

UNIVERSIDADE ESTADUAL DE GOIÁS  
UNIDADE UNIVERSITÁRIA DE CIÊNCIAS EXATAS E TECNOLÓGICAS  
MESTRADO *STRICTO SENSU* EM ENGENHARIA AGRÍCOLA

PREDIÇÃO DA NECESSIDADE DE CALAGEM EM ÁREA DE PIVÔ CENTRAL POR  
MEIO DE REDE NEURAL ARTIFICIAL.

Carlos Eduardo Bento Barbosa

ANÁPOLIS – GO  
OUTUBRO / 2020

# **PREDIÇÃO DA NECESSIDADE DE CALAGEM EM ÁREA DE PIVÔ CENTRAL POR MEIO DE REDE NEURAL ARTIFICIAL.**

Carlos Eduardo Bento Barbosa

Orientadora: Profa. Dra. Sueli Martins De Freitas Alves

Co-orientador: Prof. Me. Ivandro José de Freitas Rocha

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.

ANÁPOLIS – GO  
OUTUBRO / 2020



## 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 Carlos Eduardo Bento Barbosa

E-mail carloskum.ce@gmail.com

### Dados do trabalho

Título Previsão da necessidade de Calagem em área de pivô central por meio de rede neural artificial

### Tipo

( ) Tese (X) Dissertação

Curso/Programa Programa de Pós-graduação Mestrado em Engenharia Agrícola

Concorda com a liberação documento [] SIM [ ] NÃO<sup>1</sup>

Anápolis Local 15/10/2021 Data

Carlos Eduardo Bento Barbosa  
Assinatura do autor (a)

[Assinatura]  
Assinatura do orientador (a)

### <sup>1</sup> 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).

BC284      Bento Barbosa, Carlos Eduardo  
p            PREDIÇÃO DA NECESSIDADE DE CALAGEM EM ÁREA DE PIVÔ  
              CENTRAL POR MEIO DE REDE NEURAL ARTIFICIAL / Carlos  
              Eduardo Bento Barbosa; orientador Sueli Martins de  
              Freitas Alves; co-orientador Ivandro José de Freitas  
              Rocha. -- Anápolis, 2020.  
              62 p.

              Dissertação (Mestrado - Programa de Pós-Graduação  
              Mestrado Acadêmico em Engenharia Agrícola) -- Câmpus  
              Central - Sede: Anápolis - CET, Universidade Estadual  
              de Goiás, 2020.

              1. Ciências Agrárias. 2. Fertilidade e correção do  
              solo. 3. Inteligência Artificial. 4. Multilayer  
              Perceptron. I. Martins de Freitas Alves, Sueli ,  
              orient. II. de Freitas Rocha, Ivandro José, co-orient.  
              III. Título.



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 dois de outubro de dois mil e vinte

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

CANDIDATO **Carlos Eduardo Bento Barbosa**

BANCA EXAMINADORA:

1. Profa. Dra. **Sueli Martins de Freitas Alves (Orientadora/UEG)**
2. Prof. Dr. **Francisco Ramos de Melo (UEG)**
3. Prof. Dr. **Vinícius Almeida Oliveira (FAMA)**

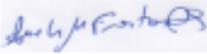
TÍTULO DA DISSERTAÇÃO: “**Predição de necessidade de calagem em área de pivô central por meio de Rede Neural Artificial**”

LOCAL: Via Webconferência - <https://meet.google.com/wka-dgip-crt> (Conforme Portaria CAPES n. 036/2020; e Instrução Normativa n.1, 31/03/2020, da Pró-reitoria de Pesquisa e Pós-graduação – UEG).

HORÁRIO DE INÍCIO: 14:00 horas, em sessão pública, após exposição de cerca de 40 minutos, o candidato 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, com correções.

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

Anápolis, 02 de outubro de 2020.

Orientador: \_\_\_\_\_ 

\_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

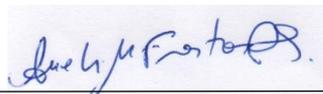
Candidato: \_\_\_\_\_ 

**PREDIÇÃO DA NECESSIDADE DE CALAGEM EM ÁREA DE PIVÔ CENTRAL  
POR MEIO DE REDE NEURAL ARTIFICIAL.**

Por: Carlos Eduardo Bento Barbosa

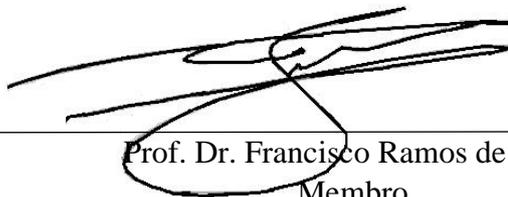
Dissertação apresentada como parte das exigências para obtenção do título de  
MESTRE EM ENGENHARIA AGRÍCOLA

Aprovada em: 02 de outubro de 2020.



---

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



---

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



---

Prof. Dr. Vinícius Almeida Oliveira  
Membro  
FAMA

Aos meus familiares, em especial a meu pai, Cleomar Ferreira Barbosa, a minha mãe, Maria Aparecida Bento Barbosa, a meu irmão, Pablo Rafael Bento Barbosa, a minha namorada, Ana Clara Maciel David, que sempre incentivaram meu crescimento e acreditaram em meu potencial. Aos meus queridos avós, Sérgio Sousa Barbosa, Maria José Ferreira Barbosa (*in memoriam*) e Geralda Abadia Bento (*in memoriam*).

## AGRADECIMENTOS

Primeiramente a Deus, criador de todas as coisas, que em sua imensa misericórdia e amor concedeu-me as ferramentas necessárias para que este trabalho pudesse ser concluído.

A minha estimada professora e orientadora Dra. Sueli Martins de Freitas Alves, que com a firmeza e paciência necessárias guiou-me em todo este trajeto de busca ao conhecimento. Que eu também possa contribuir para os demais profissionais com a mesma grandeza e simplicidade que lhe são admiráveis.

Ao produtor Robson Souza Silva e aos responsáveis técnicos Felipe Fernando Batista Silva e Nivaldo Assis de Moraes pela disponibilização da área experimental e pelas informações cedidas para realização da pesquisa.

Aos meus amigos, Caroline Xavier, Sabrina Dias, Radson Murilo, Felipe Alves, Rodrigo Starneck, Robson Félix e Bryan Augusto pela responsabilidade e companheirismo que sempre se fizeram presentes nesta jornada.

Aos professores: Guiliano Rangel Alves e Ivandro José, por toda contribuição e orientação no desenvolvimento deste projeto.

Aos professores do mestrado. Em especial ao Prof. Dr. André José de Campos, a Profa. Dra. Roberta Passini e ao Prof. Dr. Francisco Ramos de Melo, pela humildade e prontidão às quais sempre estavam dispostos a ajudar.

Ao técnico do laboratório de Engenharia Agrícola, seu Waldeir, e à secretária do programa de mestrado, Eliete Feitosa, por todo o auxílio nas tarefas diárias.

À Universidade Estadual de Goiás - UEG, Campus de Ciências Exatas e Tecnológicas - CCET, ao departamento de Engenharia Agrícola e ao Programa de Pós-Graduação em Engenharia Agrícola.

A todos, que de maneira direta ou indireta, contribuíram para a realização deste trabalho, meu muito obrigado, pois somente com a colaboração, de cada um, foi possível chegar ao objetivo final. Deus os abençoe imensamente!

## SUMÁRIO

<b>RESUMO</b> .....	<b>13</b>
<b>ABSTRACT</b> .....	<b>14</b>
<b>1. INTRODUÇÃO</b> .....	<b>11</b>
<b>2. REVISÃO DE LITERATURA</b> .....	<b>14</b>
2.1. SOLOS .....	14
2.2. CALAGEM.....	16
2.3. AGRICULTURA DE PRECISÃO .....	21
2.4. REDES NEURAIIS ARTIFICIAIS .....	23
<b>3. MATERIAL E MÉTODOS</b> .....	<b>27</b>
3.1. CARACTERIZAÇÃO E LOCALIZAÇÃO DA ÁREA DE ESTUDO .....	27
3.2. MAPEAMENTO DA ÁREA E FORMAÇÃO DA GRADE AMOSTRAL .....	27
3.3. DETERMINAÇÃO DOS ATRIBUTOS FÍSICOS E QUÍMICOS DO SOLO.....	28
3.4. ESTATÍSTICA DESCRITIVA .....	29
3.5. REDE NEURAL ARTIFICIAL .....	29
3.6. VALIDAÇÃO DO MODELO.....	35
<b>4. RESULTADOS E DISCUSSÃO</b> .....	<b>38</b>
4.1. ANÁLISE DESCRITIVA E EXPLORATÓRIA .....	38
4.2. TREINAMENTO DAS REDES NEURAIIS ARTIFICIAIS .....	39
<b>4.2.1. Modelo 1: Rede neural artificial para estimativas da necessidade de calagem</b> .....	<b>41</b>
4.2.1.1. Escolha da rede.....	41
4.2.1.2. Rede escolhida.....	43
4.2.1.3. Necessidade de calagem .....	46
<b>4.2.2. Modelo 2: Rede neural artificial para redução do número de pontos necessários para coleta de amostras.</b> .....	<b>47</b>
4.2.2.1. Escolha da rede.....	48
4.2.2.2. Rede escolhida.....	49
4.2.2.3. Redução de amostras .....	52
<b>5. CONCLUSÃO</b> .....	<b>54</b>
<b>6. REFERÊNCIAS</b> .....	<b>55</b>

## LISTA DE TABELAS

	Página
TABELA 1. Relação do tamanho e reatividade dos grânulos do corretivo. ....	20
TABELA 2. Valores para identificar a área em que o ponto amostral está localizado .....	31
TABELA 3. Análise do índice de desempenho da RNA. ....	37
TABELA 4. Estatística Descritiva das variáveis específicas utilizadas no treinamento das Redes Neurais Artificiais (RNAs). ....	38
TABELA 5. Resultados dos indicadores estatísticos para estimativas da necessidade de calagem das redes selecionadas. ....	43
TABELA 6. Teste-t para os dados observados de necessidade de calagem em relação aos dados de necessidade de calagem estimados pela RNA1. ....	47
Tabela 7. Resultados dos indicadores estatísticos das redes selecionadas, para redução dos pontos necessários para coleta de amostras. ....	<b>Erro! Indicador não definido.</b>
Tabela 8. Teste-t para os dados observados de necessidade de calagem em relação aos dados de necessidade de calagem estimados pela RNA1. ....	53

## LISTA DE FIGURAS

	Página
Figura 1. Mapa dos 13 tipos de solos encontrados no Brasil. ....	15
Figura 2. Disponibilidade de nutrientes em função do pH do solo. ....	17
Figura 3. (A) Grade regular; (B) alocação aleatória de pontos na célula; (C) adição de pontos próximo aos pontos originais.....	22
Figura 4. Mapas interpolados e zonas de manejo.....	23
Figura 5. Representação básica de uma Rede Neural Artificial.....	24
Figura 6. (a) Localização do município de Vila Propício no mapa de Goiás. (b) Área experimental no município de Vila Propício - GO.....	27
Figura 7. (a) Grade amostral da área experimental. (b) Área experimental dividida em áreas. ....	28
Figura 8. Ponto amostral sendo marcado com a estaca de madeira. ....	28
Figura 9. Modelo em blocos da arquitetura ilustrativa da RNA, com suas respectivas variáveis de entrada e saída.....	30
Figura 10. (a) Divisão fictícia do pivô em percentual de área; (b) Posicionamento dos pontos em relação a divisão fictícia do pivô em percentual de área. ....	31
Figura 11. Esquema representativo da adaptação da técnica de vizinhança dos pontos, onde os pontos preenchidos da cor verde são pontos utilizados para estimar os pontos sem preenchimentos, equivalentes a forma geométrica que os representam (círculo ou quadrado). ....	33
FIGURA 12. Interface gráfica do programa criado para agilizar a utilização das funções desenvolvidas neste estudo.....	40
FIGURA 13. Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de Necessidade de Calagem.....	41
FIGURA 14. Representação gráfica da fase de treinamento da rede selecionada (2 neurônios e treinamento 574).....	44
FIGURA 15. Representação gráfica do coeficiente de correlação (r) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (2 neurônios e treinamento 574).....	45
Figura 16. Comparativo geral dos valores observados (calculados pelo método tradicional de saturação por bases) e valores estimados de necessidade de calagem da rede selecionada (2 neurônios e treinamento 574). ....	46
Figura 17. Arquivo xls organizado e preparado para inserção na rede neural artificial.....	47
Figura 18. Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de Necessidade de Calagem.....	48
Figura 19. Representação gráfica da fase de treinamento da rede selecionada (6 neurônios e treinamento 714).....	50
Figura 20. Representação gráfica do coeficiente de correlação (r) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (6 neurônios e treinamento 714).....	51
Figura 21. Comparativo geral da rede selecionada para os valores observados (calculados pelo método tradicional de saturação por bases) e estimados para redução de amostras necessárias para coleta de amostras (2 neurônios e treinamento 574). ....	52
Figura 22- (a) Esboço da grade amostral destacando os pontos que podem ser estimados pela Rede Neural Artificial (RNA) na área experimental. (b) Esboço da nova grade amostral da área experimental sem os 26 pontos que podem ser estimados pela RNA.....	53

