam para a otimização dos processos produtivos da cultura, e pode-se destacar as redes neurais artificiais que apresentam uma alternativa promissora para estimar indicadores referentes a qualidade do solo.

Esse trabalho teve como objetivo estimar as necessidades de fósforo e potássio em áreas de pivô central cultivadas com tomate industrial utilizando Redes Neurais Artificiais (RNAs) e reduzir a quantidade de amostras necessárias para a coleta de dados a campo, visando uma possível aplicação de fósforo e potássio a taxa variável.

2 REVISÃO DE LITERATURA

2.1 TOMATE INDUSTRIAL

O tomate (*Solanum lycopersicum*) possui origem da América do Sul, e foi domesticado no México. Embora seja classificado como um fruto, o mesmo é estudado dentro do grupo das hortaliças e pertence à família das solanáceas. A planta é caracterizada como herbácea, no qual seu caule inicialmente é ereto e posteriormente torna-se prostrado devido ao peso das ramas e frutos, possuindo pelos e textura áspera e as folhas são normalmente alternadas, pecioladas, pinadas e com margens dentadas (NAIKA et al., 2006).

Devido o fruto da cultura apresentar em sua composição elevados teores de vitaminas A e C e ser rico em licopeno, ele está presente nas dietas contemporâneas, fato que justifica sua representatividade econômica no mundo (BREKSA et al., 2015). Barbosa et al. (2021) ressaltam que o fruto do tomateiro é carnoso e suculento, características que evidenciam seu destaque econômico e sua extensa distribuição geográfica. No ranking de países produtores da cultura o Brasil ocupa a oitava posição (LU et al., 2019).

Em termos de área plantada, o tomateiro ocupa a segunda posição no Brasil (CONAB, 2019). De acordo com dados do Instituto brasileiro de geografia (IBGE) no ano de 2021 foram plantados cerca de 53.329 hectares de tomate. A expressividade econômica da cultura está também relacionada ao seu cultivo em larga escala, consumo e geração de empregos, no qual sua produção é destinada tanto ao consumo *in natura* em forma de saladas simples e assim como para a fabricação de molhos e extratos (CUNHA et al., 2014).

No Brasil, o estado de Goiás apresenta destaque na produção de tomate com a finalidade industrial, sendo apontado como maior produtor, seguido de São Paulo e Minas Gerais (SALES et al., 2017). No estado a produção e comercialização de tomate apresenta relevante contribuição econômica, isso devido os fatores edafoclimáticos serem favoráveis ao cultivo da cultura, no qual a produção concentra-se na região central de Goiás, onde localiza-se um número significativo de agroindústrias de processamento (SILVA JUNIOR et al., 2015; ALVES JUNIOR et al., 2021; QUINTANILHA, et al., 2019).

2.2 FERTILIDADE DO SOLO

O solo é definido como uma coleção de corpos naturais, que é composto por frações sólidas, líquidas e gasosas, tridimensionais, é considerado um sistema dinâmico constituído por material mineral e orgânico. Apontado como um recurso extremamente importante para a vida humana devido propiciar o cultivo de alimentos e desempenhar tantos outros benefícios (POLIDORO et al., 2016). O processo de formação dos solos está inteiramente ligado a

fatores como: material de origem, clima, relevo, tempo e organismos vivos (MATOS et al., 2018).

De acordo com Santos et al. (2018) a formação do solo está diretamente ligada ao processo de intemperismo sofrido pela rocha mãe, que é inicialmente físico, onde acontece a desagregação das rochas, no qual ocorre um aumento da superfície das partículas minerais sem a alteração química dos minerais constituintes, e posteriormente químico, isso em decorrência das alterações da estrutura química sofrida pelas rochas. Tendo como exemplo do processo de intemperização boa parte dos solos predominantes no Bioma do Cerrado brasileiro (SOUSA et al., 2011).

O Cerrado é considerado o segundo maior Bioma brasileiro, compreende cerca de 1,5 milhões de km², ocupa cerca de 22% do território nacional, destacando-se no Distrito Federal e estados de Goiás, Mato Grosso, Mato Grosso do Sul, Minas Gerais e parte do Maranhão, Bahia e Piauí (IBGE, 2021).

Os solos presentes no Bioma Cerrado exibem forte potencial para a agricultura, devido apresentarem características como boa drenagem, relevo plano a suave ondulado (CAMARGO et al., 2010). Entretanto, em razão do elevado grau de intemperismo, os solos encontrados no Cerrado brasileiro, em sua maioria apresentam baixa fertilidade. São solos marcados pela presença da acidez, baixa disponibilidade de fósforo, reserva escassa de potássio e pobres em cátions (CENTURIÃO et al., 2021).

As classes de solos predominantes no Cerrado são: Os Latossolos, Neossolos quartzarenicos e Argisolos. Os latossolos ocupam cerca de 32,85% do total do território nacional, já nas regiões do Cerrado domina aproximadamente 44,39% do total, sendo considerado a classe de solo predominante no Estado de Goiás (IBGE, 2022). De acordo com Vendrame et al. (2011) essa classe de solo é formada por minerais como a caulinita, óxidos e hidróxidos de ferro e de alumínio.


Devido serem solos altamente intemperizados, os Latossolos apresentam baixa fertilidade, exceto quando originados de rochas mais ricas em minerais essenciais às plantas, apresentam também elevada acidez e alto teor de alumínio. Possuem boas condições físicas para o uso agrícola, boa permeabilidade por serem solos bem estruturados e muito porosos. Porém, devido aos mesmos aspectos físicos, possuem baixa retenção de umidade, principalmente os de textura arenosa ou média em climas mais secos (CLEMENTE et al., 2018).

Segundo Fontana et al, (2016) essas características físicas e químicas presentes nos Latossolos podem ser explicadas tanto pelos processos naturais ocorridos no solo, quanto pelo

seu uso intensivo. De acordo com Castro et al. (2011) práticas como a irrigação artificial, mecanização e correção das características químicas do solo possibilitaram a utilização dessa classe de solo que por muito tempo foi considerada infértil, permitindo a produção de culturas como o tomateiro, visto que Zayat et al. (2022) destaca que diversos tipos de solos podem ser utilizados para o plantio da cultura, desde que apresentem boas condições físicas, característica marcante nos Latossolos. SILVA et al. (2012) e NAIKA et al. (2006) ressaltam que para o cultivo do tomate devem ser escolhidos solos bem arejados, profundos, ausentes de salinidade, férteis, com o pH variando entre 5,5 e 6,5, visto que nestas condições a planta conseguira obter um bom desenvolvimento.

O crescimento e desenvolvimento das plantas será influenciado por diversos fatores, entre eles está o estado nutricional do solo. A ausência de qualquer nutriente que seja essencial ao desenvolvimento da planta pode interferir em seu máximo rendimento, o que pode ser explicado pela Lei do mínimo, em que didaticamente o barril com bordas irregulares pode exemplificar essa Lei (Figura 1), visto que a produção ficara limitada pelo nutriente em menor quantidade, na ilustração o potássio, sendo necessário então sua restituição (REETZ, 2017).

Figura 1- Ilustração da Lei do mínimo de Liebg.



Fonte: LEPSCH (2010).

Nutrientes essenciais as plantas são aqueles que em sua ausência a planta não consegue completar seu ciclo, então para um bom desenvolvimento é indispensável o equilíbrio nutricional do solo. Cada nutriente desempenha uma função na planta, não sendo possível, na ausência de algum destes nutrientes essenciais, que outro o substitua (MIXQUITITLA-CASBIS e VILLEGAS-TORRE, 2016).

Dentre os nutrientes essenciais as plantas têm- se o fósforo (P) e o potássio (K). O P é pertencente a classe dos macronutrientes, visto que é requerido em grandes quantidades pela planta, ele participa da constituição de enzimas e de processos fotossintéticos (SILVA et al., 2019). Este nutriente é constituinte da síntese proteica e atua na absorção iônica, seu fornecimento adequado acarretará benefícios para a planta como o desenvolvimento do sistema radicular e da parte aérea, e conseqüentemente irá contribuir com a absorção de água e nutriente (HOFFMAN et al., 2017). No tomateiro o P atua em processos como armazenamento de açúcares e amido, favorece o crescimento vegetativo da planta, o processo hídrico e a resistência a pragas (ZAYAT et al., 2022).

O K também é considerado um macronutriente, em que é um dos nutrientes mais exigidos pelas plantas, sendo responsável pela abertura estomática, translocação de açúcares, síntese proteica e ativação enzimática (SILVA et al., 2017). Segundo Filgueira (2008) a presença deste nutriente irá melhorar o aproveitamento hídrico da planta. De acordo com Guedes et al. (2021) o tomateiro é uma das plantas mais exigentes no elemento potássio, sendo seu correto fornecimento decisivo para o sucesso da atividade. Na cultura do tomate, Almeida et al. (2019) observou que o aumento das doses de potássio influenciou significativamente a produtividade e o teor nutricional no tecido vegetal.

Quando verificada a deficiência destes nutrientes no solo é indispensável a realização da suplementação para que as plantas possam obter seu máximo desenvolvimento. Meneghette et al. 2017 cita a importância da restituição dos nutrientes no solo e de seu fornecimento adequado, visto que o mesmo propiciará um aumento produtivo.

Para que a suplementação do solo seja feita de forma adequada, é importantíssimo a realização inicialmente da análise de solo para o diagnóstico da fertilidade e a aplicação na quantidade correta dos nutrientes. Para o conhecimento da fertilidade deve ser realizada a amostragem do solo, em que a princípio a área deve ser dividida em glebas uniformes quanto a posição do relevo e deve estar livres de pedras, vegetação e entre outros. Posteriormente, são coletadas amostras em uma profundidade de 20 cm, no qual para a coleta são utilizados equipamentos como o trado de rosca ou uma pá, em que podem ser coletadas amostras

simples ou compostas. Depois de identificadas, as amostras normalmente são encaminhadas a um laboratório certificado para a quantificação dos nutrientes (Raij, 2017).

A partir do conhecimento da disponibilidade dos nutrientes no solo, a quantidade a ser aplicada é considerada de acordo com boletins técnicos que irá variar de acordo com a região, tipo de solo, cultura e sua produtividade esperada (GUEDES et al. 2021). Para o estado de Goiás é considerado o boletim técnico 5ª aproximação (CFSG, 1988), em que como exemplo para as hortaliças, como o tomate industrial, primeiramente é verificada a classe de fertilidade pertencente de acordo com o resultado na análise de solo (Tabela 1).

Tabela 1 - Critério para definição de fertilidade do solo para hortaliças.

Atributo	Classe de fertilidade		
	Baixo	Médio	Alto
P (mg dm ⁻³)	<10,0	10,0-30,0	>30,0
K (cmol _c dm ⁻³)	<0,10	0,10-0,31	>0,31
Ca (cmol _c dm ⁻³)	<2,0	2,0-5,0	>5,0
Mg (cmol _c dm ⁻³)	<0,5	0,5-1,2	>1,2
MO (gkg ⁻¹)	<20,0	20,0-50,0	>50,0

P - fósforo; K - potássio; Ca - cálcio; Mg - Magnésio; MO - matéria orgânica.

Fonte: Comissão de Fertilidade de Solos de Goiás (1988)

Posteriormente, as recomendações referentes a cultura podem ser observadas na Tabela 2, onde devem ser considerados os níveis dos nutrientes (P e K) no solo e verificada a quantidade a ser aplicada.

Tabela 2 - Recomendações de adubação fosfatada e potássica, de plantio, para o tomate industrial.

Disponibilidade de P e K no solo	Recomendação	
	P ₂ O ₅	K ₂ O
	Kg. há ⁻¹	
Baixa	350-500	100-120
Média	250-350	60-100
Alta	100-250	40-60

Fonte: Comissão de Fertilidade de Solos de Goiás (1988).

Entretanto, existem recomendações mais específicas, como a demonstrada por Silva et al. (2012) em que apresenta uma tabela de recomendação referente a cultura do tomate industrial cultivado em regiões do Cerrado (Tabela 3). No qual a recomendação de adubação é realizada com base no resultado da análise de solo referente aos nutrientes P e K. Segundo Neta et al. (2020) o fornecimento adequado dos nutrientes ao solo auxilia na redução de

contaminação ambiental e no aumento da eficiência do aproveitamento dos fertilizantes pelas plantas cultivadas.

Tabela 3 - Recomendação de adubação para o tomate industrial no cerrado.

Nutrientes	Resultado da análise de solo	Recomendação de adubação
	mg dm ⁻³	kg. ha ⁻¹
P	< 10	600
	10-20	500
	21-30	400
	>30	300
K	<30	250
	30-60	200
	61-100	150
	>100	50

P = Fósforo, extrator Melich¹ e recomendação em kg ha⁻¹ de P₂O₅; K = potássio e recomendação em kg ha⁻¹ de K₂O.

Fonte: Silva et al. (2012).

2.3 AGRICULTURA DE PRECISÃO

Um dos maiores desafios enfrentados na atualidade está relacionado a produção de alimentos em larga escala e o uso de recursos naturais de forma sustentável (SILVA et al., 2017). Com isso, um método interessante de gerenciamento agrícola, denominado como agricultura de precisão (AP), que é composto por um conjunto de ferramentas e tecnologias, que propiciam a racionalização de insumos agrícolas e o estudo da variabilidade presente no solo, vem sendo estudado com o objetivo de atenuar os impactos ambientais provocados pela agricultura (MOLIM et al., 2015).

A AP auxilia nas tomadas de decisões no campo, considerando a variabilidade espacial e temporal do solo, e utiliza como apoio ferramentas como dispositivos, equipamentos e softwares. Atualmente, encontra-se aplicações frequentes desta ferramenta em culturas de grãos, cana-de-açúcar, hortaliças, frutíferas e na silvicultura (BASSOI et al., 2019). De acordo com Gelain et al. (2021) essa prática agrônômica chegou ao Brasil ao final do século XX e desde então vem ganhando espaço entre os extensionistas e produtores rurais, tendo como destaque a amostragem georreferenciada que visa a obtenção de mapas para conhecimento da fertilidade do solo, propiciando assim a aplicação de corretivos e fertilizantes a taxa variável (GELAIN et al., 2021).