## **Predição Da Necessidade De Calagem Em Área De Pivô Central Por Meio De Rede Neural Artificial.**

### **RESUMO**

Grande parte do estado de Goiás é composta por latossolos, devido à grande ocorrência de acidez nesse tipo de solo, torna-se imprescindível o estudo dos métodos corretivos e de novas tecnologias para auxiliar no manejo destes solos, bem como as redes neurais artificiais (RNA) que tem se mostrado viáveis aos estudos de estimativas de atributos químicos dos solos. O trabalho tem por objetivo estimar a necessidade de calagem em áreas de pivô central, utilizando redes neurais artificiais. Os dados foram coletados numa área de 35 ha, numa grade amostral de 60x60 m, gerando 88 pontos amostrais. Para cada um desses pontos, serão coletadas 5 subamostras na camada de 0 a 0,20 m, para determinar os atributos químicos e a textura do solo. Os dados foram submetidos a análise descritiva e exploratória e logo após foram normalizados para inserção nas RNAs, para que estas possam ser calibradas, em seguida suas estimativas foram comparadas aos dados amostrais a necessidade de calagem, para verificação do desempenho da rede, por meio do índice de concordância, do coeficiente de correlação e verificação do menor erro relativo médio. Nos dois modelos envolvidos as RNAs conseguiram fazer as estimativas propostas com ótimo desempenho. Foram testadas várias estruturas e de acordo com os indicadores estatísticos chegou-se a melhor rede para cada modelo. No modelo 1 a RNA1 (Rede Neural Artificial com 2 neurônios na camada oculta) conseguiu os melhores resultados, apresentando um ótimo desempenho ( $id = 0,993$ ) e o erro quadrático médio (EQM) de 0,002. No modelo 2 a RNA 1 (Rede Neural Artificial com 6 neurônios na camada oculta) conseguiu os melhores resultados, apresentando um ótimo desempenho ( $id = 0,929$ ) e o erro quadrático médio (EQM) de 0,025. O Teste-t comprovou a precisão dos dois modelos, uma vez que não houve diferenças significativas das estimativas usando RNAs e o cálculo pelo método tradicional de necessidade de calagem. O modelo 2 por meio da técnica vizinhança adaptada para inserção de dados na RNA conseguiu diminuir em 30% o número de amostras a serem coletadas para um possível mapeamento da necessidade de calagem a taxa variada.

**Palavras Chave:** Acidez do solo, métodos corretivos, agricultura de precisão, inteligência artificial.

## ABSTRACT

Much of the state of Goiás is composed of latosols, due to the high occurrence of acidity in this type of soil, it is essential to study corrective methods and new technologies to assist in the management of these soils, as well as artificial neural networks (ANN). which has been shown to be viable for studies of soil chemical attribute estimates. The objective of this work is to estimate the need for liming in central pivot areas using artificial neural networks. The data were collected in an area of 35 ha, in a 60x60 m sampling grid, generating 88 sample points. For each of these points, 5 subsamples will be collected in the 0 to 0.20 m layer to determine the chemical attributes and soil texture. The data were submitted to descriptive and exploratory analysis and soon after they were normalized for insertion in the ANNs, so that they could be calibrated, then their estimates were compared to the sample data the need for liming, to verify the network performance, by means of the agreement index, correlation coefficient and verification of the lowest mean relative error. In the two models involved, the ANNs were able to make the proposed estimates with excellent performance. Various structures were tested and according to the statistical indicators, the best network for each model was arrived at. In model 1, RNA1 (Artificial Neural Network with 2 neurons in the hidden layer) achieved the best results, presenting an excellent performance ( $id = 0.993$ ) and the mean quadratic error (MSE) of 0.002. In model 2, RNA 1 (Artificial Neural Network with 6 neurons in the hidden layer) achieved the best results, presenting an excellent performance ( $id = 0.929$ ) and the mean quadratic error (MSE) of 0.025. The t-test proved the accuracy of the two models, since there were no significant differences in the estimates using ANNs and the calculation by the traditional method of liming requirement. Model 2, using the neighborhood technique adapted for data insertion in ANN, managed to decrease the number of samples to be collected by 30% for a possible mapping of the need for liming at a varied rate.

**Keywords:** Soil acidity, corrective methods, precision agriculture, artificial intelligence.

## 1. INTRODUÇÃO

Os solos são caracterizados desde sua origem e formação, desenvolvidos a partir do intemperismo físico e químico. A desintegração mecânica ocorre através de agentes como água, temperatura, vegetação e vento, formam-se os pedregulhos e areias (solos de partículas grossas), enquanto a decomposição química, se entende como o processo em que há modificação química ou mineralógica das rochas de origem (CAPUTO, 1996). Portanto, o solo é dependente da rocha mãe e dos diferentes agentes de alteração.

Os solos do Cerrado são considerados bastante intemperizados, já que ocorre predominância dos Latossolos em praticamente metade da área (LOPES et al., 2012). Além desses solos serem altamente lixiviados, possuem elevada acidez e saturação por alumínio, baixa capacidade de retenção de cátions e alta capacidade de fixação de fósforo (LOPES e GUILHERME, 2016). Dentre os diversos fatores que acarretam a acidez do solo, como por exemplo, a decomposição da matéria orgânica e fertilizantes amoniacais, o material de origem do solo também influencia o grau de acidez do mesmo. Os solos serão naturalmente ácidos quando a rocha de origem for pobre em bases ou, então mesmo quando rica em bases, houve intenso processo pedogenético (intemperismo) (FURTINI NETO et al., 2001).

A grande maioria dos solos brasileiros com expansão da fronteira agrícola, como os solos do cerrado, apresentam características de acidez ativa (Lopes et al., 1990). A acidez ativa é medida pelo índice pH em água ou CaCl<sub>2</sub>, em que os valores de pH dos solos variam numa faixa de 3 a 10. A grande maioria dos solos brasileiros apresenta pH menor que 5,5, o que pode acarretar condições de baixa fertilidade do solo altamente desfavoráveis para a obtenção de produtividades adequadas. (FURTINI NETO et al., 2001). Solos com acidez elevada, geralmente apresentam pobreza em bases (cálcio e magnésio principalmente), elevado teor de alumínio tóxico, alta fixação de fósforo nos colóides do solo e deficiência de alguns micronutrientes (RONQUIM et al., 2010).

A maneira mais fácil, correta e economicamente viável de corrigir a acidez do solo, para incorporação ao processo produtivo, diz respeito ao uso de calcário através da prática da calagem que é a maneira mais simples para atingir este objetivo (Lopes et al., 1990). Portanto, antes da adubação e na verdade, antes do preparo do solo, deve-se procurar saber as condições de acidez do solo (FURTINI NETO et al., 2001).

O manejo correto de grandes áreas, possui um elevado custo de produção, fazendo com que muitos produtores acabem não realizando. A partir deste pressuposto, diversas estratégias vêm sendo desenvolvidas ao longo das últimas décadas com o objetivo de otimizar o uso de recursos, aumentar a produtividade e diminuir os impactos ambientais (FERRAZ et al., 2012). Nas décadas de 1980 e 1990, múltiplos métodos envolvendo tecnologia foram popularizados como Agricultura de Precisão (AP), tendo diferentes focos de desenvolvimento conforme as regiões na qual vinham sendo desenvolvidas (MINASNY, 2006).

Dentre os diversos fatores que se pode analisar na agricultura de alta precisão, destacam-se a variação do rendimento, topografia, solo e suas propriedades químicas, colheita, infestação de pragas e insetos (fatores naturais), manejo regionalizado do solo, entre outros (FERNANDES, 2006; FERRAZ et al., 2012). Com o objetivo de caracterizar a variabilidade espacial dos atributos do solo utiliza-se a amostragem georreferenciada. Após a coleta de tais amostras são construídos mapas, que serão utilizados para direcionar a aplicação em taxas variadas de fertilizantes e/ou corretivos de solo, de acordo com as demandas locais destacadas pelos mapas. Contudo, a qualidade do mapa construído está diretamente relacionada com a densidade amostral (COLAÇO e MOLIN, 2015).

O planejamento da quantidade de pontos amostrais por unidade de área depende do raio de influência da variável analisada. Se o raio de influência da variável for pequeno serão necessários mais pontos para representar a área (COLAÇO e MOLIN, 2015). Assim, um dos fatores limitantes para avaliar a variabilidade espacial é a quantidade de amostras de solo necessárias para a análise geoestatística, pois o número de pontos e conseqüentemente a distância entre eles, são fundamentais para gerar um semivariograma de confiança. Souza et al. (2014) sugeriram dimensões de malhas amostrais que condicionem no mínimo 100 pontos de amostragem. Logo, os produtores são limitados pelos recursos gastos na amostragem e mão de obra de trabalho, o que os leva a fazer apenas a análise convencional. Entretanto, a análise convencional não permite a geração de semivariogramas (SOUZA et al., 2014; ARRUDA, MOREIRA & PEREIRA, 2014).

Todavia, o emprego de novas tecnologias tem sido de grande importância nas investigações agronômicas, como a Inteligência Artificial (IA), que pode representar uma estratégia eficiente para simulação e otimização de processos importantes na agricultura (ÇELEBI et al., 2017). Entre as técnicas de IA, as redes neurais artificiais (RNAs) apresentam um modelo matemático baseado na estrutura neural do sistema nervoso, capazes de realizar aprendizado por computador e reconhecimento de padrões (SILVA et al., 2004; ÇELEBI et al., 2017).

As redes neurais artificiais são sistemas modelados matematicamente para reproduzir a inteligência de seres vivos, a fim de resolver situações que necessitem do armazenamento de conhecimento e que adquiram conhecimento através da experiência, tornando-as capazes de solucionar problemas muito complexos em diversas áreas do conhecimento (SOARES et al., 2015; BRAGA, 2014). Portanto, uma RNA compreende um grande número de unidades de processamento simples, os nodos ou neurônios, organizados em camadas, conectados por ligações ponderadas de acordo com uma arquitetura especificada (PEREIRA e CENTENO, 2017).

Redes Neurais Artificiais têm se tornado o foco de muita atenção, devido a sua ampla aplicabilidade e, principalmente, por tratar de casos considerados complicados (PEREIRA e CENTENO, 2017). Tal capacidade de resolver problemas tem sido evidenciada nas ciências agrárias, visto que trabalhos envolvendo a aplicação de RNAs são desenvolvidos visando a sua adequação e parametrização para diversas situações. Soares et al. (2014) propuseram uma metodologia de estimativas da curva de retenção de água em solos do estado do Rio Grande do Sul, por meio de redes neurais artificiais. Sobrinho et al. (2011) conseguiu obter uma RNA capaz de estimar a evapotranspiração de referência em função de dados diários de temperatura do ar, no Mato Grosso do Sul. Estimativas válidas de produtividade das culturas do milho (*Zea mays* L.) e da soja (*Glycine max* L.) foram obtidas por meio de aplicações de redes neurais artificiais (LEAL et al., 2015; ALVES et al., 2018). Bittar (2016) desenvolveu RNAs para estimar os atributos químicos e físicos do solo com um número menor de amostras em relação ao tradicionalmente usado para a análise geoestatística, o autor concluiu que os resultados apresentados foram satisfatórios, sugerindo pesquisas futuras.

O estado de Goiás se destaca por grandes produções agrícolas, estudos voltados para a potencialização da produção possuem grande importância, sendo a otimização do tempo e a redução dos custos de produção uma maneira de contribuir economicamente para o estado. Dessa maneira, o emprego de redes neurais artificiais demonstram ser uma interessante maneira de aprimorar os fatores de produção relativo a solos no estado de Goiás.

Desta forma, objetivou-se desenvolver uma Rede Neural Artificial (RNA) para estimar a necessidade de calagem em áreas de pivô central, avaliar o índice de assertividade da RNA, reduzir a quantidade de amostras necessárias para que as estimativas obtidas pela RNA possa viabilizar um possível mapeamento da necessidade de calagem a taxa variada.

## 2. REVISÃO DE LITERATURA

### 2.1. SOLOS

O solo é um corpo formado por materiais minerais e orgânicos, sendo composto por partes tanto sólidas quanto líquidas e gasosas (ARBESTAIN et al., 2008). O solo que classificamos é um conjunto de corpos naturais, compostos por materiais minerais e orgânicos que ocupam a maior parte do manto superficial das extensões continentais do nosso planeta, contêm matéria viva e podem ser vegetados na natureza onde ocorrem e, eventualmente, terem sido modificados por interferências antrópicas (SANTO et al., 2018). Os solos ainda são denominados como materiais que resultam do intemperismo ou meteorização das rochas por desintegração mecânica ou decomposição química (CAPUTO, 1996).

Por ser um país extenso, o Brasil possui diferentes tipos de solos em seu território, formados de acordo com o tipo de relevo, clima do local e material de origem. Além desses fatores, a formação de solos é condicionada a presença de partes fluviais nas proximidades, organismos vivos (e suas decomposições no meio) e ainda o tempo. (EMBRAPA, 2018).

De acordo com o Sistema Brasileiro de Classificação de Solos (SBCS) o território brasileiro possui 13 tipos de solo conforme as suas características. São eles os: Argissolos, Cambissolos, Chernossolos, Espodossolos, Glesissolos, Latossolos, Luvisolos, Neossolos, Nitossolos, Organossolos, Planossolos, Plintossolos e Vertissolos (Figura 1) (EMBRAPA, 2018). Esses solos são classificados levando em conta diversos fatores, como os processos de formação do solo; morfologia e textura; a composição, seja de sais minerais ou materiais orgânicos; de acordo o tamanho dos grânulos (granulometria); entre outros (SANTOS et al, 2018). Os métodos de descrição e coleta do solo são consolidados para ambientes naturais (SANTOS et al., 2015), cuja caracterização do solo é baseada na descrição do perfil (sequência e profundidade de horizontes, classe de textura, cor, estrutura, características especiais, etc.), coleta de amostras, análise laboratorial (análise química e física) e interpretação dos dados (COSTA et al., 2019)

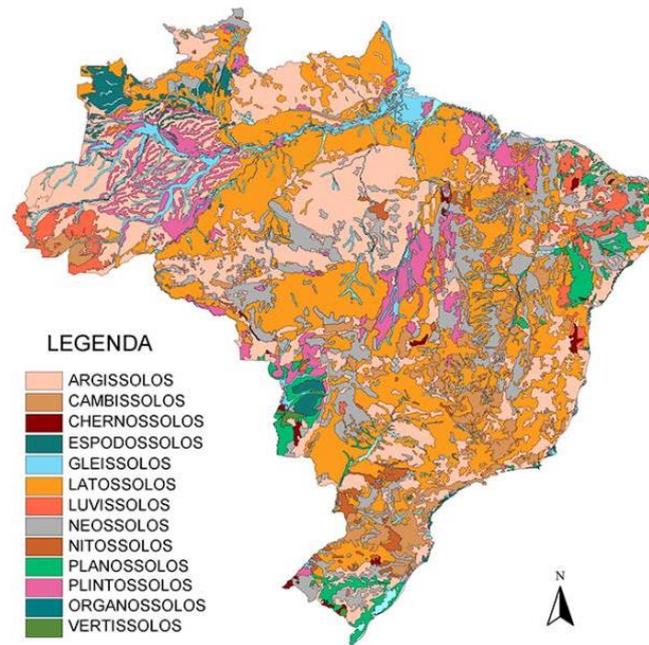


Figura 1. Mapa dos 13 tipos de solos encontrados no Brasil.

Fonte: Embrapa (2018).

A região Centro-oeste é tomada em sua maior parte pelo Cerrado, que se localiza em sua maioria em clima tropical sazonal, com estações bem definidas de seca e chuva. Além disso, a região também possui o bioma Pantanal, em parte dos estados do Mato Grosso e Mato Grosso do Sul. Desse modo, a formação dos diversos tipos de solos encontrados na região pode ter diversas origens como relevo, biota e clima. O estado de Goiás é tomado pelo Cerrado, que possui clima tropical/semiárido com períodos de seca e chuva bem definidos. O clima é o principal influenciador da desintegração de rochas em Goiás, conhecido como intemperismo.

O Cerrado ocupa 207 milhões de hectares do território brasileiro, o que representa aproximadamente 4% da região tropical do mundo (RESCK, 1999) e possui diversas fitofisionomias caracterizadas pelo clima e principalmente pelos solos (PEIXOTO et al., 2016). Os solos de maior representatividade nesse Bioma são os Latossolos (46%) especialmente o vermelho, os Argissolos (15%) e os Neossolos Quartzarênicos (15%) (REATTO et al., 1998; LEPSCH, 2010). Esses solos são intemperizados, e suas características marcantes são: o baixo teor de nutrientes, a elevada acidez e a predominância de argilas de baixa atividade (caulinitas e óxi-hidróxidos de Fe e Al), podendo assim comprometer o desenvolvimento vegetal (FRAZÃO et al., 2008; DONAGEMMA et al., 2016).

Os Latossolos são amplamente distribuídos em quase todas as regiões do Brasil e compõem a classe taxonômica predominante, ocupando 31,61% da superfície do país (2,69 milhões de km<sup>2</sup>) (ANJOS et al., 2012). Os Latossolos representam mais da metade dos solos encontrados no estado. Esses solos são encontrados principalmente na região sudeste de Goiás,

em seguida, os Argissolos e os Cambissolos mais encontrados no centro e no norte do estado (IBGE, 2018), podendo encontrar a ocorrência de: Neossolos, Argissolos, Plintossolos e Nitossolos (SANTOS et al, 2018).

O solo é um componente essencial do sistema terrestre e atualmente está sob alta pressão, devido à crescente demanda global por alimentos, energia e fibras (MEDEIROS et al., 2016). Camargo et al. (2010) ressaltam que a Ciência do Solo brasileira sempre focou em maneiras saudáveis e sustentáveis de produzir alimentos. Todavia, a importância dos solos para a sociedade, para as gerações futuras, será cada vez mais complexa, exigindo soluções específicas para cada nova questão que surgir. Os autores ainda afirmam que nas décadas futuras, a Ciência do Solo continuará sendo tópica nas discussões sobre cuidados com o meio ambiente e produção de alimentos e fibras, e que além disso, terá um papel determinante na resolução de certas questões, como qualidade da água e manejo e conservação.

## 2.2. CALAGEM

A acidificação do solo consiste na remoção dos cátions básicos ( $Ca^{2+}$ ,  $Mg^{2+}$ ,  $K^+$  e  $Na^+$ ) do sistema do solo, substituindo-os por cátions ácidos ( $Al^{3+}$  e  $H^+$ ) (FURTINI NETO et al., 2001). A acidez do solo pode ter diversas origens, como a utilização de fertilizantes ácidos, dissociação de  $H_2CO_3$  devido a água da chuva, retirada de nutrientes devido a cultura, decomposição de materiais orgânicos gerando dissociação de grupamentos fenólicos e carboxílicos, ou pela própria natureza do solo, de acordo com cada bioma (FURTINI NETO et al., 2001; NOLLA e ANGHIONONI, 2004; SANTIAGO e ROSSETTO, 2019;).

A natureza da relação entre o rendimento da produção e o pH do solo tem implicações importantes para a sustentabilidade e a eficiência da produção agrícola (HOLLAND et al., 2019). É uma realidade bem conhecida que a acidificação do solo diminui o pH do solo, causando efeitos adversos nas plantas e microrganismos do solo. A acidificação, associada às toxicidades de alumínio, manganês e ferro, e as deficiências de fósforo, cálcio, magnésio e potássio, podem levar à baixa fertilidade do solo (KUNHIKRISHNAN, et al., 2016).

No Brasil, o maior problema relacionado à reação do solo diz respeito ao fato de que cerca de 70% dos solos cultivados apresentam acidez excessiva. Portanto, a prática da calagem torna-se de vital importância no manejo da fertilidade do solo (FURTINI NETO et al., 2001) a fim de aliviar a acidificação do solo em sistemas agrícolas (JIANG et al., 2018).

O método de calagem tem como seus principais objetivos suprir a demanda de  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  e realizar o ajuste do pH do solo. Sabe-se que para fins práticos, considera-se a faixa de pH entre 6,0 e 6,5 adequada para a maioria das plantas cultivadas no Brasil (Figura 2).

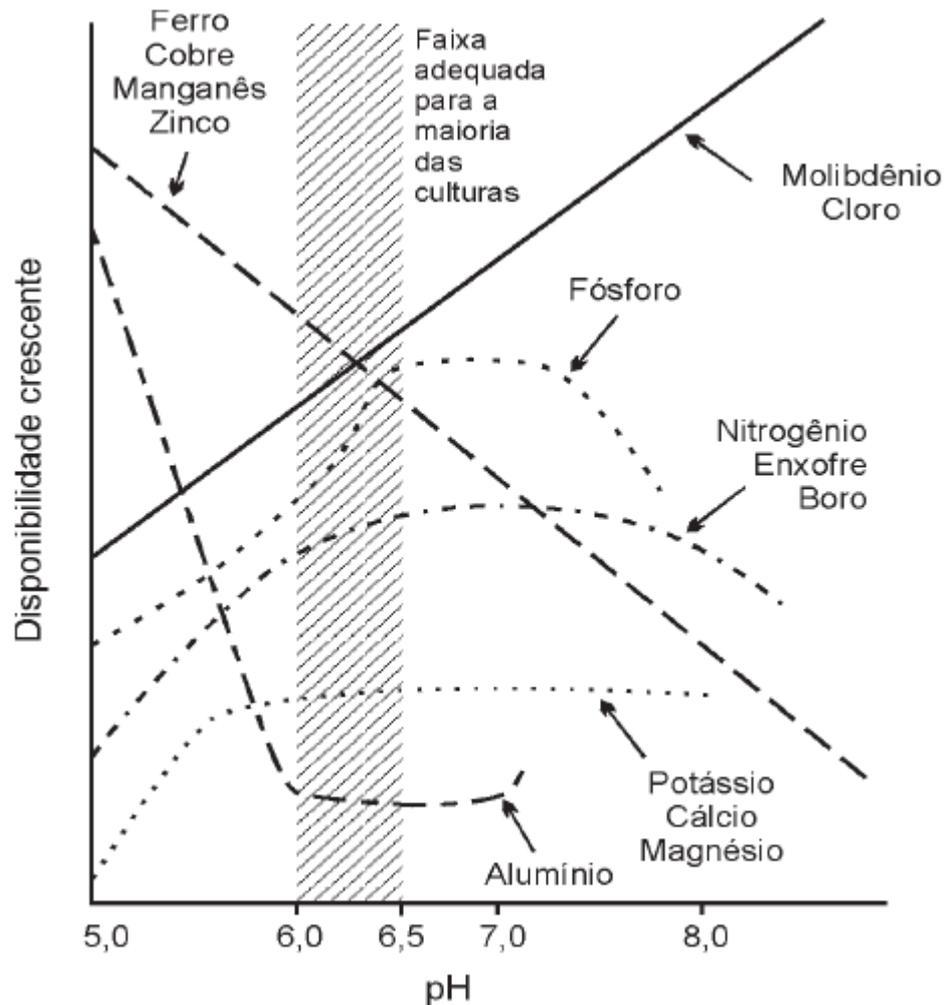


Figura 2. Disponibilidade de nutrientes em função do pH do solo.

Fonte: Instituto da Potassa e Fosfato (1998).

Dentre os vários efeitos da calagem em solos ácidos, destaca-se o aumento da disponibilidade da maioria dos nutrientes essenciais para as plantas (INSTITUTO DA POTASSA e FOSFATO, 1998), com o condicionamento do solo para a obtenção de valores entre 6,0 e 6,5 favorece uma boa disponibilidade da maioria dos nutrientes, o que, obviamente, contribui para a maior produtividade das culturas em solos corrigidos (FURTINI NETO et al., 2001).