A amostragem do solo de forma georreferenciada consiste na etapa inicial de aplicação da AP (CHERUBIN et al., 2016). Essa ferramenta pode ser realizada de duas formas: sistemática e aleatória. A amostragem sistemática é um método amplamente utilizado na AP em razão de seu melhor planejamento da quantidade de amostras coletadas, visto que as

mesmas são coletadas em pontos equidistantes. Já na amostragem aleatória as amostras são coletadas sem uma sistematização, de forma aleatória na área (SANTI et al., 2016).

Entretanto, um dos problemas associados a amostragem do solo, está relacionado a definição do tamanho da célula da malha amostral. Embora a amostragem georreferenciada venha sendo utilizada em larga escala na agricultura brasileira, não existe um consenso ou uma recomendação do tamanho de malha amostral que possa ser generalizada (Cherubin et al., 2015).

Após a realização da amostragem georreferenciada, e da análise geoestatística, que consiste em outra ferramenta apresentada pela AP e que serve como base na confecção de mapas preditivos da fertilidade, é realizada a restituição de nutrientes ao solo a taxa variável, em que os insumos serão fornecidos em diferentes quantidades de acordo com a necessidade a ser aplicada de cada talhão (BERNARDI et al., 2018).

Matias et al. (2019) cita que a análise geoestatística permite a identificação de zonas de manejo e por consequência permite uma maior eficiência na aplicação de insumos. De acordo com Rodrigues (2021) a aplicação de métodos geoestatísticos é de suma importância pois possibilita a tomada de decisão em determinada área por meio do estudo espacial de suas variáveis.


Segundo Bernardi et al. (2015) a aplicação de ferramentas da AP pode auxiliar no retorno econômico aos produtores rurais, visto que a mesma irá melhorar a eficiência do uso de nutrientes, e consequentemente reduzirá os desperdícios de insumos e contribuirá de forma positiva com o meio ambiente.

2.4 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNAs) são definidas como sistemas computacionais baseados no funcionamento dos neurônios biológicos, no qual possuem a habilidade de aprender através de experiências (PAPPU e GUMMADI, 2017). Esses modelos computacionais possuem neurônios artificiais, que são denominados como unidades de processamentos que estão interligadas atuando simultaneamente e o processo de aprendizagem da rede é realizado por meio de algoritmos de treinamento (SOARES et al., 2021). Segundo Leite et al. (2011) características de processamento como não-linearidade, alto paralelismo, robustez, tolerância a falhas e ruídos, capacidade de lidar com informações imprecisas e distorcidas, além da sua capacidade de generalizar evidenciam a relevância das RNAs.

O primeiro modelo de neurônio artificial foi proposto pelo neurofisiologista Warren McCulloch e o matemático Walter Pitts no ano de 1943 (Figura 2). Em 1957 foi criado o primeiro Perceptron por Frank Rosenblat, um algoritmo de reconhecimento de padrões com uma única camada. O modelo apresentava sinais de entrada ponderados, uma função de ativação responsável pelo processamento dos sinais de entrada e uma saída.

Figura 2 - Neurônio artificial proposto por McCulloch e Pitts em 1943.




Fonte: Ribeiro et al. (2019).

O modelo neural possui como unidade básica de processamento os neurônios artificiais que simulam os neurônios biológicos, em que um conjunto de neurônios artificiais possuem a capacidade de resolver problemas. A arquitetura da rede será definida pela quantidade de neurônios por camada e pelo tipo de conexão entre eles, em que as camadas podem ser dos seguintes tipos (VALENÇA, 2010):

- Camada de entrada: recebimento dos dados;
- Camada oculta ou intermediária: onde ocorre a extração de características;
- Camada de saída: produção e apresentação do resultado final da rede.

Existem diversos tipos de estruturas de RNA e pode-se destacar o Perceptron multicamadas, comumente conhecida como MLP - multi-layer perceptron (Figura 3) que é uma das arquiteturas mais conhecidas. A MLP contém uma ou mais camadas de entrada, apresenta múltiplas camadas ocultas que possibilita capturar relações mais complexas existentes no conjunto de treinamento, e uma ou mais camadas de saída, que pode ser composta por diferentes funções de ativação (SOUZA et al., 2021). De acordo com Musa et al. (2020) a precisão da MLP está relacionada a quantidade de neurônios presente na camada oculta, entretanto após certo número de neurônios essa precisão pode ser prejudicada.

Figura 3 - Rede Multicamadas com 2 camadas ocultas (Perceptron multicamadas).



Fonte: Silva et al. (2016).

Na atualidade diversos trabalhos vêm sendo desenvolvidos com o objetivo de legitimar a eficiência das RNAs na agricultura. Alves et al. (2018) realizou um estudo com o objetivo de estimar a produtividade da soja com base no hábito de crescimento, na densidade de semeadura e nas características agrônômicas utilizando um perceptron multicamadas (MLP). O autor concluiu que a MLP pode estimar o rendimento com considerável assertividade utilizando informações sobre as características agrônômicas, hábito de crescimento e densidade populacional da cultura da soja. O uso de RNAs para estimar a produção de soja é viável, uma vez que a técnica de treinamento de retropropagação dos erros permitiu identificar a relação entre as variáveis independentes (características agrônômicas da soja, hábito de crescimento e densidade populacional) e a produção de soja com alta precisão.

Fernandes et al. (2019) avaliando a precisão da RNA na estimativa do teor de matéria orgânica (MO) a partir de atributos químicos do solo e com o objetivo de indicar se a complexidade da rede afeta a precisão da estimativa, concluíram que a MO pode ser estimada com alta precisão com base no pH, Ca, Mg, e acidez potencial por meio de modelagem com redes neurais artificiais, e constataram que as RNAs menos complexas podem ser treinadas e mostram a mesma precisão que redes mais complexas.

Fernandes et al. (2020) desenvolveu um estudo com o objetivo de avaliar a acurácia de modelos na estimativa da resistência à penetração do solo com umidade padronizada com base na resistência à penetração do solo, medida em campo e na umidade do solo e indicar a melhor camada e melhor modelo para isso. Os autores compararam os modelos de regressão linear e não linear, redes neurais de base radial (RBF) e a MLP e recomendam o uso de

modelos de RNA (MLP ou RBF) e amostras de solo coletadas da camada de 0,10– 0,30 m para o monitoramento da resistência do solo à penetração.

Meneses et al. (2020) desenvolveu um estudo com o intuito de estimar a absorção potencial pelo método Penman-Monteith na microrregião de Baixo Parnaíba, no Maranhão, utilizando redes neurais artificiais. Foram inseridos como entrada na rede dados de temperaturas máximas, médias e mínimas do ar (°C), no qual o autor constatou que é possível estimar a evapotranspiração de referência pelo método Penman-Monteith usando redes neurais com entradas apenas de temperaturas do ar. Além disso, a rede neural artificial subestimou a evapotranspiração potencial pelo método Penman-Monteith, tanto em treinamento quanto em testes.

Conceição et al. (2021) desenvolveu um estudo com o objetivo de selecionar modelos de Redes Neurais Artificiais com maior capacidade preditiva da colheita para cultura do mamoeiro. Foram utilizados como variáveis preditoras características vegetativas, reprodutivas e de qualidade do fruto, já como variável predita foi empregada a produtividade da cultura. O autor conseguiu obter previsões de produtividade por meio de redes neurais artificiais do tipo Perceptron Multicamadas, constando que a RNA é uma ferramenta eficiente e estratégica nas tomadas de decisões da produção agrícola, sobretudo no que diz respeito ao planejamento de pós-colheita, armazenamento e transporte.

Locatelli et al. (2021) com o objetivo de verificar a capacidade das redes neurais artificiais em estimar a fitotoxidez causada pelo herbicida saflufenacil em plantas de café conilon, constatou que a rede é uma ferramenta com grande potencial na detecção da fitotoxidez do herbicida Saflufenacil em plantas de café conilon.

Guimarães et al. (2021) com o objetivo de avaliar a viabilidade da predição da produção de bananeiras 'Prata-Anã' e 'BRS Platina', por meio de redes neurais artificiais, bem como determinar os descritores morfológicos mais importantes para este fim. O autor constatou que a previsão da produção de 'Prata-Anã' e 'BRS Platina' são obtidas com eficiência por meio de redes neurais artificiais do tipo perceptron multicamadas.

Barbosa et al. (2022) desenvolveu uma rede neural artificial (RNA) com o objetivo de predizer a necessidade de calagem em áreas de pivô central e avaliar o índice de assertividade da rede. A arquitetura que se destacou apresenta 2 neurônios, e foi encontrada no treinamento 574, com isso, o autor constatou que a RNA do tipo Multilayer Perceptron (MLP) com treinamento supervisionado conseguiu estimar, com coeficiente de correlação acima de 99%, a necessidade de calagem em áreas de pivô central. Rocha et al. (2022) com o intuito de obter o Índice de Área Foliar (IAF) por meio de RNAs tendo como dados de

entrada o Índice de Vegetação por Diferença Normalizada (NDVI) obtido por meio de imagens de sensoriamento remoto, concluiu que a RNA do tipo Multilayer Perceptron (MLP) com treinamento supervisionado conseguiu estimar com assertividade acima de 70% o índice de área foliar (IAF).

3 MATERIAL E MÉTODOS

3.1 CARACTERIZAÇÃO E LOCALIZAÇÃO DA ÁREA DE ESTUDO

O experimento foi conduzido em área cultivada com tomate para processamento industrial, irrigada por pivô central, com área equivalente a 45 hectares, situada no município de Corumbá de Goiás (15°56'20" de latitude S e 48°51'58" de longitude O), altitude de 1.000 m (Figura 4). O clima da região segundo a classificação de Köeppen é do tipo Aw, com temperatura média de 22,7 °C e pluviosidade média anual de 1.513 mm. O solo é classificado como Latossolo Vermelho com textura franco argilo arenosa.

Figura 4– (a) Localização de Corumbá de Goiás em Goiás e da área experimental; (b) Área experimental.




Fonte: GOOGLE (2022).

3.2 MAPEAMENTO DA ÁREA E FORMAÇÃO DA GRADE AMOSTRAL

Os dados foram coletados em uma grade amostral de 60x60m (Figura 5a) de acordo com metodologia descrita por Bittar et al. (2018), totalizando 120 pontos amostrais. Cada ponto foi georreferenciado utilizando aparelho de Sistema de Posicionamento Global (GPS), da marca Garmin modelo Etrex Legend RoHs (erro ± 3 m), com sistema de correção diferencial em tempo real via satélite e com o datum ajustado ao sistema SIRGAS 2000.

Com a finalidade de controlar o limite espacial para os pontos amostrais, a área da lavoura foi fragmentada em 4 setores (Figura 5b), com cada um desses representando 25% da lavoura (FREITAS, 2018).

Figura 5- (a) Grade amostral da área experimental. (b) Área experimental dividida em áreas.



Fonte: Autor (2022).

3.3 DETERMINAÇÃO DOS ATRIBUTOS QUÍMICOS DO SOLO

Em cada ponto da grade amostral georreferenciada, foram coletadas amostras deformadas de solo (5 subamostras), na camada de 0 a 20 cm com o auxílio de um trado de rosca, em num raio de 3m, em torno de cada ponto.

Posteriormente as amostras foram embaladas, identificadas e encaminhadas ao laboratório de análise de solos certificado, com aproximadamente 300 g de amostra de cada ponto, para a determinação dos seguintes atributos: pH, potássio (K), fósforo (P), cálcio (Ca), magnésio (Mg), alumínio trocável (Al), acidez potencial (H+Al), matéria orgânica (MO), saturação por alumínio (m%), capacidade de troca catiônica (CTC), saturação por bases (V%).

3.4 NECESSIDADE DE FÓSFORO E POTÁSSIO

As necessidades de fósforo (P) e potássio (K) para a cultura do tomate industrial foram estimadas utilizando as recomendações da Tabela 4 conforme proposto por Silva et al. (2012), em função da análise de solo realizada no laboratório certificado.

Tabela 4 - Recomendação de adubação para o tomate industrial no cerrado.

Nutrientes	Resultado da análise de solo	Recomendação de adubação
	mg dm ⁻³	kg ha ⁻¹
P	< 10	600
	10-20	500
	21-30	400
	>30	300
K	<30	250
	30-60	200
	61-100	150
	>100	50

P = Fósforo, extrator Melich¹ e recomendação em kg ha⁻¹ de P₂O₅; K = potássio e recomendação em kg ha⁻¹ de K₂O.

Fonte: Silva et al. (2012).

3.5 ESTATÍSTICA DESCRITIVA

A estatística descritiva foi realizada com o intuito de avaliar a dispersão e distribuição dos dados para as variáveis que constituem os atributos químicos obtidos por meio da coleta de dados e as necessidades de P e K obtidas por meio da Tabela 4. As seguintes medidas descritivas foram calculadas: média, mediana, variância, desvio padrão, e coeficiente de variação, para cada uma das variáveis em estudo. A identificação de “*Outliers*”, foi realizada por meio de interpretação gráfica (Box plot) e o critério de Tukey (1960). As análises estatísticas foram realizadas com o auxílio de planilhas eletrônicas e do software R (R CORE TEAM, 2015).

3.6 REDE NEURAL ARTIFICIAL

Para a preparação e treinamento das redes foi utilizado o software GNU Octave versão 6.4.0 seguindo metodologia descrita por Rocha (2019). Para o treinamento foi utilizado o algoritmo de *back-propagation*, com topologia do tipo *Perceptron* de Múltiplas Camadas (MLP) para a aprendizagem das RNAs (BRAGA et al., 2014), no qual foram treinados dois modelos.