Tradicionalmente, a calagem é uma prática comum no tratamento de solos. Na calagem são adicionados materiais de cal para neutralizar os solos ácidos e superar os problemas associados à acidificação do solo, visando a regulação do pH em uma faixa aceitável para a produção agrícola e aprimoramento da disponibilidade de nutrientes. (KUNHIKRISHNAN, et al., 2016; EGERIC et al., 2019; HOLLAND et al., 2019). Desse modo, ao realizar a calagem, decorre elevação do pH, atenuação do alumínio trocável, fornecendo ainda cálcio e magnésio e elevando a disponibilidade de nitrogênio, fósforo e potássio, aprimorando a eficiência de uso dos nutrientes e da água no solo (RAIJ, 2011).

Elevar o pH do solo é um dos métodos comuns de controle do efeito da acidez do solo na planta e no solo (RAHMAN e OTHMAN, 2020) e para conseguir isso, o pH do solo é aumentado pela aplicação de materiais calcários na superfície do solo (LI et al., 2019). Os materiais calcários mais utilizados incluem carbonatos de cálcio, hidróxidos e óxidos. Estes materiais de calagem foram estabelecidos para aumentar o pH do solo, diminuir a acidez do solo, aumentar as atividades microbianas e a disponibilidade de nutrientes (NAWARATHNA et al., 2018).

Na região Centro-Oeste, onde predomina o cerrado, os altos índices de  $Al^{3+}$  (superiores a 10%) e baixos índices de Cálcio, inferior a  $0,4 \text{ cmolc.dm}^{-3}$  em 86% desta área, são fatores que por muito tempo atrapalharam o desenvolvimento agrícola regional. Dessa maneira, a correção de pH desses solos é de suma importância para o cultivo (SOUSA et al., 2005).

Diversos métodos são realizados com a finalidade de determinar a necessidade de calagem, dentre eles os mais utilizados para estimar a quantidade de corretivo que deve ser aplicado nos solos são: Método da Neutralização do Al Trocável e Elevação dos Teores de  $Ca^{2+}$  e  $Mg^{2+}$  (ou método de neutralização do alumínio), Método da Saturação por bases e ainda o método SMP (SILVA et al., 2018). Independentemente do método utilizado, o resultado obtido é a quantidade de calcário ( $CaCO_3$ ), que deve ser aplicado no solo.

O Método da Neutralização do alumínio utiliza-se de uma relação matemática que visa definir a quantidade de calcário, relacionando tanto a acidez do solo devido ao  $Al^{3+}$  quanto a presença de  $Ca^{2+}$  e  $Mg^{2+}$  simultaneamente. Essa relação é mostrada na Equação 1:

$$NC = Y \times [Al^{3+} - (mt \times t/100)] + [X - (Ca^{2+} + Mg^{2+})] \quad (1)$$

Em que:

NC = Necessidade de calcário, em  $t \text{ ha}^{-1}$ ;

Y = variável relacionada à capacidade tampão do solo (de acordo com a textura do solo);

$Al^{3+}$  = acidez trocável, em  $cmolc\ dm^{-3}$ ;

$mt$  = saturação máxima por Al tolerada,  $m = 5\%$ ;

$t$  = capacidade de troca catiônica efetiva ( $CTC_{efetiva}$ ), em  $cmolc\ dm^{-3}$ ;

$X$  = disponibilidade de Ca e Mg requerida pelo tomateiro,  $X = 3$ ;

$Ca^{2+} + Mg^{2+}$  = teores trocáveis de Ca e Mg, em  $cmolc\ dm^{-3}$ .

Esse método é utilizado nos estados de Goiás, Minas Gerais, Espírito Santo e outros, com pequenos ajustes de acordo com o estado (SILVA et al., 2018).

O Método da Saturação por bases, visa elevar a saturação do solo de acordo com cada tipo de cultivo, com o intuito de aumentar o pH, considerando a estreita relação entre a porcentagem de saturação por bases e o pH do solo (FURTINI-NETO et al., 2001). O método da saturação de bases é utilizado, principalmente, em São Paulo. Todavia pode ser usado para solos de cerrados (CFSG, 1988). A equação (3) mostra a relação de NC agora com o a porcentagem de saturação recomendada para a hortaliça (V), a capacidade de troca de íons com pH neutro (T) e a saturação por bases já presente no solo (SB).

$$NC = \frac{T \times (V_2 - V_1)}{PRNT} \quad (2)$$

Em que:

PRNT = poder relativo de neutralização total (%);

$V_2$  = saturação de bases desejada (%);

$V_1$  = saturação de bases atual (%);

T = capacidade de troca catiônica (Ca + Mg + K + Na + H + Al);

Nos solos do Estado de Goiás, não se considera o teor de Na, no cálculo do valor T (meq/100 ml).

Temos ainda, um terceiro método, utilizado principalmente na região Sul do país desde o começo da década de 60 (NOLLA & ANGHINONI, 2004), conhecido como Solução Tampão SMP, acrônimo para Shoemaker, Mac Iean e Pratt (SHOEMAKER et al., 1961), que consiste em agitar o solo com soluções tampão, e detectado o pH diretamente, assim, conforme o valor obtido, a quantidade de calcário é definida. Devido ao fato que a solução tampão é formada por um ácido fraco e sua base conjugada, uma base fraca e ácido conjugado que visa resistir a variações de pH no meio, o pH da solução solo-tampão, são elaboradas tabelas específicas para cada hortaliça a ser plantada na região. (LOPES et al., 1991; SILVA et al., 2018) A grande vantagem desse método é o baixo custo, sendo o maior trabalho a construção da tabela local.

O poder corretivo de  $\text{CaCO}_3$  está diretamente ligado à sua qualidade, que é medida pelo Poder Reativo de Neutralização Total (PRNT) (PRIMAVESI et al., 2004). O PRNT pode ser obtido através da Equação, sendo que o PN é o potencial de correção do produto, expresso em função da porcentagem de  $\text{CaCO}_3$ , e RE a reatividade das partículas.

$$\text{PRNT} = \frac{(\text{PN} \times \text{RE})}{100} \quad (3)$$

Os valores granulométricos e de reatividade recomendados pela ABNT foram compilados em comunicado técnico por Coelho (2004). De acordo com o autor, a reatividade do calcário está ligada ao tamanho das partículas. Desse modo, os valores de quantidade, tamanho e reatividade estão apresentados na **Erro! Fonte de referência não encontrada.**

TABELA 1. Relação do tamanho e reatividade dos grânulos do corretivo.

	Quantidade	Tamanho	Reatividade relativa	Reatividade absoluta
	30%	<2mm	20%	6%
	20%	<0,84mm	60%	12%
	50%	<0,3 mm	100%	50%
Total	100%	-	-	68%

Fonte: Coelho (2004).

Cabe ressaltar que grânulos maiores do que 2mm não possuem reatividade de acordo com a ABNT 10. A reatividade mínima então é de aproximadamente 68% como indicado na tabela se for utilizado um corretivo que possui 100% de  $\text{CaCO}_3$ . Considerando que o valor mínimo de calcário recomendado é de 67%, e utilizando a relação expressa pela Equação 1, nos traz um valor mínimo de PRNT de 45%. O PRNT pode variar bastante de acordo com a quantidade de calcário e o tamanho das partículas, sendo que valores entre o mínimo e 60% são considerados baixos, valores entre 60% e 90% são intermediários e acima de 90% altos (COELHO, 2004; MALAVOLTA, 1989).

### 2.3. AGRICULTURA DE PRECISÃO

A Agricultura de Precisão (AP) é uma ferramenta de gestão, baseada na variabilidade espacial e temporal da cultura, como também dos atributos físicos e químicos do solo, clima, topografia, entre outros fatores da unidade produtiva. Essa ferramenta de gestão visa minimizar os efeitos indesejáveis ao ambiente e aumentar a produtividade, tendo como elemento chave o gerenciamento da variabilidade espacial (MONDO et al., 2012).

Mesmo em áreas consideradas homogêneas e pertencentes a mesma classe, o solo normalmente apresenta variações nos seus atributos a curtas distâncias e em grau suficiente para interferir na produtividade das culturas (AMARO FILHO et al., 2007). Uma ferramenta muito utilizada para a descrição dessas características é a geoestatística, imprescindível para o manejo regionalizado de lavouras (YAMAMOTO e LANDIM, 2013; SOUZA et al., 2014). O semivariograma é a principal ferramenta utilizada na geoestatística para a caracterização da dependência espacial, representado por um gráfico que associa distâncias com semivariâncias (Figura 3) (DALCHIAVON et al., 2017). Este tem a propriedade de medir o grau de dissimilaridade entre pares de medidas em razão da distância e orientação da linha entre dois locais de amostragem (SEIDEL e OLIVEIRA 2014), a partir de uma malha amostral, ou coloquialmente chamado de grid amostral, para o qual estabelece o número e espaçamento dos pontos onde as amostras serão coletadas (GUIMARÃES et al., 2016).

A escolha da densidade amostral adequada para o levantamento de algum parâmetro é determinante para a qualidade do mapa final e da sua capacidade de representar adequadamente a realidade (MOLIN et al., 2015). Quando é utilizado baixa densidade de pontos em grades amostrais, pode-se evidenciar o risco de se obter um resultado final equivocado. Cherubin et al. (2015), avaliando a dimensão de grid amostral no estudo da variabilidade espacial de fósforo e potássio em Latossolo Vermelho, propuseram grades amostrais não maiores do que 100 m entre pontos para caracterizar a variabilidade espacial dos nutrientes no solo. Definida a densidade amostral, pode-se ainda, optar pelo tipo de grade utilizada para coleta dos atributos a serem avaliados. A escolha da grade amostral regular (quadrada ou retangular) com pontos equidistantes tem sido usual, pois facilita a navegação durante a coleta das amostras (MOLIN et al., 2015) e o arranjo entre os pontos e a posição deles dentro de cada célula pode apresentar as mais diversas variações (Figura 3).

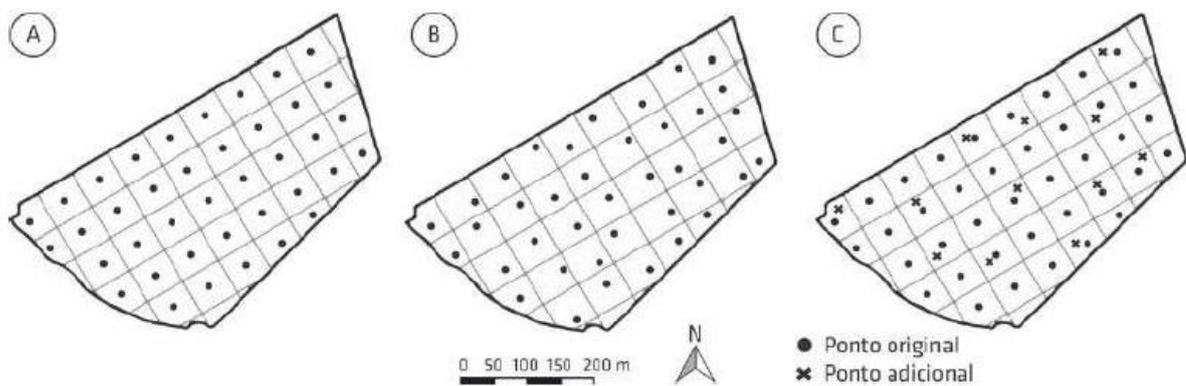


Figura 3. (A) Grade regular; (B) alocação aleatória de pontos na célula; (C) adição de pontos próximo aos pontos originais.

Fonte: Molin et al. (2015).

O conhecimento da variabilidade espacial é um fator importante a ser analisado no planejamento de um programa de amostragem de solo e manejo de culturas na agricultura de precisão (CHERUBIN et al., 2014). O pH do solo é um dos principais fatores que afetam a disponibilidade de nutrientes no solo. Portanto, é de grande importância avaliar a variabilidade espacial do pH para o gerenciamento do manejo de nutrientes no solo. O manejo do solo faz parte da agricultura de precisão que envolve informações da variabilidade, visando o aumento da produtividade, otimização no uso dos recursos, fertilizantes e redução no impacto ambiental (DALCHIAVON et al., 2017).

Com o crescimento gradual do uso de técnicas de manejo diferenciado do solo, como a adubação em taxa variável, devido a adoção de máquinas específicas, é indispensável definir zonas de manejo. A aplicação de sistemas de manejo específico na agricultura de precisão exige informações precisas sobre a variação espacial dos atributos do solo, que podem ser obtidas por meio dos mapas interpolados (Figura 4), que norteiam as práticas de gestão para regiões onde há limitação para o desenvolvimento da planta (SOUZA et al. 2014; CARVALHO et al., 2017).

Assim, é possível por meio do estabelecimento de zonas específicas de manejo incluir a aplicação de insumo com taxa variada, que são condições necessárias à agricultura de precisão (DALCHIAVON et al., 2017).

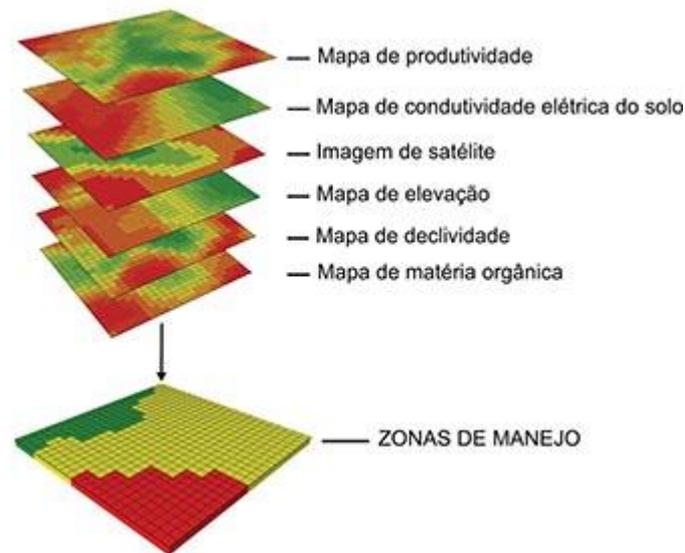


Figura 4. Mapas interpolados e zonas de manejo

Fonte: Amado et al. (2016).

Na busca de entender como os atributos do solo afetam a produção, visando a definição de sítios específicos de manejo, predição de produtividade e nutrientes do solo, uma alternativa consiste no uso de redes neurais artificiais (RNAs) (LEAL et al., 2015). RNAs têm sido aplicadas com sucesso em diversas situações na agricultura de precisão. Silva et al. (2004) obtiveram resultados potenciais na utilização de RNAs como ferramenta para uma melhor representação e interpretação das necessidades de nutrientes em agricultura de precisão. Leal et al. (2015) utilizando redes neurais artificiais, concluíram que matéria orgânica, capacidade de troca de cátions, saturação de bases e teor de argila, permite a predição da produtividade do milho, cultivado em “segunda safra” em região de cerrado. Todavia, Freitas (2018) objetivando avaliar a eficiência das estimativas de atributos físicos e químicos do solo obtidas por meio de uma rede neural artificial, certificou que o uso da RNA adquiriu o conhecimento necessário para estimar valores médios dos atributos de solo com eficiência, mas o mesmo não ocorreu para estimar os atributos pontualmente. A autora ainda afirma que para o aprimoramento da rede sugere-se implementação em sua estrutura, visando a possibilidade de inserir novas variáveis de entrada.

## 2.4. REDES NEURAIIS ARTIFICIAIS

Redes neurais artificiais (RNAs) são um sistema de processamento de informações e programas inteligentes, que se assemelham à estrutura e funções das redes neurais dos seres vivos, capazes de aprender com exemplos e usá-los para resolver problemas (ABDULLAHI et

al., 2017; ALVES et al., 2017; RAO et al., 2019). Diferente das técnicas convencionais de computação, as RNAs aprendem a resolver problemas por aprendizado e experiência, como ocorre com os seres humanos (SILVA et al., 2004). Além disso, as RNAs são mais robustas na presença de ruído e não sofrem algumas das limitações dos algoritmos baseados em estatísticas, principalmente relacionadas à não linearidade ou heterocedasticidade dos dados. (SADECK et al., 2017).

As redes neurais artificiais (RNAs) consistem em três camadas: camada de entrada, camada oculta e camada de saída. Contudo, um modelo de rede neural pode ter mais de uma camada oculta e a precisão seria alta se o número de camadas ocultas for alto (RAO et al., 2019). Uma representação básica das redes neurais é ilustrada na Figura 5.

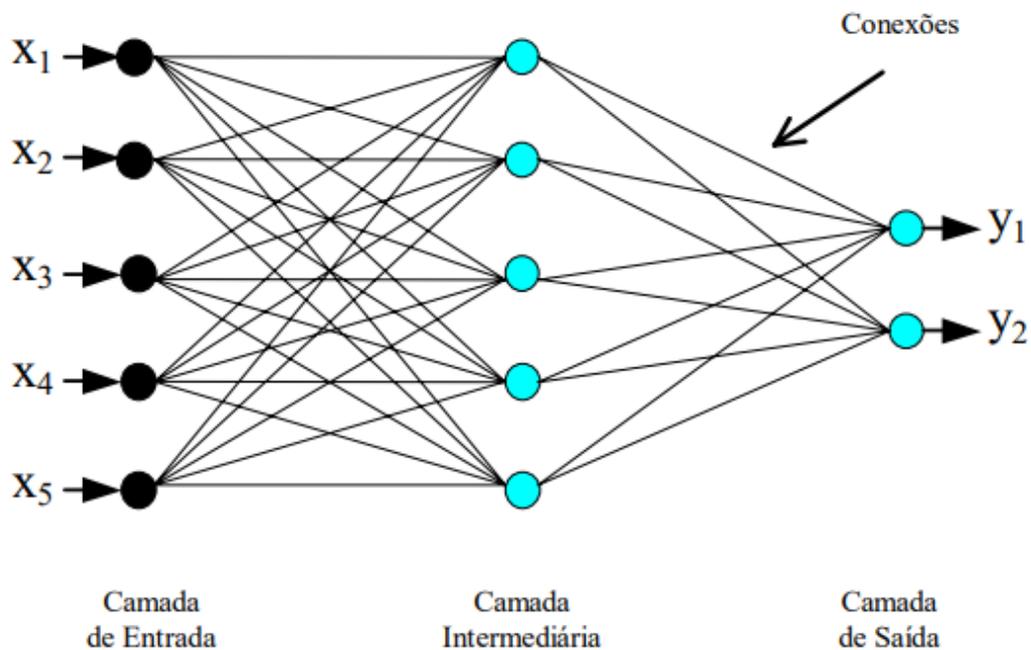


Figura 5. Representação básica de uma Rede Neural Artificial.

Fonte: Silva et al. (2004).

Então, as RNAs são sistemas computacionais paralelos, formados por um grande número de unidades de processamento (que simulam os neurônios) conectadas entre si de maneira específica para desempenhar determinada tarefa (SILVA et al., 2004; BINOTI et al., 2013). Todavia a RNA é caracterizada por um grande número de conexões ponderadas entre elementos, e o conhecimento da rede é adquirido por meio de um processo de treinamento, no qual valores de pesos associados a conexões entre as unidades são ajustados por esse treinamento (SILVA et al., 2004; ABDULLAHI et al., 2017). As unidades realizam operações apenas sobre seus dados locais, que são entradas recebidas através das suas conexões (SILVA et al., 2004).

O fluxo de informações por meio das conexões da rede pode afetar a estrutura da RNA. Isso ocorre porque uma rede aprende primeiro e depois altera dependendo da entrada e da saída, ou seja, depende dos dados fornecidos no conjunto de dados (RAO et al., 2019). De forma simples, denominamos esse fluxo de informações de rede neural. Arquiteturas de rede diferentes requerem algoritmos de treinamento diferentes. Citando o treinamento supervisionado, o conjunto de dados é estruturado com a saída conhecida para cada padrão de entrada e os pesos são ajustados para permitir que a rede produza resultados o mais próximo possível dos resultados de saída conhecidos ou definidos (ABDULLAHI et al., 2017).

A inteligência artificial (IA) pode representar uma estratégia eficiente para simulação e otimização de processos importantes na agricultura (DORNELLES et al., 2018). Entre as técnicas de IA, as redes neurais artificiais (RNAs) tem sido amplamente utilizada na agricultura, principalmente para prever as propriedades do solo, e pode ir além da capacidade humana de avaliar grandes bancos de dados e relacioná-los a uma característica desejável específica (BODAGHABADI et al., 2015; ALVES et al., 2017).

Portanto, buscando analisar como os atributos do solo afetam a produção, bem como a possibilidade de utilização destes na predição da produtividade de grãos, visando a definição de sítios específicos de manejo, predição de produtividade e lucro, uma alternativa consiste no uso de redes neurais artificiais (RNAs) (LEAL et al., 2015).

Nas últimas décadas, modelos de rede neural artificial têm sido amplamente utilizados nas ciências agrárias. Silva et al. (2004) avaliando o uso de RNAs para a determinação das necessidades de adubação da cultura da goiabeira, encontraram resultados potenciais para a recomendação de adubação levando-se em consideração princípios da agricultura de precisão.

Bodaghabadi et al. 2015 avaliando a aplicação das RNAs obtidas para relações similares solo-paisagem no Irã Central, apontaram que as RNAs foram capazes de identificar estruturas na distribuição de unidades de solo usando atributos relacionados ao terreno. No entanto, verificaram que outros fatores de formação do solo também devem ser considerados, como por exemplo, superfícies geomórficas (formas de relevo) inserida na entrada da RNA para melhorar as previsões das unidades de solo. Já Leal et al. (2015) utilizando Redes neurais artificiais na predição da produtividade de milho por meio de atributos do solo, concluíram que a análise dos atributos do solo permite a predição da produtividade do milho, cultivado em “segunda safra” em região de cerrado.

Atualmente, trabalhos são desenvolvidos utilizando RNAs visando a sua adequação para estimar variáveis de produtividade. Dornelles et al. (2018), objetivando propor o uso de inteligência artificial via redes neurais artificiais na cultura da aveia concluíram que as redes

neurais permitiram simular com eficiência o rendimento de grãos de aveia e com melhor otimização da densidade de semeadura (DORNELLES et al., 2018). Todavia, Alves et al. (2018) tendo em vista estimar a produtividade da soja com base na densidade de semeadura e características agronômicas, utilizando um perceptron de múltiplas camadas da RNA, afirmaram que o uso de RNAs é viável, uma vez que a técnica de treinamento de retropropagação permitiu identificar a relação entre as variáveis independentes e a produtividade da soja com alta precisão (72%).

Pela razão da RNA ter capacidade de classificação, exame, simulação e tomada de decisão, lhe dá uma ampla aplicação na engenharia, fortemente aplicado na agricultura (BAHMED et al., 2017). Recentemente Wu et al. (2019) avaliou funções empíricas e RNA para prever o pH do solo usando vários índices geoquímicos. Os autores identificaram que a RNA apresentou as melhores estimativas de pH do solo de acordo com indicadores estatísticos. Por fim, Alsharari et al. (2020) avaliaram modelos lineares, três não lineares e três redes neurais artificiais (RNAs), para encontrar o melhor modelo que pode ser usado para prever a resistividade elétrica do solo, com base no conhecimento de suas propriedades geotécnicas. Os autores verificaram que o modelo de RNA é capaz de prever com eficiência a resistividade elétrica do solo e é melhor do que os outros modelos que foram desenvolvidos.

### 3. MATERIAL E MÉTODOS

#### 3.1. CARACTERIZAÇÃO E LOCALIZAÇÃO DA ÁREA DE ESTUDO

O experimento foi desenvolvido em uma área comercial de tomate industrial irrigado por pivô central (Figura 1) correspondente a 35 ha localizada no município de Vila Propício com de altitude 686 m, cujas coordenadas geográficas são: latitude 15°24'12" S e longitude 48°53'59.69" W. O solo pode ser classificado como um latossolo vermelho de textura argilosa, com consistência plástica e pegajosa.



Fonte: GOOGLE (2018)

(a)



Fonte: GOOGLE (2018)

(b)

Figura 6. (a) Localização do município de Vila Propício no mapa de Goiás. (b) Área experimental no município de Vila Propício - GO.

#### 3.2. MAPEAMENTO DA ÁREA E FORMAÇÃO DA GRADE AMOSTRAL

Os dados foram coletados em uma grade amostral de 60x60 m, com um total de 88 pontos amostrais como pode-se observar na Figura 6 (a), conforme a metodologia de Bittar e colaboradores (2018). Cada ponto foi georreferenciado utilizando aparelho de Sistema de Posicionamento Global (GPS), da marca Garmin modelo Etrex Legend RoHs (erro  $\pm 3$ m), com o datum ajustado ao sistema SIRGAS 2000. Foram coletadas amostras de solos deformadas com um trado de rosca, para análises químicas do solo.

Como sugerido por Freitas (2018) a área da lavoura foi dividida em 4 áreas, com cada um desses representando 25% da lavoura [Figura 2 (b)], com o intuito de controlar o limite espacial para os pontos amostrais.