3.6.1 Modelo 1: Necessidades de fósforo (P) e potássio (K)

Foi treinado um modelo com objetivo de estimar as necessidades de P e K em áreas de pivô central cultivadas com tomate industrial. O treinamento foi realizado de forma separada com o objetivo de verificar a melhor configuração para cada estimativa desejada.

3.6.1.1 Alimentação de dados

Os dados foram separados em dois tipos de variáveis, variáveis de entrada e variáveis de saída, para a realização do treinamento (BRAGA et al., 2014).

3.6.1.1.1 Variáveis de entrada

As variáveis de entrada são os dados apresentados a camada de entrada da rede. Onde foram compostas pelas seguintes variáveis:

- Área: Foram definidas às variáveis área 1 (A1), área 2 (A2) e área 3 (A3), as quais assumiram valores 0 e 1 como sugerido por Rocha (2019). Na Tabela 5, observa-se como identificar a área na qual o ponto amostral está localizado, utilizando as variáveis A1, A2 e A3. Quando as três variáveis assumem o valor de 0 trata-se da área 4.

Tabela 5 - Valores para identificar a área em que o ponto amostral está localizado.

Área	A1	A2	A3
1	1	0	0
2	0	1	0
3	0	0	1
4	0	0	0

Fonte: Rocha (2019).

- Foram inseridos os valores DX, DY e DA obtidos pela diferença das coordenadas X (longitude) e Y (latitude), e altitude de cada ponto em relação ao centro do pivô, respectivamente, seguindo metodologia proposta por Rocha et al. (2022). A metodologia foi aplicada com o intuito de universalizar a utilização da RNA escolhida, com isso a rede poderá ser aplicada em outros pivôs.

-Os atributos químicos do solo em cada ponto amostral: pH, potássio (K), fósforo (P), cálcio (Ca), magnésio (Mg), alumínio trocável (Al), acidez potencial (H+Al), matéria orgânica (MO), saturação por alumínio (m%), capacidade de troca catiônica (CTC), saturação por bases (V%).

A disponibilização das variáveis a rede foi realizada ponto a ponto, aleatoriamente, de acordo com as separações dos conjuntos.

3.6.1.1.2 Variáveis de saída

As variáveis de saída são os dados apresentados na camada de saída da rede. A variável de saída foi composta pelas necessidades de P e K calculadas e obtidas por meio da Tabela4apresentada no Item 3.4.

3.6.1.1.3 Separação dos conjuntos

De acordo com recomendação de Braga et al. (2014), os dados foram separados de forma aleatória em três conjuntos, porém estratificados, onde a separação foi realizada para as variáveis de entrada e saída da rede. Do total de 120 pontos amostrais, a separação seguiu da seguinte forma: O conjunto de treinamento foi composto por 65% do total de pontos amostrais (78 pontos), para a validação foram utilizados 25% (30 pontos), e 10% foram utilizados na fase de teste (12 pontos).


3.6.2 Modelo 2: Redução de pontos necessários para a coleta de amostras

O segundo modelo foi treinado com o objetivo de reduzir o número de amostras necessárias para coleta de dados a campo, visando uma possível aplicação a taxa variável de P e K. Conforme realizado no primeiro modelo treinado, o treinamento foi conduzido de forma individual com o objetivo de verificar a melhor configuração para cada estimativa desejada.

Os dados foram separados em dois tipos de variáveis, variáveis de entrada e variáveis de saída, para a realização do treinamento. Para definição dos pontos que forneceram os dados para constituir as variáveis de entrada e variáveis de saída da rede foi utilizada uma adaptação apresentada por Barbosa et al. (2022) da técnica de vizinhança (GONZALEZ, 2010).

Conforme sugerido por Barbosa et al. (2022) foi realizado um aprimoramento do que foi proposto pelo autor, em que o esquema representativo da adaptação da técnica de vizinhança pode ser observado na Figura 6, no qual os pontos das extremidades dos triângulos preenchidos e sem preenchimento (variável de entrada) foram utilizados como referência para estimar os pontos destacados na cor vermelha (variáveis de saída).

Figura 6 - Esquema representativo da adaptação da técnica de vizinhança.



Fonte: Autor (2022).

Aplicando a adaptação da técnica para a inserção de dados da RNA é possível reduzir o número de amostras coletadas a campo em 40%, uma vez que de 120 pontos foram utilizados apenas 72 pontos para obter as estimativas.

3.6.2.1 Variáveis de entrada

Sendo assim, a camada de entrada é composta pelas seguintes variáveis:

- As variáveis A1, A2 e A3 (Tabela 5) conforme o item 3.6.1.1.1;
- Os valores de DX, DY e DA dos pontos representados por triângulos com e sem preenchimento (Figura8);
- Os atributos químicos do solo em cada um dos pontos: pH, potássio (K), fósforo (P), cálcio (Ca), magnésio (Mg), alumínio trocável (Al), acidez potencial (H+Al), matéria orgânica (MO), saturação por alumínio (m%), capacidade de troca catiônica (CTC), saturação por bases (V%).

Todas as variáveis foram disponibilizadas para a rede conforme a vizinhança dos pontos aos quais se desejou estimar, escolhidos aleatoriamente conforme a separação dos conjuntos.

3.6.2.2 Variáveis de saída

As variáveis de saída foram os dados inseridos na camada de saída da RNA. Para compor a variável de saída, tem-se as necessidades de P e K, calculadas e obtidas pela Tabela

4 apresentada no item 3.4, referentes aos pontos destacados na cor vermelho conforme a Figura 8.

3.6.2.3 Separação dos conjuntos

A separação dos conjuntos ocorreu conforme o item 3.6.1.1.3, entretanto devido à redução no número de pontos a mesma seguiu da seguinte forma:

- O conjunto de treinamento foi composto por 65% do total de pontos amostrais (32 pontos);
- Para a validação foram utilizados 25% do total (12 pontos);
- Para teste foram utilizados 10% do total de pontos (4 pontos).

3.6.3 Critérios de treinamento das RNAs

Conforme proposto por Rocha (2019) foram utilizados os seguintes critérios para treinamento das redes para ambos os modelos treinados (Tabela 6).

Tabela 6 - Parâmetros utilizado para realizar treinamento MLP.

Parâmetro	Valor	Descrição
NrCiclos	1000	Número de ciclos – número máximo de vezes que os dados de treinamento serão apresentados para cada treinamento.
QteTreina	1000	Número de treinamentos – número de treinamentos que devem ser realizados em cada arquitetura (número de neurônio na camada oculta).
QteIniO	1	Quantidade de neurônios iniciais na camada oculta.
QteFimO	20	Quantidade final de neurônios na camada oculta.
QtePasO	1	Passos - é o incremento que será realizado na quantidade de neurônios na camada oculta cada vez que o número de treinamentos especificado for atingido.

Fonte: Rocha (2019).

3.6.4 Normalização dos dados

Para serem inseridos na rede os dados de entrada foram pré-processados. Com o intuito de garantir que cada parâmetro recebesse a mesma atenção, os dados foram normalizados em uma faixa de -1 e 1 (SOARES et al., 2015). A normalização foi realizada por meio da Equação 1 (SRINIVASAN et al., 1994):

$$y = \frac{(x - x_{min})(d_2 - d_1)}{x_{m\acute{a}x} - x_{min}} + d_1(1)$$

Em que:

y = resultado normalizado;
 x = valor a ser normalizado;
 $x_{\text{mín}}$ = valor mínimo de x ;
 $x_{\text{máx}}$ = valor máximo de x ;
 d_1 = limite inferior do resultado da normalização (-1);
 d_2 = limite superior do resultado da normalização (1).

3.6.5 Escolha da Melhor RNA

O critério de escolha da melhor rede foi: Maior índice de desempenho (id) no treinamento e na validação externa, maior coeficiente de determinação (R^2), menor erro quadrático médio (EQM).

3.6.6 Desnormalização dos dados

Após o treinamento e validação das redes, os dados foram desnormalizados retornando a sua grandeza original, para que ocorresse a comparação dos resultados estimados pelas RNAs, conforme Equação 2:

$$x = \frac{(x_{\text{máx}} - x_{\text{mín}})(y - d_1)}{d_2 - d_1} + x_{\text{mín}} \quad (2)$$

Em que:

x = resultado desnormalizado;
 y = valor normalizado;
 $x_{\text{mín}}$ = valor mínimo de x ;
 $x_{\text{máx}}$ = valor máximo de x ;
 d_1 = limite inferior do resultado da normalização (-1);
 d_2 = limite superior do resultado da normalização (1).

3.7 VALIDAÇÃO DO MODELO

Com o intuito de verificar a eficiência das estimativas obtidas por meio das RNAs, em ambos os modelos treinados foram calculados os seguintes indicadores:

(a) Erro médio relativo (P), conforme Equação 3:

$$P = \frac{100}{n} \sum \left| \frac{O-E}{O} \right| \quad (3)$$

Em que:

P = erro médio relativo;

n = número de elementos;

O = valores observados experimentalmente;

E = valores estimados.

(b) Coeficiente de correlação (r), que permite quantificar o grau de associação entre os valores observados e os valores estimados (SCHNEIDER, 1998) (Equação 4):

$$r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)^2][\sum_{i=1}^n (O_i - O)^2]}} \quad (4)$$

Em que:

r = coeficiente de correlação de Pearson;

E_i = valores estimados;

O_i = valores observados;

E = média dos valores estimados;

O = média dos valores observados;

n = quantidade de padrões de teste.

(c) Coeficiente de determinação (R^2) indica quanto da variação total é comum aos elementos que constituem os pares analisados, valores observados e valores estimados pela rede (Equação 5):

$$R^2 = r^2 \quad (5)$$

Em que:

R^2 = coeficiente de determinação;

r = coeficiente de correlação de Pearson.

(d) Índice de concordância (c), fornece o grau de exatidão entre as variáveis envolvidas na análise, valores originais e valores estimados pela RNA, uma vez que relaciona a diferença entre os valores estimados em relação aos valores observados (WILLMONT, 1981) (Equação 6):

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O_i| + |O_i - O_i|)^2} \quad (6)$$

em que:

c = índice de concordância de Willmont;

E_i = valores estimados;

O_i = valores observados;

E = média dos valores estimados;

O = média dos valores observados;

n = quantidade de padrões de teste.

(e) Índice de desempenho (Id), calculado por meio coeficiente de correlação de Pearson (r) e o índice de concordância de Willmont (Equação 7).

$$id = r \cdot c \quad (7)$$

em que:

Id = índice de desempenho;

r = coeficiente de correlação de Pearson;

c = índice de concordância de Willmont.

O Id da RNA foi classificado de acordo com CAMARGO e SENTELHAS (1997), conforme a Tabela 7.

Tabela 7 - Análise do índice de desempenho da RNA.

Valor de id	Desempenho
> 0,85	Ótimo
0,76 - 0,85	Muito bom
0,66 - 0,75	Bom
0,61 - 0,65	Mediano
0,51 - 0,50	Sofrível
0,41 - 0,50	Mau
< 0,41	Péssimo

Fonte: Camargo e Sentelhas (1997).

A partir do item 3.6.3 foram seguidos todos os passos para os dois modelos treinados (necessidade de fósforo e potássio e redução de pontos necessários para a coleta de amostras).

3.8 TESTE PARA COMPARAÇÃO DAS MÉDIAS

Como intuito de comparar os valores médios estimados pela RNA com os valores médios originais determinados pelo método tradicional, para ambos os modelos treinados (Necessidades de fósforo e potássio e redução de pontos necessários para a coleta de amostras), foi realizado o Teste-t.

3.9 ANÁLISE GEOESTATÍSTICA PARA OS DADOS DE NECESSIDADE DE FÓSFORO (P) E POTÁSSIO (K), MAPAS TEMÁTICOS E ACURÁCIA DOS MAPAS.

A estatística descritiva foi realizada com o intuito de avaliar o comportamento dos dados de necessidade de P e necessidade de K, para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo e os estimados pela rede neural artificial (RNA) modelo 2, em que foram calculadas as seguintes medidas: média, mediana, variância, desvio padrão, assimetria, curtose e coeficiente de variação. A identificação de “*Outliers*”, foi realizada por meio de interpretação gráfica (Box plot) e o critério de Tukey (1960).

Para a análise geoestatística foi utilizado o software livre QGIS versão 3.28.0, em que foi utilizado o complemento Smart-Map. Para verificar a existência e quantificar o grau de dependência espacial dos dados foi utilizado o ajuste de funções teóricas aos modelos com patamar de semivariogramas experimentais: Linear, Esférico, Exponencial e Gaussiano.

Para análise do grau de dependência espacial, foi calculado o índice de dependência espacial (IDE) conforme Equação 8, o qual classificou-se o grau de dependência espacial (GDE) como: forte, para $IDE \leq 25\%$; moderado, para IDE entre 25 e 75%; e fraco, para $IDE > 75\%$ (Cambardella et al., 1994):

$$IDE = \frac{C_0}{(C + C_0)} \quad (8)$$

Em que:

IDE = Índice de dependência espacial;

C_0 = Efeito pepita;

$(C + C_0)$ = Patamar.

O melhor modelo foi escolhido por meio do maior coeficiente de determinação (R^2) e o maior grau de dependência espacial. Após definição dos modelos e parâmetros dos

semivariogramas e comprovada a dependência espacial foi utilizado o método de interpolação por meio da técnica denominada krigagem ordinária, para confecção dos mapas de isolinhas.

Para a avaliação da acurácia dos mapas foi utilizado novamente o software QGIS com o auxílio do complemento Semi-Automatic Classification Plugin (SCP), em que foram obtidos os Índices de Kappa (K) e Exatidão Global.

O resultado do índice Kappa (K) foi classificado de acordo com Krippendorff (2004): baixa acurácia para valores $\leq 0,67$; entre 0,67 e 0,80 média acurácia e $\geq 0,80$ alta acurácia.

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE DESCRITIVA DOS DADOS

Foi realizada a análise descritiva e exploratório dos dados de atributos químicos do solo e necessidades de fósforo e potássio, no qual os resultados podem ser observados na Tabela 8. Em relação a dispersão relativa dos dados, fornecida pelos valores de coeficiente de variação (CV%), observa-se que os atributos apresentaram baixa ($CV < 12\%$), média ($12\% \leq CV \leq 62\%$), e alta ($CV > 62\%$) variação conforme classificação de Warrick e Nielsen (1980).

Tabela 8- Estatística descritiva dos atributos químicos de solo na profundidade de (0 - 20 m) e necessidade de fósforo (P) e potássio (K).

Atributos	\bar{X}	MD	Var	DP	Máx	Mín	CV (%)
pH	5,01	5,00	0,11	0,33	6,30	4,40	6,57
Ca	2,48	2,25	0,85	0,92	6,10	1,00	37,18
Mg	0,29	0,20	0,03	0,16	0,80	0,10	56,34
Al	0,02	0,00	0,00	0,04	0,25	0,00	280,62
H+Al	2,58	2,50	0,58	0,76	4,50	1,10	29,66
CTC	5,65	5,69	1,11	1,05	8,43	2,87	18,67
P	12,90	9,00	93,87	9,69	52,00	3,00	75,11
K	0,31	0,31	0,01	0,08	0,45	0,13	26,48
MO	1,94	2,00	0,24	0,49	3,10	0,70	25,55
m%	0,73	0,00	4,64	2,15	15,00	0,00	297,05
V%	53,78	53,00	165,65	12,87	86,00	28,00	23,93
NP	525,83	600,00	8822,83	93,93	600,00	300,00	17,86
NK	79,17	50,00	2461,48	49,61	200,00	50,00	62,67

pH – potencial hidrogeniônico; Ca - cálcio; Mg - magnésio; Al – alumínio; H+Al – acidez potencial; CTC – capacidade de troca catiônica; P – fósforo; K – potássio; MO – matéria orgânica; m% - saturação por alumínio; V% - saturação por bases; NP – necessidade de fósforo (Kg. há⁻¹); NK – necessidade de potássio (Kg. há⁻¹); \bar{X} – média; MD – mediana; Var – variância, Máx – valor máximo; Mín – valor mínimo; CV – coeficiente de variação;

Fonte: Autor (2022).

Para o pH observa-se baixa variação (CV= 6,57%), já os atributos Ca, Mg, H+Al, CTC, MO, V% e NP apresentaram média variação, no qual os valores variaram entre 17,86 a 56,34%. Em relação ao teor de P, nota-se expressiva variação (CV= 75,11%), no qual segundo Cherubin et al. (2015), tal variação pode ser justificada pelas aplicações constantes de fertilizantes na linha de semeadura, o que contribui para a manutenção ou o aumento da variabilidade espacial do solo. O teor de Al e m% apresentaram maior variação, valores superiores a 200%, que pode ser explicada pela quantidade de valores igual a zero no conjunto de dados, fato também observado no estudo de Cherubin et al. (2011). Azevedo et al.

(2015) ressaltam que a variabilidade presente nos dados é fundamental para que ocorra a generalização no treinamento de RNAs. No estudo de Bittar et al. (2018) foram encontrados valores elevados de CV para o Al e m%.

A análise exploratória demonstrou a presença de *outliers*, entretanto o processo de treinamento foi realizado com a presença dos valores discrepante. Os *outliers* foram incluídos no processo de treinamento com o intuito de ofertar a rede o máximo de informações implícitas aos dados (FLORES, 2009). Haykin (2001) resalta que a RNA consegue lidar bem com valores discrepantes, também conhecidos como “*outliers*”. Barbosa et al. (2022) estudando a aplicação das RNAs na previsão da necessidade de calagem em áreas de pivô central evidenciou uma tendência semelhante, em que a rede conseguiu lidar bem com os valores discrepantes e com a variação presente nos dados devido a MLP trabalhar com o método da validação cruzada.

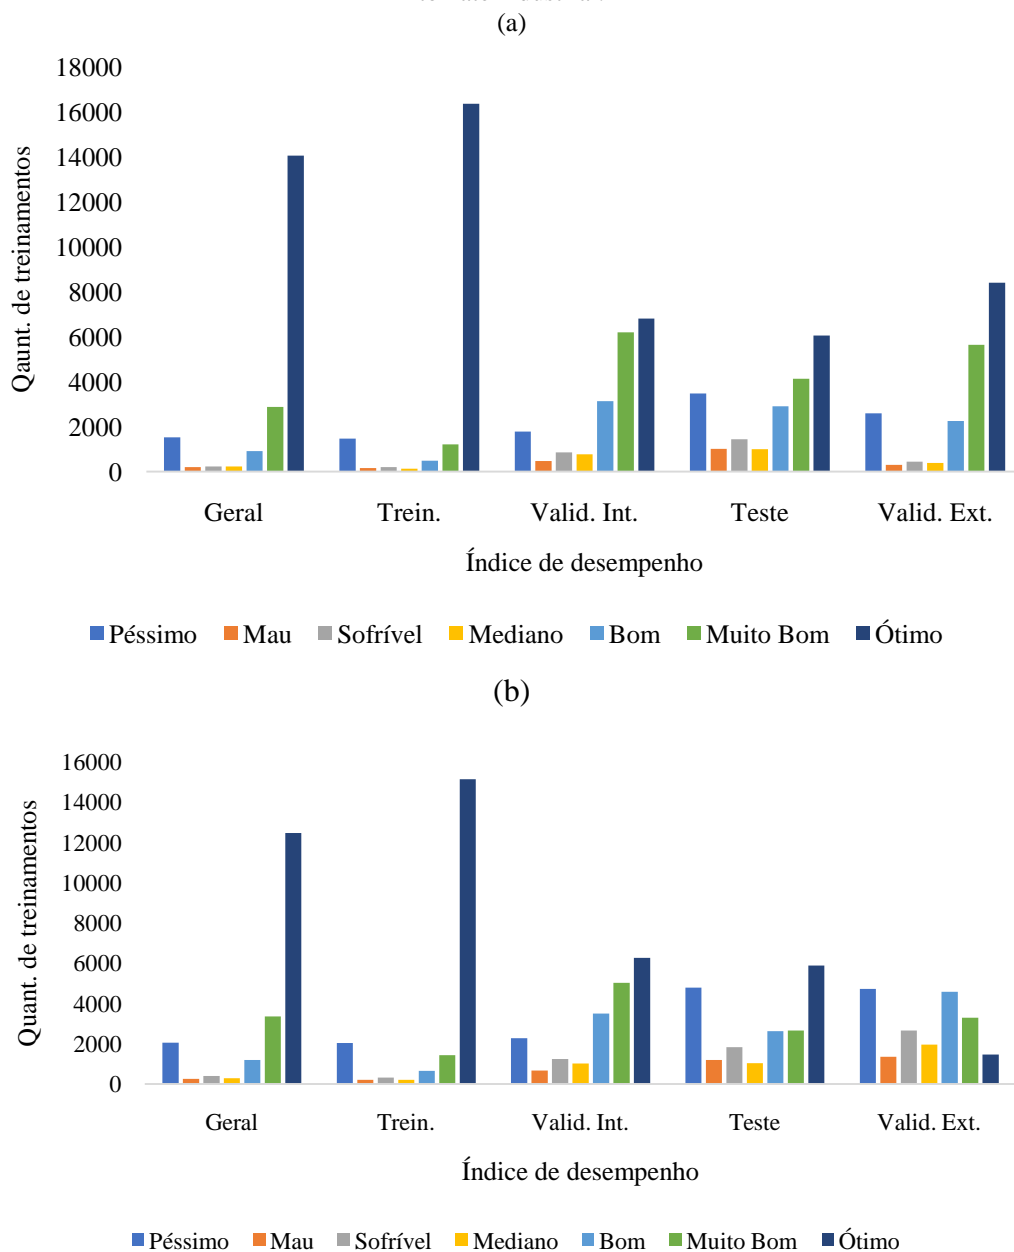
4.2 REDE NEURAL ARTIFICIAL

4.2.1 Modelo 1: Rede neural artificial para estimativas da necessidade de fósforo (P) e potássio (K)

Observa-se que a metodologia descrita por Rocha (2019) foi de suma importância para a otimização do esforço computacional, devido ao grande número de redes treinadas. De acordo com Alves et al. (2018) a possibilidade de variação da complexidade da arquitetura e configuração permite encontrar redes com bons desempenhos.

Foram treinadas um total de 20.000 redes para estimar a necessidade de P e 20.000 redes para a necessidade de K, no qual o treinamento foi realizado separadamente com o intuito de verificar a melhor configuração para obter as estimativas desejadas, e a quantificação dos resultados em relação ao desempenho pode ser observada na Figura 7.

Figura 7 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial.



Fonte: Autor (2022).

Para a necessidade de P (Figura 9a), nas fases de treinamento mais de 14.000 redes apresentaram ótimo desempenho, posteriormente quando foi apresentado um novo conjunto de dados as redes, ou seja, na fase de validação externa, nota-se uma redução do número de redes que obtiveram um ótimo desempenho, que foi de aproximadamente 8000.

Conforme a necessidade de P, o mesmo processo foi realizado para a necessidade de K (Figura 9b). Nota-se que nas fases de treinamento, mais de 12.000 redes apresentaram ótimo desempenho, e na fase de validação externa o número de redes com ótimo desempenho reduziu para 1459.

Resultados diferentes aos deste estudo foram observados por Barbosa et al. (2022) avaliando a aplicabilidade das RNAs em estimar a necessidade de calagem, em que o autor encontrou 14.000 redes com ótimo desempenho nas fases de treinamento, entretanto na fase de validação externa foi observado o fenômeno denominado *overfitting*, no qual as redes começaram a se especializar no conjunto de treinamento, apresentando somente 50 redes com ótimo desempenho.

4.2.1.1 Rede selecionada

Na escolha da melhor RNA foram filtradas as redes que obtiveram ótimo desempenho em todas as fases de treinamento e validação externa, posteriormente foi selecionada as redes que apresentaram menor EQM, maior valor de R^2 e menor número de neurônios para as estimativas desejadas (Necessidades de P e necessidade de K), em que os resultados podem ser observados na Tabela 9.

Tabela 9 - Resultados dos indicadores estatísticos para estimativas da necessidade de fósforo (P) e potássio (K) das redes selecionadas.

Atributo	Calib.	EQM	P(%)	R^2	r	C	id	Desempenho
Necessidade de fósforo	Geral	0,0317	27,1795	0,9185	0,9588	0,9780	0,9377	Ótimo
	Treinamento	0,0159	20,9722	0,9611	0,9806	0,9893	0,9701	Ótimo
	Valid. int.	0,0641	42,7779	0,8367	0,9181	0,9570	0,8787	Ótimo
	Teste	0,0523	28,3937	0,9397	0,9725	0,9457	0,9197	Ótimo
	Valid. ext.	0,0090	15,1085	0,9840	0,9927	0,9942	0,9869	Ótimo
Necessidade de potássio	Geral	0,0092	11,2639	0,9783	0,9892	0,9945	0,9838	Ótimo
	Treinamento	0,0066	9,7173	0,9844	0,9923	0,9960	0,9884	Ótimo
	Valid. int.	0,0179	17,7425	0,9628	0,9820	0,9895	0,9717	Ótimo
	Teste	0,0049	5,2039	0,9895	0,9953	0,9971	0,9923	Ótimo
	Valid. ext.	0,0120	13,8682	0,9772	0,9896	0,9943	0,9839	Ótimo

Calib.- fase de calibração; EQM - erro quadrático médio; P(%) - erro médio relativo; R^2 - coeficiente de determinação; r – coeficiente de correlação; C – índice de concordância; id - índice de desempenho; Valid. Int. - fase de validação interna; Valid. Ext. - fase de validação externa.

Fonte: Autor (2022).

Em relação a necessidade de P, a rede escolhida apresenta 3 neurônios e foi encontrada no treinamento 786. Em todas as fases de calibração da rede foram observados coeficientes de determinação (R^2) superiores a 0,80, muito próximos da unidade, indicando um bom ajuste. Já para a necessidade de K a rede escolhida apresenta 1 neurônio e foi

encontrada no treinamento 415, em relação aos indicadores avaliados o mesmo comportamento evidenciado para a necessidade de P foi observado para a necessidade de K.

Segundo Garcia (1989) valores do coeficiente de determinação superiores a 0,70 apontam bons ajustes. Fernandes et al. (2020) recomendam o uso de modelos de RNA para estimar a resistência a penetração do solo, os autores encontraram valores inferiores ao deste estudo, entretanto as RNAs apresentaram maior acurácia quando comparada aos modelos de regressões lineares e não lineares múltiplas para obter as estimativas desejadas. Azevedo et al. (2017) encontraram um R^2 de 0,96 avaliando a precisão da MLP em estimar a área foliar (AF) da cultura da couve, valor muito próximo ao encontrado neste estudo. O mesmo autor avaliando a eficiência da MLP em prever a AF da aceroleira, comparando as regressões múltiplas, encontrou valores de R^2 superiores a 0,98 (AZEVEDO et al., 2019), em que os valores corroboram com os deste estudo. Conceição et al. (2021) selecionando modelos de RNAs com maior capacidade preditiva da colheita do mamoeiro encontrou menores erros do quadrado médio e valores de R^2 superiores a 0,99 com 3 neurônios na camada intermediária.