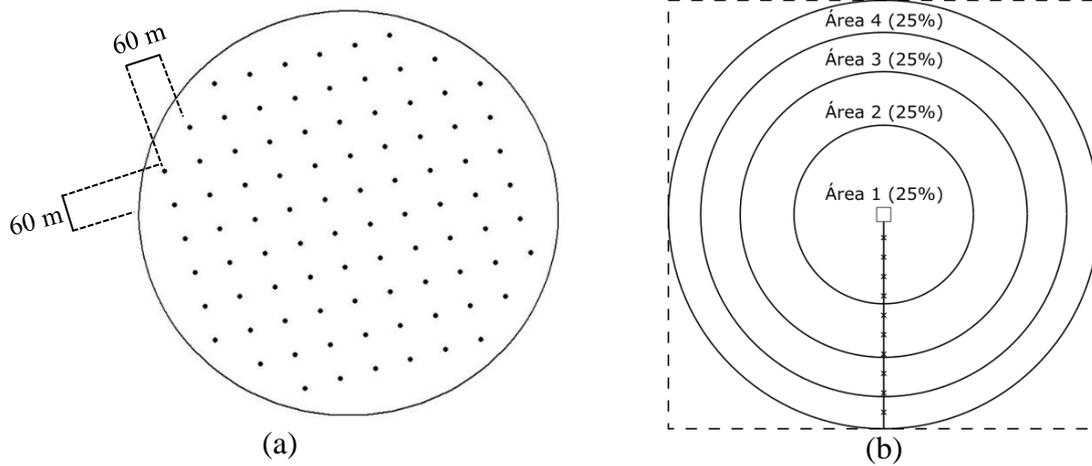


Figura 7. (a) Grade amostral da área experimental. (b) Área experimental dividida em áreas.

Fonte: Autoria Própria (2018).

### 3.3. DETERMINAÇÃO DOS ATRIBUTOS FÍSICOS E QUÍMICOS DO SOLO

Em cada ponto da grade amostral georreferenciada devidamente estaqueado, foram coletadas amostras de solo (composta por 5 subamostras) na camada de 0,00 a 0,20 m, com um trado de rosca, coletadas num raio de 3m, em torno de cada ponto (Figura 8).



Figura 8. Ponto amostral sendo marcado com a estaca de madeira.

Fonte: arquivo pessoal (2019).

Em seguida 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 químicos do solo: 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%), argila, silte e areia.

Para estimar a necessidade de calagem, foi utilizado o método de saturação por bases, conforme a Equação 1 adotada por Primavesi et al. (2004):

$$NC = \frac{(v_2 - v_1) \times T}{100} \times f \quad (4)$$

em que:

NC = Necessidade de calagem ton ha<sup>-1</sup>;

v<sub>2</sub> = Saturação por bases recomendada para a cultura do tomate;

v<sub>1</sub> = Saturação por bases atuais do solo;

T = Capacidade de Troca de Cátions (CTC) pH 7,0 cmolc dm<sup>-3</sup> [Ca<sup>2+</sup> + Mg<sup>2+</sup> + K<sup>+</sup> + (H<sup>+</sup> + Al<sup>3+</sup>)];

f = Fator de correção  $\frac{100}{PRNT}$

### 3.4. ESTATÍSTICA DESCRITIVA

As variáveis que compõem os atributos químicos e textura do solo, obtidas por meio da coleta de dados foram submetidas à estatística descritiva, com o objetivo de avaliar a dispersão e distribuição destes. Foram calculadas as medidas descritivas: média, mediana, moda, variância, desvio padrão, e coeficiente de variação, para cada uma das variáveis de estudo. Para verificar a normalidade dos dados, realizou-se o teste de Shapiro e Wilk (1965). Já a identificação de “Outliers”, foi por meio de interpretação gráfica (Box plot) e o critério de Tukey (1960). As análises estatísticas foram realizadas por meio dos softwares Sisvar 5.6 (FERREIRA, 2014) e R (R CORE TEAM, 2015).

### 3.5. REDE NEURAL ARTIFICIAL

Para realizar a preparação e treinamento das redes neurais artificiais foi utilizado o software GNU Octave e uma adaptação do programa desenvolvido por Rocha (2019). O treinamento foi realizado de acordo com a metodologia de Braga et al. (2014), que utiliza um algoritmo de retropropagação de erros ou back-propagation, com topologia do tipo Perceptron de Múltiplas Camadas (MLP) para a aprendizagem das RNAs.

Dois modelos foram treinados, o primeiro modelo tem o objetivo de estimar a necessidade de calagem para áreas de pivô central, e o segundo modelo busca diminuir o número de pontos necessários para fazer a aplicação de calcário a taxa variada.

### 3.5.1. Modelo 1: Alimentação de dados para estimativas da necessidade de calagem

Para compor o conjunto de variáveis para realização dos treinamentos, separam-se os dados em dois tipos de variáveis, variáveis de entrada e variáveis de saída (Figura 39) (BRAGA et al., 2014).

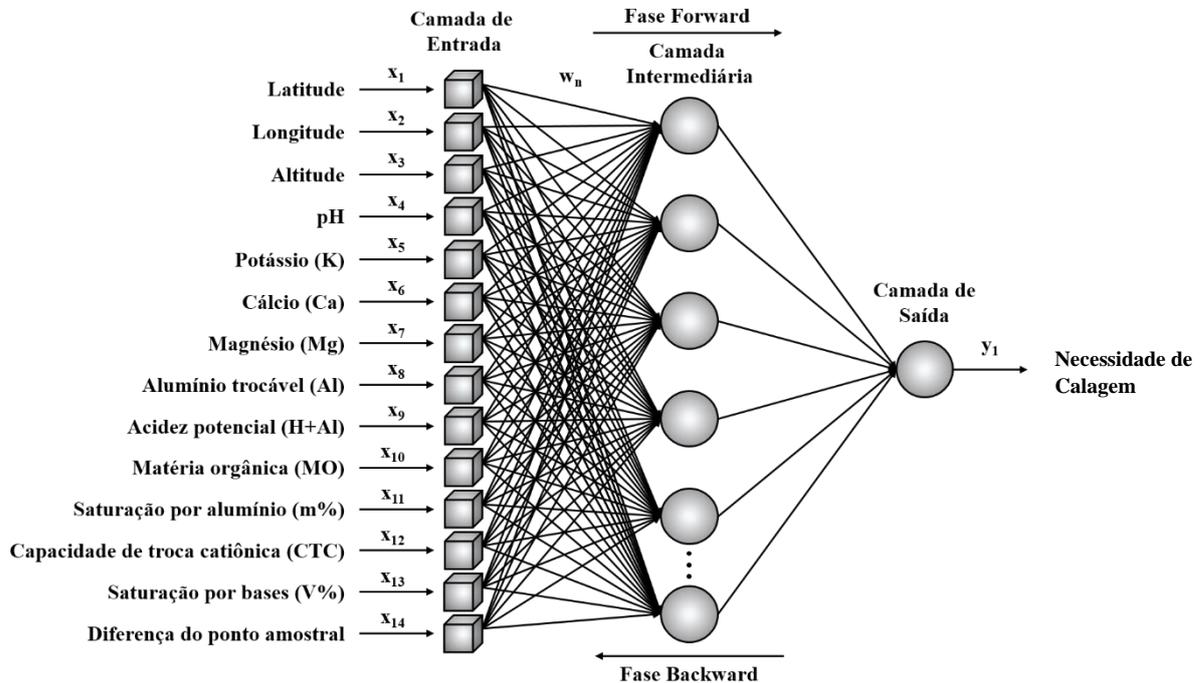


Figura 9. Modelo em blocos da arquitetura ilustrativa da RNA, com suas respectivas variáveis de entrada e saída.

Fonte: Autoria Própria (2019).

#### 3.5.1.1. Variáveis de entrada

As variáveis de entrada foram os dados inseridos na camada de entrada da rede. Sendo compostos pelas seguintes variáveis:

- Área: Como sugerido por Rocha (2019) a variável área foi definida como as variáveis A1, A2 e A3 para a área, sendo que estas assumem valores de 0 ou 1 (Figura 10 e Tabela 2). Na Tabela 2, 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.

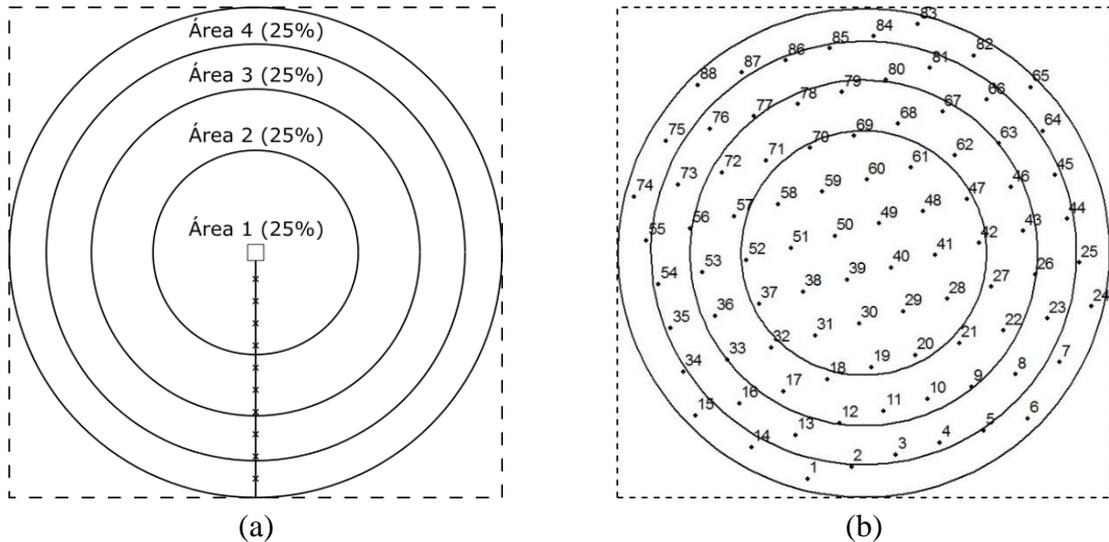


Figura 10. (a) Divisão fictícia do pivô em percentual de área; (b) Posicionamento dos pontos em relação a divisão fictícia do pivô em percentual de área.

Fonte: autoria própria (2019).

TABELA 2. 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: autoria própria (2019).

- As coordenadas X, Y e altitude dos pontos amostrais, foi adaptada a metodologia de Rocha (2019) com o objetivo de universalizar a utilização da RNA escolhida. Nesta metodologia, a rede pode ser aplicada em outros pivôs, não ficando restrita a somente à área de estudo. Os valores de DX, DY e DA foram obtidos pela diferença das coordenadas X e Y, e altitude de cada ponto em relação ao centro do pivô, respectivamente.

- 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 ponto a ponto, escolhidos aleatoriamente, conforme a separação dos conjuntos.

### 3.5.1.2. Variáveis de saída

As variáveis de saída foram os dados apresentados para camada de saída da RNA. Para compor a variável de saída, tem-se a necessidade de calagem calculada conforme a Equação 1.

### 3.5.1.3. Separação dos conjuntos

O conjunto de dados tem a finalidade de alimentar a rede e fornecer informações que condicionam a aprendizagem. De acordo com Alves (2016), os dados devem ser separados de forma aleatória em três conjuntos tanto para as variáveis de entrada quanto para as de saída:

- Conjunto de treinamento: 57 pontos, sendo 65% do total de pontos amostrais (88 pontos);
- Conjunto de validação: 22 pontos, sendo 25% do total de pontos amostrais;
- Conjunto de teste: 9 pontos, sendo 10% do total de pontos amostrais.

Cada um dos conjuntos deve conter informações de todos os setores citados na Figura 10b, para assegurar que todos os limites espaciais dos pontos sejam inseridos de forma equilibrada na RNA.

## **3.5.2. Modelo 2: Alimentação dos dados para redução do número de pontos necessários para coleta de amostras**

Para compor o conjunto de variáveis para realização dos treinamentos, separam-se os dados em dois tipos de variáveis, variáveis de entrada e variáveis de saída

### 3.5.2.1. Variáveis de entrada

As variáveis de entrada foram os dados inseridos na camada de entrada da rede. Para escolha das variáveis de entrada a serem inseridas foi utilizada uma adaptação da técnica de vizinhança, normalmente utilizada no processamento digital de imagens (GONZALES, 2010).

A técnica da vizinhança define quais serão os pontos que fornecerão os dados para compor as variáveis de entrada e quais pontos irão compor as variáveis de saída.