Os valores do coeficiente de correlação (r) encontradas nas duas redes selecionadas (Tabela 9), em ambas as fases de calibração, demonstram elevado grau de relação entre os dados observados (Estimados a partir da tabela de recomendação de fertilizantes, em função da análise de solo) com os dados estimados pela RNA, foram observados valores muito próximos de 1 evidenciando uma relação linear positiva, confirmando a capacidade das redes escolhidas em realizar as estimativas das necessidades de P e necessidade de K. Soares et al. (2021) encontrou valores semelhantes ao deste estudo avaliando o ajuste das RNAs na estimativa de altura e avaliação dos efeitos de consórcio em um plantio misto de *Eucalyptus globulus* (E) e *Acacia mearnsii* (A).

É possível observar uma concordância forte entre os valores observados e os valores estimados pela rede (Tabela 9), para ambos os modelos treinados (necessidade de P e necessidade de K), visto que foram obtidos valores de c superiores a 0,94, muito próximos de 1, constatando a capacidade das redes escolhidas em generalizar o problema. Santos e Silva (2020) avaliando a eficiência da MLP em prever valores diários da evapotranspiração de referência (ETo) encontrou um índice de concordância de 0,99, valor semelhante ao encontrado neste estudo.

A Figura 8 apresenta um comparativo entre os valores observados da necessidade de P e necessidade de K entre os estimados pelas RNAs escolhidas. É possível notar que ambas as redes propiciaram estimativas muito próximas das observadas, evidenciando a capacidade promissora de predição das mesmas. Comportamento semelhante foi observado no estudo de

Barbosa et al (2022), avaliando a capacidade preditiva da MLP em estimar a necessidade de calagem em áreas de pivô central.

Figura 8- Comparativo dos valores geral de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS) e estimado pela rede neural artificial (RNA).



Fonte: Autor (2022).

4.2.1.2 Necessidade de fósforo (P) e potássio (K)

A Tabela 10 apresenta o resultado do Test-t entre os valores observados e estimados pelas redes escolhidas para a necessidade de P e K. Constata-se a capacidade promissora da

RNA em obter as estimativas válidas, visto que o teste não apresenta diferença significativa a 5% de probabilidade, em ambas as redes treinadas. Soares et al. (2014) concluíram em seu estudo, avaliando a eficiência da rede em estimar a retenção de água no solo, que a MLP treinada com algoritmo *backpropagation*, possui grande capacidade no desenvolvimento de ferramentas que auxiliem o setor agrícola.

Tabela 10 - Teste-t para os valores de necessidade de fósforo (P) e necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS) e estimado pela rede neural artificial (RNA).

	Necessidade de P		Necessidade de K	
	OBS	RNA	OBS	RNA
Média	79,17	90,23	525,83	523,01
Variância	2461,48	4363,93	8822,83	7839,74
Observações		120		
Gl		219		
p-value	0,13		0,81	

Gl - graus de liberdade; p-value - teste de t-student significativo a 5% de probabilidade.


Fonte: Autor (2022).

4.2.2 Modelo 2: Rede neural artificial para redução do número de pontos necessários para coleta de amostras

Foram treinadas 20.000 redes para a redução de pontos amostrais necessários para a coleta de dados a campo, no qual novamente a metodologia descrita por Rocha (2019) foi de suma importância para a otimização do esforço computacional. A quantificação do índice de desempenho das redes pode ser observada na Figura 9.

Observa-se que em todas as fases de treinamento e na validação externa que o número de redes com péssimo desempenho foi superior ao número de redes com ótimo desempenho (Figura 9). O mesmo acontecimento foi observado por Rocha et al. (2022) avaliando a eficiência da MLP em prever o índice de área foliar em áreas de pivô central, e também por Barbosa et al. (2022) adaptando a técnica de vizinhança para reduzir a quantidade de amostras necessárias para viabilizar um possível estudo de mapeamento da necessidade de calagem a taxa variada em áreas de pivô central utilizando Redes Neurais Artificiais.

Figura 9- Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de (a) necessidade de fósforo (P) e (b) necessidade de potássio (K), para a cultura do tomate industrial.



Fonte: Autor (2022).

4.2.2.1 Rede selecionada

Foram filtradas as redes que apresentaram ótimo desempenho na fase de validação externa, em que o processo foi realizado para a escolha da melhor rede. Em um segundo momento, foram analisadas as redes que obtiveram ótimo, muito bom e bom desempenho em todas as fases de treinamento. Ao final, somente uma rede, referente a cada estimativa desejada, conseguiu atender aos critérios adotados, e os resultados podem ser observados na Tabela 11.

Tabela 11 - Resultados dos indicadores estatísticos das redes selecionadas, para redução dos pontos necessários para coleta de amostras.

Atributo	Calib.	EQM	P (%)	R ²	r	C	id	Desempenho
Necessidade de fósforo	Geral	0,1134	42,8857	0,7716	0,8815	0,9286	0,8186	Muito bom
	Treinamento	0,0953	30,0516	0,7899	0,8931	0,9408	0,8402	Muito bom
	Valid. int.	0,1212	55,0335	0,5048	0,7445	0,8374	0,6235	Mediano
	Teste	0,2182	99,3185	0,7925	0,9282	0,9140	0,8485	Muito bom
	Valid. ext.	0,0342	8,5301	1,0000	1,0000	0,9834	0,9834	Ótimo
Necessidade de potássio	Geral	0,0230	7,0282	0,9466	0,9736	0,9862	0,9602	Ótimo
	Treinamento	0,0024	1,9866	0,9951	0,9977	0,9987	0,9963	Ótimo
	Valid. int.	0,0334	6,5765	0,9952	0,9978	0,9649	0,9628	Ótimo
	Teste	0,1380	43,5614	0,7827	0,9247	0,9199	0,8506	Ótimo
	Valid. ext.	0,0004	2,7854	0,9996	0,9999	0,9997	0,9995	Ótimo

Calib. - fase de calibração; EQM - erro quadrático médio; P(%) - erro médio relativo; R² - coeficiente de determinação; r - coeficiente de correlação; c - índice de concordância; id - índice de desempenho; Valid. Int. - fase de validação interna; Valid. Ext. - fase de validação externa.


Fonte: Autor (2022).

As redes escolhidas para a redução dos pontos necessários para a coleta de dados a campo, visando uma possível aplicação de P e K a taxa variada, apresentam 4 e 8 neurônios, e foram encontradas nos treinamentos 655 e 6, respectivamente. Na fase de validação externa, quando é apresentado um conjunto de dados não conhecido pela rede, foram observados valores de R² superiores a 0,99 e uma correlação superior a 99% para as duas redes escolhidas. As estimativas das redes apresentaram erros aleatórios (EQM) variando entre 0,0004% e 0,2182%, quando se compara a outros estudos como o de Freitas (2017) estimando os atributos do solo (EQM variando entre 8% e 16%) e Barbosa et al. (2022) estimando a necessidade de calagem (EQM variando entre 0,06 e 0,9%), constata-se a capacidade das redes escolhidas em obter as estimativas e a precisão das mesmas, sendo importante lembrar que quanto menor o valor do erro maior a acurácia.

Um comparativo entre as estimativas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS) com as estimativas obtidas pelas RNAs modelo 2 pode ser observado na Figura 10. Os gráficos de linhas demonstram um

comportamento semelhante entre os dados observados e estimados, indicando que a rede é um método promissor em obter as estimativas desejadas.

Figura 10 - Comparativo geral entre as redes selecionadas para os valores OBS (obtidos utilizando a tabela de recomendação de fertilizantes, em função da análise de solo) e valores estimados pela rede neural artificial (RNA) modelo 2 para a (a) necessidade de fósforo e (b) necessidade de potássio, para a cultura do tomate industrial.



Fonte: Autor (2022).

4.2.2.2 Redução de amostras de coleta de dados visando estimativas para análise geoestatística

O modelo de RNA treinado possibilitou a redução de 40% no número necessário de amostras coletadas em campo e com isso foi possível estimar valores válidos necessários para

a análise geoestatística a serem utilizados no mapeamento da variabilidade espacial do solo para uma possível aplicação de fósforo e potássio a taxa variável.

Barbosa et al. (2022) desenvolveu um modelo no qual conseguiu reduzir em 30% o número de amostras necessárias, o autor diminuiu de 88 pontos amostrais para 62 pontos necessários para a coleta de dados com o intuito de estimar a necessidade de calagem em áreas de pivô central, neste estudo é possível observar uma redução de 10% a mais do que a alcançada pelo autor, em que das 120 amostras serão necessários a coleta a campo de somente 72 pontos, visto que 48 podem ser estimadas pelo modelo treinado.

Quando comparados os dados dos 48 pontos amostrais estimados utilizando a tabela de recomendação de fertilizantes, em função da análise de solo com os 48 pontos estimados pela RNA modelo 2 (Tabela 12), constatou-se que o modelo treinado consiste em um método promissor em obter estimativas válidas das necessidades de P e K, visto que o resultado do Teste-t a 5% de probabilidade revela que não existe diferença significativa para as estimativas de ambas as redes treinadas.


Tabela 12 - Teste-t para os dados de necessidade de fósforo (P) e potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA).


	Necessidade de P		Necessidade de K	
	OBS	RNA	OBS	RNA
Média	516,67	536,34	79,17	89,80
Variância	9503,55	9439,99	2429,08	3994,96
Observações		48		
Gl		89		
p-value	0,32		0,36	

Gl: grau de liberdade; p-value: teste de t-student significativo a 5% de probabilidade.
Fonte: Autor (2022).

A Figura 11 apresenta um esboço representativo da grade amostral com a presença dos 72 pontos utilizados como referência para obter as estimativas de P e K, e um esboço da grade amostral com a presença dos pontos que podem ser estimados pelo modelo 2. Nota-se que a adaptação da técnica de vizinhança consiste em um método promissor para a redução da densidade amostral coletada a campo necessárias para um possível mapeamento da necessidade de P e necessidade de K, em que segundo Barbosa et al. (2022) o modelo treinado propicia a redução de custo relacionados a amostragem do solo e consequentemente a mão de obra necessária para a prática, e também diminuição do valor gasto com a realização de análises de solo.

Figura 11 - (a) Esboço da grade amostral com a presença dos 72 pontos utilizados como referência para obter as estimativas de necessidade de fósforo (P) e necessidade de potássio (K); e (b) Esboço da grade amostral com a presença dos 48 pontos que podem ser estimados pelo modelo 2.





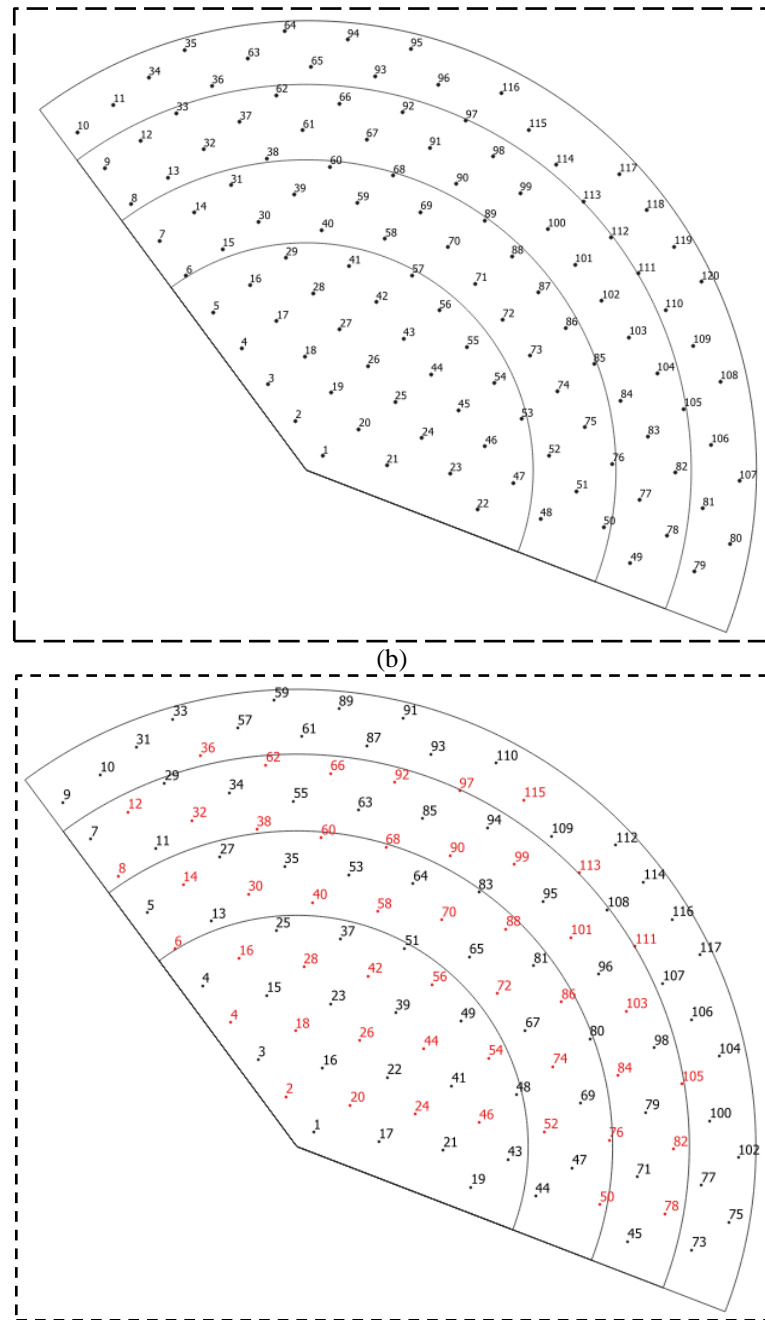
Fonte: Autor (2022).

4.3 ANÁLISE GEOESTATÍSTICA PARA OS DADOS DE NECESSIDADE DE FÓSFORO E POTÁSSIO, MAPAS DE NECESSIDADE DE FÓSFORO E POTÁSSIO E ACURÁCIA DOS MAPAS.

A Figura 12 apresenta um esboço representativo da origem dos dados utilizados para a realização da análise geoestatística.

Figura 12 - Esboço representativo da (a) grade amostral com a presença dos 120 pontos coletados a campo (OBS); e (b) grade amostral com a presença dos 72 pontos coletados a campo e 48 que podem ser estimados pela rede neural artificial (RNA) modelo 2 (OBS+RNA).

(a)



Fonte: Autor (2022).

É possível observar a grade amostral gerada a partir dos 120 pontos coletados a campo (Figura 12a) e a grade amostral gerada a partir do modelo 2, em que os pontos amostrais representados pela cor preta consistem nos pontos coletados a campo e os destacados pela cor vermelha são os pontos que podem ser estimados pela RNA modelo 2 (Figura 12b).

Visando conhecer a distribuição do conjunto de dados e os valores que podem influenciar na qualidade do modelo ajustado foi realizada a estatística descritiva e o resultado pode ser observado na Tabela 13. Verifica-se que os atributos necessidade de P e necessidade de K apresentaram média ($12\% \leq CV \leq 62\%$) a alta variabilidade ($CV > 62\%$) segundo

classificação de Warrick e Nielsen (1980). Os valores discrepantes (*outliers*) presentes no conjunto de dados foram retirados para que não influenciasssem na qualidade dos modelos ajustados.

Tabela 13 - Estatística descritiva da necessidade de fósforo (P) e potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA) modelo 2.

Atributos	Origem dos dados	Média	MD	DP	Var	Cur	Ass	CV
Necessidade de fósforo	OBS	79,17	50,00	49,61	2461,48	-0,16	1,23	62,6695
	OBS+RNA	83,42	50,00	55,74	3107,30	-0,28	1,21	66,8226
Necessidade de potássio	OBS	525,83	600,00	93,93	8822,83	0,40	-1,16	17,8631
	OBS+RNA	533,70	599,99	93,52	8745,92	0,64	-1,30	17,5228

MD: mediana; DP: desvio padrão; Var: variância; Cur: curtose; Ass: assimetria; CV: coeficiente de variação (%);

Fonte: Autor (2022).

A Tabela 14 apresenta os modelos teóricos de semivariogramas ajustados para os atributos de necessidade de P e necessidade de K estimados utilizando a tabela de recomendação de fertilizantes, em função da análise de solo e os estimados pela RNA modelo 2. Ambos os atributos analisados apresentaram dependência espacial, possibilitando a confecção dos mapas de isolinhas (Figura 13). Com relação ao grau de dependência espacial, nota-se que o atributo necessidade de P estimado pela RNA modelo 2 (OBS + RNA) apresentou um IDE forte, e para os demais atributos foi constatada moderado grau de dependência espacial conforme classificação de Cambardella et al. (1994).

Tabela 14 - Modelos teóricos de semivariograma ajustados para os atributos de necessidade de fósforo (P) e necessidade de potássio (K), para a cultura do tomate industrial estimadas utilizando a tabela de recomendação de fertilizantes, em função da análise de solo (OBS), e os estimados pela rede neural artificial (RNA) modelo 2.

Atributos	Origem dos dados	Semivariograma	A	C ₀	C ₀ +C	R ²	IDE	GDE
Necessidade de fósforo	OBS	Esf.	235,17	4.663,88	9.469,67	0,76	49,25	Moderado
	OBS+RNA	Exp.	193,89	275,59	9.617,90	0,77	2,87	Forte
Necessidade de potássio	OBS	Exp.	387,96	952,97	2.815,93	0,94	33,84	Moderado
	OBS+RNA	Exp.	403,96	1.232,17	3.442,41	0,92	35,79	Moderado

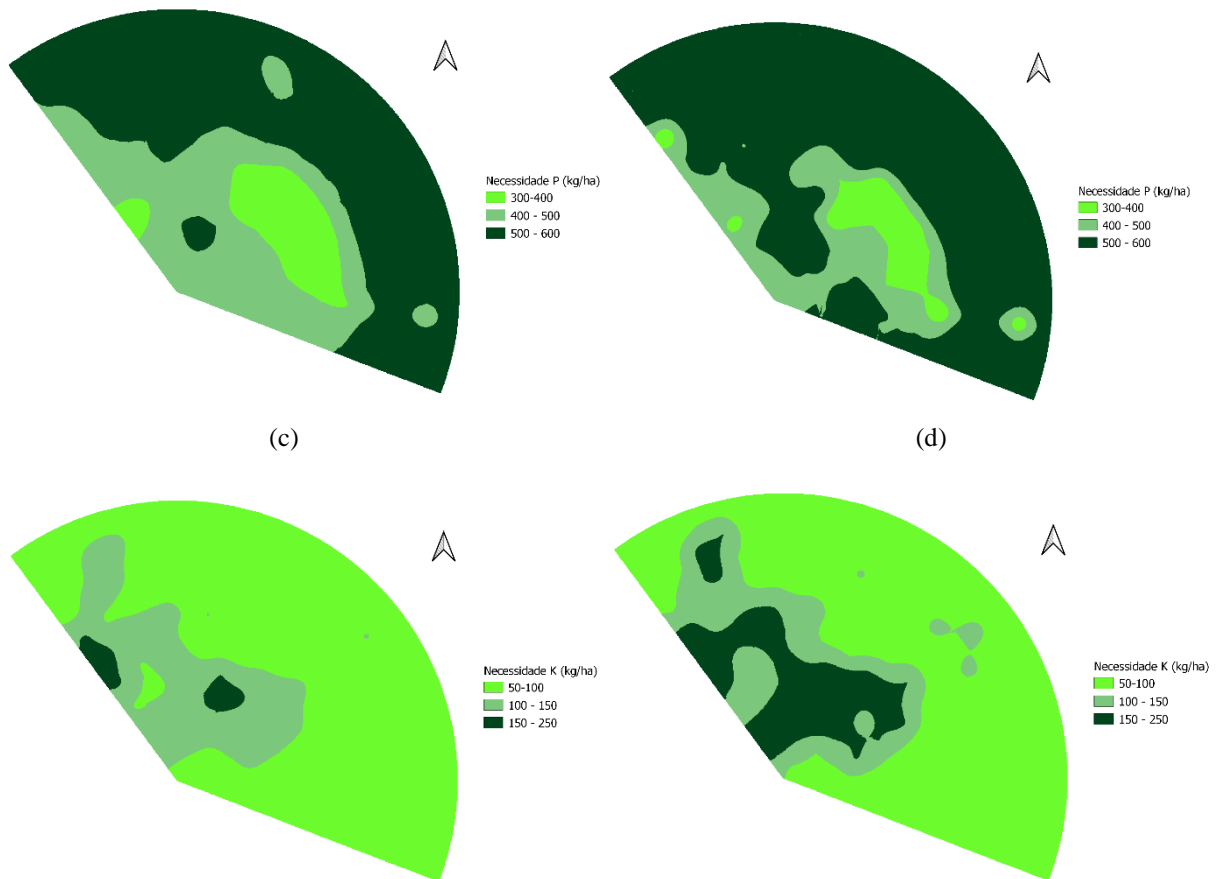
Exp. – exponencial; Esf. – Esférico; Gauss. – gaussiano; A - alcance; C₀ - Efeito Pepita; C₀+C - Patamar; IDE – Índice de dependência espacial; GDE – grau de dependência espacial; R² - coeficiente de determinação; Necessidade de fósforo (kg ha⁻¹); Necessidade de potássio (kg ha⁻¹).

Fonte: Autor (2022).

Os mapas elaborados das necessidades de P e K estimados utilizando a tabela de recomendação de fertilizantes, em função da análise de solo, e os estimados pela RNA modelo 2 podem ser observados na Figura 13. A ácuracia dos mapas foi avaliada por meio dos índices de Kappa e Exatidão global e os resultados podem ser observados na Tabela 15.

Figura 13- Mapas de isolinhas da (a) Necessidade de fósforo (P) estimada utilizando a tabela de recomendação de fertilizantes, em função da análise de solo; (b) necessidade fósforo (P) estimada pela rede neural artificial (RNA) modelo 2; (c) Necessidade de potássio (K) estimada pela rede neural artificial (RNA) modelo 2.

(a) (b)



Fonte: Autor (2022).

Segundo classificação de Krippendorff (2004) os mapas de necessidade de P e necessidade K (Figura 13) apresentaram alta e média acurácia, respectivamente, revelando um grau de similaridade entre os mapas. Com relação ao índice de exatidão global, segundo Anderson et al. (2001) o nível mínimo de acurácia para sugerir uma boa classificação para a exatidão global é $\geq 0,85$, ambos os atributos avaliados apresentaram valores superiores a 85% de exatidão global. Comportamento semelhante ao deste estudo foi observado por Freitas et al. (2022) avaliando a acurácia de mapas de fertilidade do solo obtidos na análise geoestatística a partir de dados estimados por uma rede neural artificial, em que o índice de alguns dos atributos estudados pelo autor apresentaram boa classificação em relação ao índice de exatidão global.

Tabela 15 - Resultados dos índices de acurácia Kappa e Exatidão Global.

Atributo	Índice	
	Kappa	Exatidão global
Necessidade de P	0,82	0,93
Necessidade de K	0,74	0,90

Fonte: Autor (2022).

Nota-se que o modelo proposto permite obter estimativas válidas de P e K para serem utilizadas no estudo da variabilidade espacial do solo. De acordo com Cherubin et al. (2015) a acurácia da caracterização da variabilidade de P e K no solo dependerá da densidade de pontos amostrais coletados, visto que grades amostrais densas propiciam a captação de diferentes escalas de variabilidade dos atributos no solo.

5 CONCLUSÃO

A rede neural artificial com topologia do tipo Perceptron de Múltiplas Camadas (MLP) possibilitou obter estimativas da necessidade de fósforo e da necessidade de potássio

com um ótimo desempenho, coeficientes de determinação superiores a 0,90, indicando bons ajustes, e coeficientes de correlação acima de 91%, mostrando que são eficientes e que podem ser utilizadas como ferramenta para estimar as necessidades de fósforo e potássio em áreas de pivô central, pois apresenta alta capacidade preditiva, e que podem ser utilizadas para tomada de decisão para a adubação do solo visando aumento da produção agrícola.

Foi possível definir a melhor configuração da RNA para obter as estimativas desejadas, em que para a necessidade de fósforo a rede escolhida apresenta 3 neurônios e foi encontrada no treinamento 786, e para a necessidade de potássio a rede escolhida apresenta 1 neurônios e foi encontrada no treinamento 415.

A metodologia utilizada para a obtenção das coordenadas X e Y, e altitude, para a área de pivô central no qual a rede foi desenvolvida, possibilita a universalização da RNA.

A adaptação da técnica de vizinhança propiciou a redução de 40% no número de amostras necessárias para a coleta de dados a campo, contribuindo conseqüentemente com a redução de tempo e custos relacionadas a amostragem do solo e análises laboratoriais, auxiliando no mapeamento da variabilidade espacial do solo.

O índice de Kappa e Exatidão global propiciaram a avaliação da acurácia dos mapas elaborados, em que foi constada média e alta acurácia entre os mapas de necessidades de fósforo e potássio, respectivamente, e valores de exatidão global superiores a 85%, demonstrando um grau de similaridade entre os mapas.

Com a redução do número de amostras a rede consegue obter estimativas válidas de P e K para serem usadas no estudo da variabilidade espacial do solo.

REFERÊNCIAS

ALMEIDA, L.H.C.; SANCHES, P.P.; FRATONI, M.M.J.; OLIVEIRA, E.C.; BARBOSA, A.P.; RICHARDSON, G.; WEST, J.; ZUCARELI, C.; FREGONEZI, G.A.F. Folha índice

representativa do teor de potássio em tomateiro. **Cultura Agronômica**, Ilha Solteira, v.28, n.1, p.65-81, 2019.

ALVES JUNIOR, J.; SENA, C.C.R.; DOMINGOS, M.V.H.; KNAPP, F.M.; ALMEIDA, F.P.; BATTISTI, R.; CASAROLI, D.; EVANGELISTA, A.W.P. Diagnosis of Irrigation Management in the Industrial Tomato Crop in Goiás, Brazil. **Chemical Engineering Transactions**, Milão, v. 87, p. 415-420, 2021.

ALVES, G.R.; TEIXEIRA, I.R.; MELO, F.R.; SOUZA, R.T.G.; SILVA, A.G. Estimating soybean yields with artificial neural networks. **Acta Scientiarum**, Maringá v. 40, e35250, 2018.

AMORMINO JÚNIOR, M. Elementos da natureza e propriedades do solo. IN: CLEMENTE, E.P.; SANTOS, H.G.; PARES, J.G. (Eds.). **Utilização do sistema de informação de solos brasileiros para validação dos atributos da ordem dos latossolos**. Ponta Grossa: Atena Editora, 2018. Cap. 28. p. 303-311.

ARAÚJO JÚNIOR, C.A.; SOUZA, P.D.; ASSIS, A.L.; CABACINHA, C.D.; LEITE, H.G.; SORES, C.P.B.; SILVA, A.A.L.; CASTRO, R.V.O. Artificial neural networks, quantile regression, and linear regression for site index prediction in the presence of outliers. **Pesquisa agropecuária brasileira**, Brasília, v54, p. 00078, 2019.

AZEVEDO, A.M.; ANDRADE JÚNIOR, V.C.; PEDROSA, C.E.; OLIVEIRA, C.M.; DORNAS, M.F.S.; CRUZ, C.D.; VALADARES, N.R. Application of artificial neural networks in indirect selection: a case study on the breeding of lettuce. **Bragantia**, v.74, p,1-7, 2015.