Como pode-se observar na Figura 11, os pontos destacados com os círculos e quadrados preenchidos pela cor verde representam os pontos que são referências para serem inseridos na camada de entrada da RNA, já os pontos destacados por quadrados e círculos sem preenchimento, serão os pontos a terem sua necessidade de calagem estimados pela RNA, ou seja, dão origem aos dados que compõem as variáveis de saída.

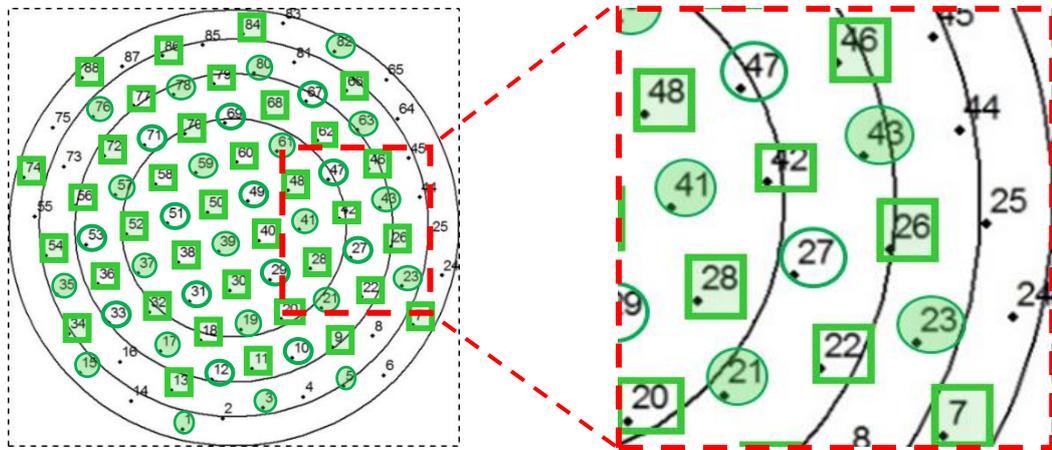


Figura 11. Esquema representativo da adaptação da técnica de vizinhança dos pontos, onde os pontos preenchidos da cor verde são pontos utilizados para estimar os pontos sem preenchimentos, equivalentes a forma geométrica que os representam (círculo ou quadrado).

Fonte: Autoria própria (2020).

Com este arranjo para inserir os dados na RNA, consegue-se diminuir o número de amostras coletadas em cerca de 30%, uma vez que de 88 pontos foram utilizados apenas 62 pontos para estimativa.

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

- As variáveis A1, A2 e A3 (Tabela 2) conforme o item 3.5.1.1..
- Os valores de DX, DY e DA tanto dos pontos preenchidos de verde quanto aos pontos sem preenchimento (Figura 11).
- 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.

### 3.5.2.2. 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 a necessidade de calagem calculada referentes aos pontos que foram estimados, destacados por círculos e quadrados sem preenchimento na Figura 11.

### 3.5.2.3. Separação do conjunto

Assim como no item 3.5.1.3. Separação dos conjuntos, os conjuntos de calibração de treinamento foram separados com uma única diferenciação devido a quantidade total de pontos:

- Conjunto de treinamento: 17 pontos, sendo 65% do total de pontos amostrais (26 pontos);
- Conjunto de validação: 6 pontos, sendo 25% do total de pontos amostrais;
- Conjunto de teste: 3 pontos, sendo 10% do total de pontos amostrais.

### 3.5.3. Normalização dos dados

Para que os dados de entrada possam ser inseridos na RNA torna-se necessário um pré-processamento, onde essas variáveis foram normalizadas para valores numa faixa entre -1 e 1, o que garante a equalização dos dados (ZARIFNESHAT et al., 2012). A transformação será realizada por meio da Equação 2 (SRINIVASAN et al., 1994):

$$y = \frac{(x - x_{\min})(d_2 - d_1)}{x_{\max} - x_{\min}} + d_1 \quad (5)$$

em que:

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

### 3.5.4. Escolha da Melhor RNA

A seleção da melhor RNA foi feita analisando os dados dos treinamentos consolidados e das validações externas, por meio das planilhas eletrônicas geradas pelas funções de treinamento e validação. Para determinar a rede com melhor desempenho foram utilizados os seguintes critérios:

- Maior índice de desempenho (id) no treinamento e na validação externa;

- Maior coeficiente de determinação ( $R^2$ );
- Menor erro quadrático médio (EQM).

Para as redes com melhor desempenho, foi executada a função de geração de gráficos, gerando dois arquivos: um com o gráfico de treinamento e outro com os gráficos do R linear dos conjuntos de treinamento, validação, teste e geral.

### 3.5.5. Desnormalização dos dados

Após o treinamento e validação das redes, será necessário realizar a desnormalização dos dados, para efeitos de comparação dos resultados estimados pelas RNAs, conforme Equação 3:

$$x = \frac{(x_{\text{máx}} - x_{\text{mín}}) * (y - d_1)}{d_2 - d_1} + x_{\text{mín}} \quad (6)$$

em que:

- y = resultado desnormalizado;
- x = 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).

## 3.6. VALIDAÇÃO DO MODELO

Conforme sugerido por Freitas (2017), para verificação da eficiência das estimativas obtidas pelas RNAs, foram utilizados os seguintes indicadores:

- Erro médio relativo (P%): permite calcular o erro médio entre os dados observados experimentalmente (análise de solo) e os dados estimados pela RNA;

$$P = \frac{100}{n} \sum \left| \frac{O-E}{O} \right| \quad (7)$$

em que:

- P - erro médio relativo;
- n - número de elementos;
- O - valores observados experimentalmente;
- E - valores estimados.

- Coeficiente de correlação: permite quantificar o grau de associação para cada atributo entre valores originais e os valores estimados pela RNA (SCHNEIDER, 1998);

$$r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)^2][\sum_{i=1}^n (O_i - O)^2]}} \quad (8)$$

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.

- Coeficiente de determinação: indica quanto a variação total é comum aos elementos que constituem os pares analisados, valores originais e valores estimados pela RNA. Quanto mais próximo da unidade for o coeficiente de determinação, maior será a validade do modelo;

$$\sqrt{R^2} = r \quad (9)$$

em que:

- $R^2$  - coeficiente de determinação;
- $r$  - coeficiente de correlação de Pearson.

- Índice de concordância: 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 valores estimados em relação aos valores observados, podendo variar entre 0 (nenhuma concordância) e 1 (concordância perfeita) (WILLMONT, 1981).

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2} \quad (10)$$

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.

- Índice de desempenho (id), conforme Equação 11. Na tabela 5, estão apresentados os critérios de avaliação do desempenho da RNA quanto ao seu índice de desempenho, conforme Camargo e Sentelhas (1997).

$$id = r \cdot c \quad (11)$$

em que:

- id* - índice de desempenho;  
*r* - coeficiente de correlação de Pearson;  
*c* - índice de concordância de Willmont.

TABELA 3. Análise do índice de desempenho da RNA.

Valor de <i>id</i>	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).

Com objetivo de testar se há indícios de diferenças dos valores originais em relação aos valores estimados por meio das RNAs, foi realizado o Teste-t.

## 4. RESULTADOS E DISCUSSÃO

### 4.1. ANÁLISE DESCRITIVA E EXPLORATÓRIA

A análise descritiva e exploratória foi realizada para todas as variáveis. De acordo com a classificação de Warrick e Nielsen (1980), obtiveram-se coeficientes de variação que variaram entre baixos, médios e altos. Como pode-se observar na Tabela 4, para as variáveis Al, Sat. Al (M%) e NC, encontrou-se coeficientes de variação considerados altos (>60%), isso se deve ao fato de ter um grande número de valores 0 para os teores de Al e M%, fazendo com que os desvios padrão fiquem maiores ou muito próximos dos valores das médias, resultando em grandes porcentagens de C.V. (%). A necessidade de calagem é proporcional aos teores de Al no solo por isso neste caso o C.V.(%) também apresentou um valor elevado. Bittar (2016) também identificou altos valores de C.V. (%) para as variáveis Al e M% estudando um latossolo vermelho escuro.

TABELA 4. Estatística Descritiva das variáveis específicas utilizadas no treinamento das Redes Neurais Artificiais (RNAs).

Atributos químicos	Média	Desvio padrão	Mín.	Máx.	C.V. (%)	Shapiro-Wilk W	p-value
pH (CaCl <sub>2</sub> )	4,99	0,33	4,40	6,60	6,55	0,90	0,90
Ca (cmolc/dm <sup>3</sup> )	3,24	1,02	1,60	6,30	31,40	0,93	0,00
Mg (cmolc/dm <sup>3</sup> )	1,17	0,56	0,50	3,60	47,77	0,83	0,00
Ca+Mg (cmolc/dm <sup>3</sup> )	4,41	1,53	2,20	9,40	34,70	0,89	0,00
Al (cmolc/dm <sup>3</sup> )	0,14	0,16	0,00	0,70	114,91	0,71	0,00
H+Al (cmolc/dm <sup>3</sup> )	3,73	1,12	1,30	6,80	30,07	0,97	0,03
CTC (cmolc/dm <sup>3</sup> )	8,71	1,94	5,43	14,36	22,23	0,97	0,04
K (cmolc/dm <sup>3</sup> )	0,57	0,14	0,28	0,90	23,92	0,99	0,80
M. O. (%)	2,29	0,30	1,20	2,70	13,25	0,84	0,00
Sat. Al (M%)	3,05	3,74	0,00	19,00	122,95	0,72	0,00
Sat. Base (V%)	56,94	9,54	27,00	88,00	16,76	0,98	0,21
Ca/Mg	2,97	0,63	1,60	4,50	21,34	0,90	0,00
Ca/CTC (%)	37,03	6,09	17,00	51,80	16,45	0,97	0,07
Mg/CTC (%)	13,16	4,08	5,70	32,10	31,00	0,92	0,00
(H+Al)/CTC (%)	43,09	9,61	11,60	72,30	22,30	0,98	0,31
K/CTC (%)	6,76	1,75	3,10	13,60	25,95	0,97	0,06
NC (ton/ha)	1,26	0,86	0,10	4,24	69,17	0,92	0,00

Mín: valor mínimo; Máx: valor máximo; C.V.: coeficiente de variação; p-value e W: teste normalidade Shapiro Wilk a 5%; pH-Potencial Hidrogeniônico; Ca – Cálcio (cmolc dm<sup>-3</sup>); Mg - Magnésio (cmolc dm<sup>-3</sup>); Al – Alumínio (cmolc dm<sup>-3</sup>); H+AL – Acidez Potencial (cmolc dm<sup>-3</sup>); CTC – Capacidade de Troca Catiônica; K – Potássio (cmolc dm<sup>-3</sup>); Sat. Al M % - Saturação por Alumínio (%); V% - Saturação por Bases (%); M.O.- Matéria Orgânica (g dm<sup>-3</sup>); Ca/Mg – Cálcio sobre Magnésio; Ca/CTC (%) – Cálcio sobre a Capacidade de Troca Catiônica; Mg/CTC (%) – Magnésio sobre a Capacidade de Troca Catiônica; (H+Al) /CTC (%) – Acidez potencial sobre a Capacidade de Troca Catiônica; K/CTC (%) – Potássio sobre a Capacidade de Troca Catiônica; NC (ton/ha) – Necessidade de Calagem.

Para as variáveis Ca, Mg, Ca+Mg, H+Al, CTC, K, M. O. (%), Sat. Base (V%) Ca/Mg, Ca/CTC, Mg/CTC, (H+Al)/CTC e K/CTC foram encontrados coeficientes de variação considerados médios ( $12\% < C.V. < 60\%$ ). Em estudos realizados por Cherubin et al. (2014), Santi et al. (2012) os C.V. também variaram nessa faixa. Já a variável pH, possui um C.V. que pode ser considerado baixo ( $< 12\%$ ). Valores parecidos foram encontrados por Freitas (2017).

De acordo com a classificação de Ribeiro et al. (1999) em relação a fertilidade do solo, o valor médio da Capacidade de Troca Catiônica de  $8,71 \text{ cmolc/dm}^3$  pode ser classificado como bom ( $8,61 \text{ cmolc/dm}^3 < CTC < 15,00 \text{ cmolc/dm}^3$ ). Já o valor médio de Saturação por bases foi de  $56,94\%$  podendo ser considerado médio ( $40,01\% < V\% < 60,00\%$ ). O valor médio encontrado para o pH foi de  $4,99$  podendo ser considerada uma acidez alta ( $4,4 < \text{pH} < 5,0$ ), em relação a cultura do tomate industrial o potencial hidrogeniônico não está adequado, uma vez que, o valor recomendado está entre  $5,5$  e  $6,5$  (SILVA et al., 2012).