AZEVEDO, A.M.; JÚNIOR, V.C.A.; JÚNIOR, A.S.S.; SANTOS, A.A.; CRUZ, C.D.; PEREIRA, S.L.; OLIVEIRA, A.J.M. Eficiência da estimação da área foliar de couve por meio de redes neurais artificiais. **Horticultura Brasileira**, v.35, p.014-019, 2017.

AZEVEDO, A.M.; SILVEIRA, V.A.; OLIVEIRA, C.M.; PEDROSA, C.E.; LEMOS, V.T.; VALADARES, N.R.; GUIMARÃES, A.G. Predição da área foliar em acerola por redes neurais e regressão múltipla. **Revista Agrária Acadêmica**, v.2, n.3, p.96-105, 2019.

BARBOSA, C.E.B. **Desenvolvimento de rede neural artificial para a predição da necessidade de calagem em área de pivô central**. 2020. 62p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual de Goiás, Anápolis, 2020.

BARBOSA, M.L.; BARROS, R.P.; PINHEIRO, R.A. Aspectos biológicos e produtivos do tomateiro (*Solanum lycopersicum*) sob adubação húmica. **Revista Ambientale**, v.13, n.1, p.72-78, 2021.

BASSOI, L. H.; INAMASU, R.Y.; BERNARDI, A.C.C.; VAZ, C.M.P.; SPERANZA, E.A.; CRUVINEL, P.E. Agricultura de precisão e agricultura digital. **Embrapa**, Brasília, n.20, 2019.

BERNARDI, A.C.C.; BETTIOL, G.M.; GREGO, C.R.; ANDRADE, R.G.; RABELLO, L.M.; INAMASU, R.Y. Ferramentas De Agricultura De Precisão Como Auxílio Ao Manejo Da Fertilidade Do Solo. **Cadernos de Ciência & Tecnologia**, Brasília, v. 32, n.1-2, p. 211-227, 2015.

BERNARDI, A.C.C.; BUENO, J.O.A.; LAURENTI, N.; SANTOS, K.E.L.; ALVES, T.C. Efeito da calagem e fertilizantes aplicados à taxa variável nos atributos químicos do solo e custos de produção de pastagem de capim Tanzânia manejadas intensivamente. **Brazilian Journal of Biosystems Engineering** v.12, n.4, p.368-382, 2018.

BITTAR, R.D. **Redes neurais artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado**. 2016. 112p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual de Goiás, Anápolis, 2016.

BITTAR, R.D.; S. ALVES, M.deF.; MELO, F. R. de. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, Mossoró, v. 31, n. 3, p. 704 – 712, 2018.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes Neurais Artificiais: Teorias e Aplicações**. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2014. 226p.

BRESKA, A.P.; ROBERTSON, L.D.; LABATE, J.A.; KING, B.A.; KING, D.E. Physicochemical and morphological analysis of ten tomato varieties identifies quality traits more readily manipulated through breeding and traditional selection methods. **Journal of Food Composition and Analysis**, v.42, p.16–25, 2015.

CAMARGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, n.1, p.89-97, 1997.

CAMARGO, M.S.; BARBOSA, D.S.; RESENDE, R.H.; KORNDORFER, G.H.; PEREIRA, H.S. Fósforo em solos de cerrado submetidos à calagem. **Biosci. J.**, Uberlândia, v. 26, n.2, p. 187-194, 2010.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F.; KONOPKA, A.E. Field-scale variability of soil properties in central Iowa soils. *Soil Science Society of America Journal*, v.58, p.1501-1511, 1994.

CASTRO, W.J.; CASTRO, M.L.L.; LIMA, J.O.; OLIVEIRA, L.F.C.; RODRIGUES, C.; FIGUEIREDO, C.C. Erodibilidade de solos do cerrado Goiano. **Revista em Agronegócios e Meio Ambiente**, v.4, n.2, p. 305-320, 2011.

CENTURIÃO, N.C.; USHIWATA, S.Y.; VILAR, C.C.; MARIMON JUNIOR, B.H. Efeitos de biochars (carvões) provenientes de diferentes materiais na fertilidade de dois solos do Cerrado. **Revista de Ciências Agroambientais**, v.19, n.2, p. 71-80, 2021.

CHERUBIN, M.R.; SANTI, A.L.; EITELWEIN, M.T.; AMADO, T.J.C.; SIMON, D.H.; DAMIAN, J. M. Dimensão da malha amostral para caracterização da variabilidade espacial de fósforo e potássio em Latossolo Vermelho. **Pesquisa Agropecuária Brasileira**, Brasília, v.50, n.2, p.168-177, 2015.

CHERUBIN, M.R.; SANTI, A.L.; EITELWEIN, M.T.; MENEGO, D.R.; ROS, C.O. da; PIAS, O.H. de C.; BERGHETTI, J. Eficiência de malhas amostrais utilizadas na

caracterização da variabilidade espacial de fósforo e potássio. **Ciência Rural**, Santa Maria, v.44, n.3, p.425-432, 2014.

COMISSÃO DE FERTILIDADE DE SOLOS DE GOIÁS. Recomendações de corretivos e fertilizantes para Goiás: 5ª aproximação. Goiânia, UFG/EMGOPA, (Informativo Técnico 1), 1988. 101p.

CONAB - Companhia Nacional de Abastecimento. Compêndio de Estudos Conab / Companhia Nacional de Abastecimento. – v.1 (2016-). - Brasília: Conab, 2016.
 CONCEIÇÃO, L.V.; NEPOMUCENO, C.F.; GUIMARÃES, B.V.C.; SILVA, S.O. Predição de produtividade do mamoeiro (Carica PapayaL.) por Redes Neurais Artificiais. **Do** , v. 10, n.12, e595101220692, 2021.

CONCEIÇÃO, L.V.; NEPOMUCENO, C.F.; GUIMARÃES, B.V.C.; SILVA, S.O. Predição de produtividade do mamoeiro (Carica PapayaL.) por Redes Neurais Artificiais. **Research, Society and Development**, Vargem Grande Paulista, v. 10, n.12, e595101220692, 2021.

CUNHA, J.P.B; MACHADO, T.A.; SANTOS, F.L.; COELHO, L.M. Perdas na colheita de tomate industrial em função da regulagem da colhedora. **Pesquisa Agropecuária Tropical**, Goiânia, v. 44, n. 4, p. 363-369, 2014.

DORNELLES, E.F.; KRAISIG, A.R.; SILVA, J.A.G. da; SAWICKI, S.; ROOS-FRANTZ, F.; CARBONERA, R. Inteligência artificial na otimização de densidade de semeadura e simulação de rendimento para aveia. **Revista Brasileira de Engenharia Agrícola e Ambiente**, Campina Grande, v.22, n.3, p.183-188, 2018.

FAGUNDES, N.C.A.; PAIS, A. de J. R.; SOUZA, C.R. de; SANTOS, P.F.; ALMEIDA, H. de S.; VIEIRA, F. de A.; OLIVEIRA-FILHO, A.T. de; VAN DEN BERG, E.; CARVALHO, D.; SANTOS, R.M. dos. Floristic and structural relationships in seasonally dry tropical forests on limestone outcrops. **Scientia Forestalis**, Piracicaba, v. 48, n. 127, p. 3294-3305, 2020.

FERNANDES, M.M.H. et al. Estimation of soil penetration resistance with standardized moisture using modeling by artificial neural networks. **Catena**, Países Baixos, v.189, p.104-505, 2020.

FILGUEIRA, F. A. R. Manual de olericultura: agrotecnologia moderna na produção e comercialização de hortaliças. Viçosa: UFV, 2008. 422p.

FILGUEIRAS, T.S. **Gramíneas do Cerrado**. Rio de Janeiro: IBGE, 2021. 630 p.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes Neurais Artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, Paraná, v. 1, n. 13, p. 47-57, 2016.

FLORES, J.H.F. **Comparação de modelos MLP/RNA e modelos BOX-JENKINS em series temporais não lineares**. 2009. 133p. Dissertação (Pós - Graduação em Engenharia de Produção), Universidade Federal do Rio Grande do Sul. Porto Alegre, 2009.

FONTANA, A.; TEIXEIRA, W.G.; BALIEIRO, F.C.; MOURA, T.P.A.; MENEZES, A.R.; SANTANA, C.I. **Pesquisa agropecuária brasileira, Brasília**, v.51, n.9, p.1457-1465, 2016.

FREITAS, E.F.M. **Rede neural artificial na predição de atributos físicos e químicos do solo**, 2018. 103p. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás. Anápolis, 2018.

GELAIN, E.; BOTTEGA, E.L.; MOTOMIYA, A.V.A.; MARIN, C.K.; OLIVEIRA, Z.B. Dependência e correlação espacial dos atributos de solo em função do arranjo amostral. **TECNO-LÓGICA**, Santa Cruz do Sul, v. 25, n. 1, p. 145-172, 2021.

GONZALEZ, R.C.; WOODS, R.E. **Processamento Digital de Imagens**, 3.ed. São Paulo: Pearson, 2010. 642p.

GUEDES, E.; SANTOS, R.F.; GUEDES, C.R.; SOUZA, E.P.; CARDOSO, A.I.I. Fontes de potássio para produção e qualidade de tomate cultivado em sistema orgânico em ambiente protegido. **Research, Society and Development**, São Paulo, v.10, n.14, p.2-11, 2021.

GUIMARÃES, B.V.C.; DONATO, S.L.R.; ASPIAZÚ, I.; AZEVEDO, A.M. Predição da produtividade de bananeiras ‘Prata-Anã’ e ‘BRS Platina’ por redes neurais artificiais. **Pesquisa Agropecuária Tropical**, Goiânia, v. 51, e66008, 2021.

GUIMARÃES, B.V.C.; DONATO, S.L.R.; AZEVEDO, A.M.; ASPIAZÚ, I.; SILVA JUNIOR, A.A. Prediction of ‘Gigante’ cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.22, n.5, p.315-319, 2018.

Haykin, S. (2001). *Redes neurais: princípios e prática*. Porto Alegre: Bookman. 900 p.
HERUBIN, M.R.; SANTI, A.L.; BASSO, C.J.; EITELWEIN, M.T.; VIAN, A.L. Caracterização e estratégias de manejo da variabilidade espacial dos atributos químicos do solo utilizando a análise dos componentes principais. **Enciclopédia Biosfera**, v.7, p.196-210, 2011.

HOFFMAN, A.; COLOMBO, J.N.; KRAUSE, M.R.; HADDADE, I.R.; MATIELLO, H.N. Produção de mudas de tomate em substrato comercial enriquecido com superfosfato simples. **Agrotrópica**, v.29, n.3, p.251 – 258, 2017.

IBGE – Instituto Brasileiro de Geografia e Estatística. Banco de informações ambientais: Pedologia, 2022. Disponível em: <BDIA - Banco de Dados de Informações Ambientais (ibge.gov.br)>. Acesso em: 10 out. 2021.

IBGE – Instituto Brasileiro de Geografia e Estatística. Levantamento sistemático da produção agrícola, 2021. Disponível em: <TSistema IBGE de Recuperação Automática - SIDRA>. Acesso em: 05 out. 2021.

IBGE – Instituto Brasileiro de Geografia e Estatística. Portal de Mapas, 2022. Disponível em: <Portal de mapas do IBGE>. Acesso em: 12 jan. 2022.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

LOCATELLI, T.; FREITAS, I.L.J.; FREITAS, S.P.; VITÓRIA, E.L.; BATISTA, A.G.; LOCATELLI, T.P. Redes neurais artificiais para estimativa da fitotoxicidade de Saflufenacil em mudas de Café Conilon. **Revista em Agronegócio e Meio Ambiente**, Maringá, v.14, n.4, p.9032, 2021.

LOPES, K.A. do L.; AGUIAR, F.I. dos S.; OLIVEIRA, I.R. de; DANTAS, J.S. Variabilidade espacial de atributos químicos de um argissolo amarelo distrocoeso em diferentes densidades de amostragem. **Revista Científica Rural**, Bagé, v. 22, n. 2, p. 29-42, 2020.

LU, Z.; WANG, J.; GAO, R.; YE, F.; ZHAO, G. Sustainable valorisation of tomato pomace: A comprehensive review. **Trends in Food Science & Technology**, v.86, p.172–187, 2019.

LUZ, J.M.Q; BITTAR, C.A.; OLIVEIRA R.C.; NASCIMENTO, A.R.; NOGUEIRA, A.P.O. Desempenho e divergência genética de genótipos de tomate para processamento industrial. **Horticultura Brasileira**, Vitória da Conquista, v. 34, n. 4, p. 483-490, 2016.

MARTINIANO, A.; FERREIRA, R.P.; FERREIRA, A.; FERREIRA, A.; SASSI, R.J. Utilizando uma rede neural artificial para aproximação da função de evolução do sistema de Lorentz. **Revista Produção e Desenvolvimento**, Rio de Janeiro, v.2, n.1, p.26-38, 2016.

MATIAS, S.S.R.; MATOS, A.P. de; LANDIM, J. S.P.; FEITOSA, S.F.; ALVES, M.A.B.; SILVA, R.L. Recomendação de calagem com base na variabilidade espacial de atributos químicos do solo no Cerrado brasileiro. **Revista de Ciências Agrárias**, Lisboa, v. 42, n. 4, p. 896-907, 2019.

MATOS, E.C.T. de; RODRIGUES, L.A.; SOUZA, P. de A.; SILVA, R. V. da; FARIA JR., R.T. Espectroscopia fotoacústica para analisar a fertilidade de solos tratados com biochar e micorriza. **Química Nova**, Rio de Janeiro, v. 41, n. 9, p. 989-998, 2018.

MENEGHETTE, H.H.A.; LAZARINI, E.; BOSSOLANI, J.W.; PARRA, F.; HAYASHI, F.K. Doses de fósforo e potássio em plantas de amendoim na presença e ausência de adubação foliar. **Revista Brasileira de Engenharia de Biosistemas**, v.11, n.2, p.125-134, 2017.

MENESES, K.C.; APARECIDO, L.E.O.; MENESES, K.C.; FARIAS, M.F. Estimating Potential Evapotranspiration in Maranhão State Using Artificial Neural Networks. **Revista Brasileira de Meteorologia**, São José dos Campos, v. 35, n. 4, p. 675-682, 2020.

MIXQUITITLA-CASBIS, G.; VILLEGAS-TORRES, O. Importância dos fosfatos e fosfitos na nutrição de culturas. **Acta Agrícola Y Pecuária**, v.2, n.3, p.55-61, 2016.

NAIKA S; JEUDE JVL; GOFFAU M; HILMI M; DAM BV. 2006. A cultura do tomate. Wageningen: Fundação Agromisa e CTA. 104p.

NETA, M.N.A.; MOTA, W.F.; PEGORARO, R.F.; PACHECO, M.C.; BATISTA, C.M.; SOARES, M.C. Agronomic yield and quality of industrial tomatoes under NPK doses. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.24, n.1, p.59-64, 2020.

PAPPU, S.M.J.; GUMMADI, S.N. Artificial neural network and regression coupled genetic algorithm to optimize parameters for enhanced xylytol production by *Debaryomyces nepalensis* in bioreactor. **Biochemical Engineering Journal**, v.120, p.136-145, 2017.

PERES, L.A.C.; TERRA, N. F.; REZENDE, C.F.A. Produtividade do tomate industrial submetido a adubação organomineral em cobertura. **Brazilian Journal of Development**, Curitiba, v. 6, n. 3, p. 10586-10599, 2020.

POLIDORO, J.C.; SANTOS, M.L.M; LUMBRERAS, J.F.; COELHO, M.R.; CARVALHO FILHO, A.; MOTTA, P.E.F.; CARVALHO JUNIOR, W.; ARAÚJO FILHO, J.C.; CURCIO, G.R.; CORREIA, J.R.; MARTINS, E.S.; SPERA, S.T.; OLIVEIRA, S.R.M.; BOLFE, E.L.; MANZATTO, C.V.; TÔSTO, S.G.; VENTURIERI, A.; SÁ, I.B.; OLIVEIRA, V.A.; SHINZATO, E.; ANJOS, L.H.C.; VALLADARES, G.S.; RIBEIRO, J.L.; MEDEIROS, P.S.C.; MOREIRA, F.M.S.; SILVA, L.S.L.; SEQUINATTO, L.; AGLIO, M.L.D.; DART, R.O. **Programa Nacional de Solos do Brasil (PronaSolos)**. Rio de Janeiro: Embrapa Solos, 2016. 55 p.

Porto Velho. **Brazilian Journal of Development**, Curitiba, v.7, n.10, p. 95257-95268 2021. PREZOTTI, L.C.; MARTINS, A.G. **Guia de interpretação de análise de solo e foliar**. Vitória, ES: Incaper, 2013. 104 p.

QUINTANILHA, K.T.; TAVARES, E.B.; CORCIOLI, G. Mapeamento do fluxo dos tomates comercializados no CEASA-Goiás em 2017 e 2018. **Research, Society and Development**, v.8, n.10, p.e138101199, 2019.

R Core Team. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2015.

REETZ, H.F. **Fertilizantes e o seu uso eficiente**. São Paulo: ANDA, 2017. 178 p.

RIBEIRO, H.G.; BINOTI, D.H.B.; OLIVEIRA, N.P.L.; RODRIGUES, L.M.; FRANÇA, A.C.S. Utilização de redes neurais artificiais para estimação da biodiversidade de fragmentos florestais. **Cadernos Camilliani**, Cachoeiro de Itapemirim, v.16, n.4, p.1754-1770, 2019.

ROCHA, I.J.F. **Estimativa do índice de área foliar para cultura irrigada por meio de pivô central utilizando imagens de sensoriamento remoto e redes neurais artificiais**. 2019. 125p. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás. Anápolis, 2019.

RODRIGUES, J. Análise geoestatística da distribuição da malária na área urbana de SALES, D.L.A.; ALVES JÚNIOR, J.; CASAROLI, D.; EVANGELISTA, A.W.P.; SOUZA, J.M.F. Estimativa de evapotranspiração e coeficiente de cultura do tomateiro industrial utilizando o algoritmo safer. **Revista Irriga**, Botucatu, v. 22, n. 3, p. 629-640, 2017.

SANO, E.E.; ROSE, R.; SCARAMUZZA, C.A. de M.; ADAMI, M.; BOLFE, E.L.; COUTINHA, A.C.; ESQUERDO, J.C.D.M.; MAURANO, L.E.P.; NARVAES, I. da S.; OLIVEIRA FILHO, F.J.B. de; SILVA, E.B. da; VICTORIA, D. de C.; FERREIRA, L.G.; BRITO, J.L.S.; BAYMA, A.P.; OLIVEIRA, G.H. de; BAYMA-SILVA, G. Land use

dynamics in the Brazilian Cerrado in the period from 2002 to 2013. **Pesquisa Agropecuária Brasileira**, Brasília, v.54, e00138, 2019.

SANTOS, D.S.; SILVA, R.M. Aplicação de redes neurais MLP na predição da evapotranspiração de referência. **Brazilian Journal of Development**, Curitiba, v.6, n.5, p.25293-25305, 2020.

SANTOS, H.G. et al. **Sistema brasileiro de Classificação de Solos**. 5. ed. Brasília: Embrapa, 2018. 590 p.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A.; ARAÚJO FILHO, J.C.; OLIVEIRA, J.B.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. Brasília, DF: Embrapa, 2018. 355 p.
SCHNEIDER, P.R. **Análise de regressão aplicada à Engenharia Florestal**. Santa Maria: ed. UFSM/CEPEF, 1998. 236p.

SEAPA - Secretaria de Estado De Agricultura, Pecuária e Abastecimento. **Radiografia do Agro**. p. 116, 2020. Disponível em: < Radiografia do Agro - SEAPA (agricultura.go.gov.br)>. Acesso em: 10 jun 2021.

SEGATTO, T.A.; PRADEBON, L.C.; PRADEBON, E.D.; SANTOS, I.J.; SCHIAVO, J.; MEOTTI, M. G. L. Caracterização de atributos de qualidade do solo e recomendação de calagem e adubação para sistemas de cultivo com inclusão de soja. **Brazilian Journal of Animal and Environmental Research**, Curitiba, v. 3, n. 1, p.225-231, 2020.

SEVERIANO, E. da C.; OLIVEIRA, G.C. de; DIAS JÚNIOR, M. de S.; COSTA, K.A. de P.; SILVA, F. G. S.; FERREIRA FILHO, S. M. Structural changes in latosols of the cerrado region: i – relationships between soil physical properties and least limiting water range. **Revista brasileira de ciência do solo**, Viçosa, v. 35, n. 3, p. 773-782, 2011.

SHAPIRO, S. S.; WILK, M. B. **Na analysis of variance test for normality (complete sample)**. Biometrika, London, v.52, n.3/4, p.591-611, 1965.

SILVA JUNIOR, A.R.; RIBEIRO, W.M.; NASCIMENTO, A.D.R.; SOUZA, C.B. Cultivo do tomate industrial no Estado de Goiás: evolução das áreas de plantio e produção. **Conjuntura Econômica Goiana**, v. 34, p. 97-109, 2015.

SILVA, C.J.; PONTES, N.C.; GOLYNSKI, A.; BRAGA, M.B.; QUEZADO-DUVAL, A.M.; SILVA, N. E. P. Performance of processing tomatoes under different supply levels of crop evapotranspiration. **Horticultura Brasileira**, Brasília, v.36, n.3, p. 299-305, 2018.
pro, E.M.; SANTOS, M.M.; LOPES, M.B.S.; FIDELIS, R.R.; ROCHA, W.S.; CHAGAS JÚNIOR, A.F. Eficiência de rizóbios sob doses de fósforo na cultura do feijão-caupi. **Revista Brasileira de Agropecuária Sustentável**, v.9, n.2, p.67-77, 2019.

SILVA, E.R.O. da; BARROS, M.M. de; PEREIRA, M.G.; GOMES, J.H.G.; SOARES, S. da C. Effects of spatial variability of soil chemical parameters on Tifton 85 grass yield. **Revista Caatinga**, Mossoró, v. 33, n. 1, p. 236 – 245, 2020.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A (2016). **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**, 2 edn, Artliber Editora Ltda, São Paulo, SP, Brasil.

SILVA, J.; GUEDES, I.M.R.; LIMA, C.E.P. Adubação e nutrição. IN: CLEMENTE, F.M.V.T.; BOITEUX, L (Eds.). **Produção de Tomate para processamento industrial**. Brasília DF: Embrapa, 2012. cap. 5, p. 105-127.

SILVA, L.M.; BASÍLIO, S.A.; SILVA JÚNIOR, R.L.; BENETT, K.S.S.; BENETT, C.G.S. Aplicação de nitrogênio, potássio e cálcio na cultura da cenoura. **Revista de Agricultura Neotropical**, Cassilândia, v.4, n.3, p.69-76, 2017.

SILVA, M. de O.; VELOSO, C.L.; NASCIMENTO, D.L. do; OLIVEIRA, J. de; PEREIRA, D. de F.; COSTA, K. D. da S. Indicadores químicos e físicos de qualidade do solo. **Brazilian Journal of Development**, Curitiba, v.6, n.7, p.47838-47855, 2020.

SILVA, M.B.; OLIVER, F.C.; CRUZ, R.M.S.; MARCHI, B.A.; ALMAS, L.R.M.; ALBERTON, O. Resposta do fungo micorrízico arbuscular rhizophagus clarus e adição de substâncias húmicas no crescimento do tomateiro (*Solanum Lycopersicum* L.). **Revista Scientia Agraria**, Curitiba, v.18 n.3, p.123-130, 2017.

SILVA, V.L. da; OLIVEIRA, A.C. de; FARIAS, G.A.; SILVA, W.V. da; SILVA, L.P. da. Doses de NPK em tomateiro Marmande e seu desempenho a campo no cerrado. **Revista de Agricultura Neotropical**, Cassilândia-MS, v.5, n.1, p.54-59, 2018.

SOARES, C.S.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, Santa Maria, v.45, n.11, p.1987- 1993, 2015.

SOARES, G.M.; SILVA, L.D.; HIGA, A.R.; SIMON, A.A.; SÃO JOSÉ, J.F.B. Artificial neural networks (ANN) for height estimation in a mixed-species plantation of *Eucalyptus globulus* labill and *Acacia mearnsii* de wild. **Revista Árvore**, Viçosa, v.45, 2021.

SOARES, G.M.; SILVA, L.D.; HIGA, S.A.R.; SIMON, A.A.; SÃO JOSÉ, F.B. Artificial neural networks (ANN) for height estimation in a mixed-species plantation of *Eucalyptus globulus* labill and *Acacia mearnsii* de wild. **Revista Árvore**, v.45, p.4512, 2021.

SOUSA, R.F.; NASCIMENTO, J.L.; FERNANDES, E.P.; LEANDRO, W.M.; CAMPOS, A.B. Matéria orgânica e textura do solo em veredas conservadas e antropizadas no bioma Cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.15, n.8, p.861–866, 2011.

SOUZA, P.D.; ARAÚJO JÚNIOR, C.A.; CABACINHA, C.D.; OLIVEIRA, L.S.; LOPES JUNIOR, C.L.; ALMEIDA, W. **Nativa**, Sinop, v.9, n.1, p.54-61, 2021.

SOUZA, Z.M. de; SOUZA, G.S. de; MARQUES JÚNIOR, J.; PEREIRA, G. T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.261-268, 2014.

SRINIVASAN, D.; LIEW, A.C.; CHANG, C.S. A neural network short-term load forecaster. **Electric Power Systems Research**, Holanda, v.28, n.3, p.227-234, 1994.

TEODORO, P.E.; Laís BARROSO, M.A.; NASCIMENTO, M.; TORRES, F.E.; SAGRILO, E.; SANTOS, A. dos; RIBEIRO, L. P. Redes neurais artificiais para identificar genótipos de

feijão-caupi semiprostrado com alta adaptabilidade e estabilidade fenotípicas. **Pesquisa Agropecuária Brasileira**, Brasília, v.50, n.11, p.1054-1060, 2015.

TUKEY, J.W. **A survey of sampling from contaminated distribution**. In: OLKIN, I. Contributions to probability and statistics. California: Stanford University Press, 1960. Chapter 39, p.448-485.

VENDRAME, P.R.S.; EBERHARDT, D.N.; BRITO, O.R.; MARCHÃO, R.L.; QUANTIN, C.; BECQUER, T. Formas de ferro e alumínio e suas relações com textura, mineralogia e carbono orgânico em Latossolos do Cerrado. **Semina: Ciências Agrárias**, Londrina, v.32, n.1, p. 1657-1666, 2011.

VERGARA, R.deO.; GAZOLLA-NETO, A.; GADOTTI, G.I. Space distribution of soybean seed storage potential. **Revista Caatinga**, Mossoró, v. 32, n. 2, p. 399 -410, 2019.

WARRICK, A.W.; NIELSEN D.R. Spatial variability of soil physical properties in the field. In: HILLEL, D. Applications of soil physics. New York: Academic Press, p. 319-344, 1980.

WILLMONT, C.J. On the validation of models. **Physical Geography**, Palm Beach, v.2, n. 2, p.184-194, 1981.

ZAYAT, J.Z.M.; BERNARDES NETO, J.F.; GOLINSKY, A.; MARQUES, P.V.F.; GONÇALVES, G.P.; TOFOLES, A.M. Viabilidade econômica da produção de tomate do tipo saladete no sul do estado de Goiás. **Revista Ibero-Americana de Humanidades**, Ciências e Educação, São Paulo, v.8, n.06, 2022.