Com o teste de Shapiro-Wilk a  $5\%$  de probabilidade constatou-se para as variáveis estudadas com exceção de K, Sat. Base (V%), Ca/CTC e K/CTC que os dados não seguem, distribuição normal.

Utilizando o critério de Tukey (1960) e gráficos do tipo *Boxplot*, foram encontrados *outliers*, no entanto devido ao fato de se utilizar RNAs do tipo MLP (*Multilayer Perceptron*), que realiza as estimativas por método de validação cruzada, estas redes conseguiram lidar tanto com valores *outliers* quanto os altos valores de coeficientes de variação evitando com que esses valores influenciassem na modelagem.

#### 4.2. TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

Devido ao grande número de redes treinadas, foi essencial a utilização do programa desenvolvido por Rocha (2019) (Figura 12), pois com esse programa foi possível variar a complexidade da arquitetura de cada rede (número de neurônios da camada oculta), visto que, Braga et al., (2012) menciona problemas de dimensionamento e ajuste do número de neurônios em relação a complexidade do problema a ser resolvido. Desta forma, com o programa foi possível ajustar e evidenciar o índice de desempenho para cada número de neurônios na camada oculta.

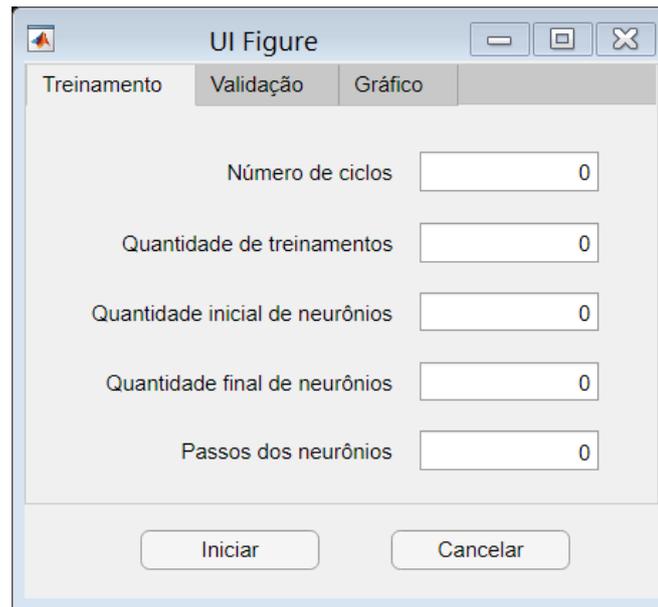


FIGURA 12. Interface gráfica do programa criado para agilizar a utilização das funções desenvolvidas neste estudo.

Fonte: autoria própria (2019).

Com esse programa foi possível automatizar o desenvolvimento das redes, isso contribuiu para a otimização do esforço computacional e do tempo para realizar os treinamentos. Na configuração final, foram realizados 1.000 treinamentos para cada número de neurônios da camada oculta que variaram de 1 a 20, totalizando 20.000 RNAs para cada modelo.

Para o treinamento, o programa necessitou de uma planilha em xls (Microsoft Excel), com todas as variáveis de entrada e a variável de saída. As informações foram normalizadas dentro do programa, após isso, começou o treinamento, que gerou uma planilha com os dados estimados, todos os indicadores estatísticos (Erro da raiz do quadrado médio, erro relativo médio, coeficiente de determinação, coeficiente de correlação, índice de concordância de Willmont e índice de desempenho), além da geração de gráficos das fases de treinamento.

#### 4.2.1. Modelo 1: Rede neural artificial para estimativas da necessidade de calagem

Depois de treinadas foi realizada a quantificação dos resultados em relação ao desempenho das redes (Figura 13). Nota-se na Figura 13 que para as fases de treinamento houveram mais de 14.000 redes com um ótimo desempenho para as estimativas desejadas, entretanto, quando se observa a validação externa, nota-se que apenas pouco mais de 50 redes obtiveram desempenho ótimo, portanto, mostrando o fenômeno de *overfitting* onde as redes começaram a se especializar apenas no conjunto de treinamento.

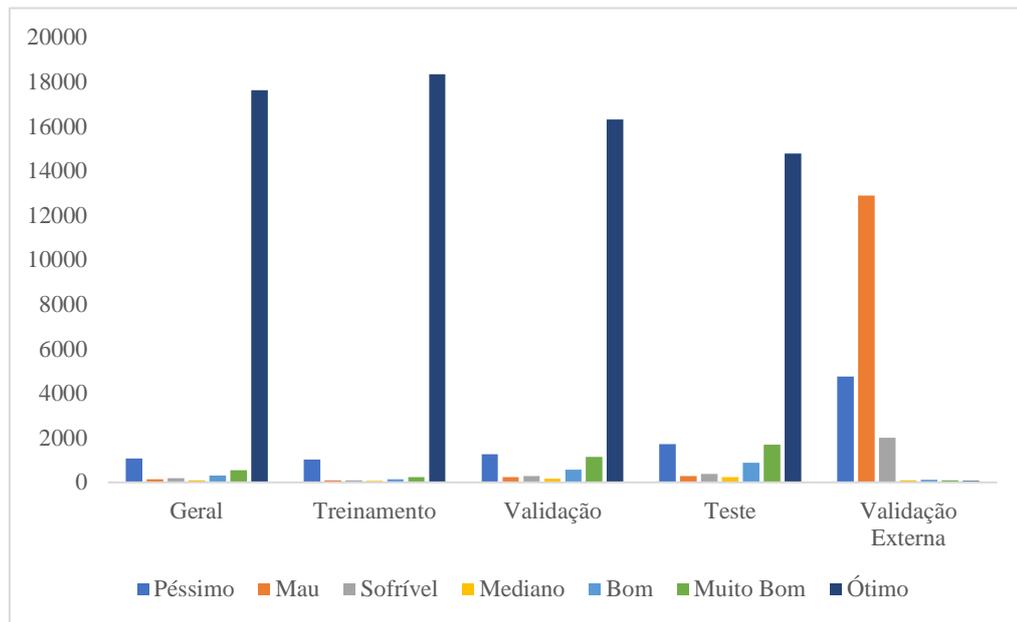


FIGURA 13. Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de Necessidade de Calagem.

Fonte: autoria própria (2019).

##### 4.2.1.1. Escolha da rede

Segundo Braga et al. (2012), para que o modelo utilizado possa ser aplicado em quaisquer conjuntos de dados, torna-se imprescindível que as redes neurais artificiais consigam generalizar o problema. Com base nesse pressuposto, o primeiro critério foi o desempenho na validação externa, pois, se a rede conseguiu obter um ótimo desempenho com os dados externos ao treinamento, ou seja, dados nunca antes apresentados a rede durante o treinamento, indica a capacidade de generalização.

Das 20.000 redes treinadas 60 redes tiveram um ótimo desempenho na fase de validação externa. Sendo assim o segundo critério foi ter um ótimo desempenho em todas as fases de treinamento (geral, treinamento, validação e teste). 35 redes conseguiram atingir esta meta. O

desempenho baseado na técnica de Camargo e Sentelhas, (1997), mostra em termos de exatidão (r) e precisão (c) a confiança apresentada pelo modelo.

Outros critérios adotados foram os de menor EQM (erro quadrático médio) que indica o grau de dispersão dos dados obtidos em relação à média, ou seja, o erro aleatório, e ainda a intensidade da relação linear entre os dados observados e os dados estimados, que é dada pelo r (coeficiente de correlação de Pearson) (CAMARGO ; SENTELHAS, 1997). Posteriormente foram selecionadas 4 redes neurais artificiais, em função de todos os critérios adotados e do número de neurônios na camada oculta.

Como pode-se observar na Tabela 6, foram escolhidas 4 RNAs, sendo o desempenho de todas em todas as fases de treinamento e na fase de validação externa ótimo. Mostrando-se a rede mais precisa, a RNA1 (2 neurônios na camada oculta) conseguiu demonstrar o menor EQM em todas as fases, com exceção da fase de Validação interna (0,005), onde a RNA2 (3 neurônios na camada oculta) conseguiu um valor menor (0,003), desta forma a RNA1 se sobressaiu nesse quesito.

A Tabela 6, também mostra os coeficientes de correlação, todos ficaram bem próximos de 1, mostrando que além de uma relação de linearidade muito forte, existe uma tendência crescente, para todos os conjuntos analisados. Neste critério a RNA1 também se mostrou mais acurada, pois, em todas as fases ela se sobressai em relação as outras redes escolhidas. Fernandes et al. (2019) estimando a matéria orgânica do solo por meio de RNAs, encontrou também altos valores de correlação e de concordância, com baixos erros (EQM), neste caso mostrando-se superior às estimativas por meio de regressão linear múltipla.

Segundo Braga et al., (2012) redes com menor número de neurônios na camada oculta têm maior capacidade de generalização, pois, redes com grande número de neurônios na camada oculta podem resultar em *overfitting*. Quanto maior a estrutura, maior o número de parâmetros livres ajustáveis e, conseqüentemente, maior a flexibilidade da rede, gerando redes que memorizam os dados de entrada. superdimensionadas.

As RNA3 (6 neurônios na camada oculta) e RNA4 (14 neurônios na camada oculta) tiveram desempenho ótimo, porém a RNA1 (2 neurônios na camada oculta) obteve um melhor desempenho em relação aos critérios adotados. Portanto a rede escolhida, foi a RNA1, que mostrou ótimo desempenho, a melhor precisão e acurácia (Tabela 6).

TABELA 5. Resultados dos indicadores estatísticos para estimativas da necessidade de calagem das redes selecionadas.

RNA	Neur.	Calib.	EQM	P(%)	R <sup>2</sup>	r	c	id	Desemp.
1	2	Geral	0,002	9,113	0,991	0,996	0,998	0,993	Ótimo
		Trein.	0,000	4,743	0,997	0,999	0,999	0,998	Ótimo
		Val. Int.	0,005	9,105	0,976	0,989	0,991	0,980	Ótimo
		Teste	0,001	37,535	0,993	0,997	0,998	0,995	Ótimo
		Val. Ext.	0,011	119,105	0,981	0,956	0,982	0,963	Ótimo
2	3	Geral	0,002	15,582	0,991	0,996	0,997	0,993	Ótimo
		Trein.	0,001	11,501	0,997	0,999	0,999	0,997	Ótimo
		Val. Int.	0,003	23,009	0,976	0,989	0,988	0,966	Ótimo
		Teste	0,005	23,540	0,993	0,997	0,990	0,973	Ótimo
		Val. Ext.	0,061	367,153	0,926	0,834	0,922	0,854	Ótimo
3	6	Geral	0,005	16,821	0,988	0,975	0,994	0,981	Ótimo
		Trein.	0,001	12,676	0,997	0,993	0,998	0,995	Ótimo
		Val. Int.	0,010	24,577	0,979	0,956	0,987	0,966	Ótimo
		Teste	0,012	24,368	0,931	0,845	0,951	0,886	Ótimo
		Val. Ext.	0,026	232,417	0,914	0,808	0,949	0,868	Ótimo
4	14	Geral	0,004	22,882	0,989	0,979	0,994	0,983	Ótimo
		Trein.	0,000	11,414	0,999	0,998	0,999	0,998	Ótimo
		Val. Int.	0,012	42,934	0,989	0,976	0,987	0,976	Ótimo
		Teste	0,009	47,287	0,976	0,944	0,988	0,964	Ótimo
		Val. Ext.	0,042	393,263	0,961	0,911	0,945	0,909	Ótimo

RNA: rede neural artificial; Neur.: número de neurônios na camada oculta; Calib.: fase de calibração; EQM: erro quadrático médio; P(%): erro médio relativo; R<sup>2</sup>: coeficiente de determinação; id: índice de desempenho; Trein.: Fase de treinamento; Val. Int.: fase de validação interna; Val. Ext.: fase de validação externa.

#### 4.2.1.2. Rede escolhida

A rede selecionada tem 2 neurônios e foi encontrada no treinamento 574. Ela necessitou de 110 ciclos para chegar à convergência estipulada no programa de treinamento (Figura 14), interrompendo o treinamento também no ciclo 110. O treinamento da rede neural ajustou os valores dos 2 neurônios da camada oculta e os valores dos *bias* de cada um, assim como do neurônio de saída. Com um EQM baixo, pode-se evidenciar a alta precisão da rede.

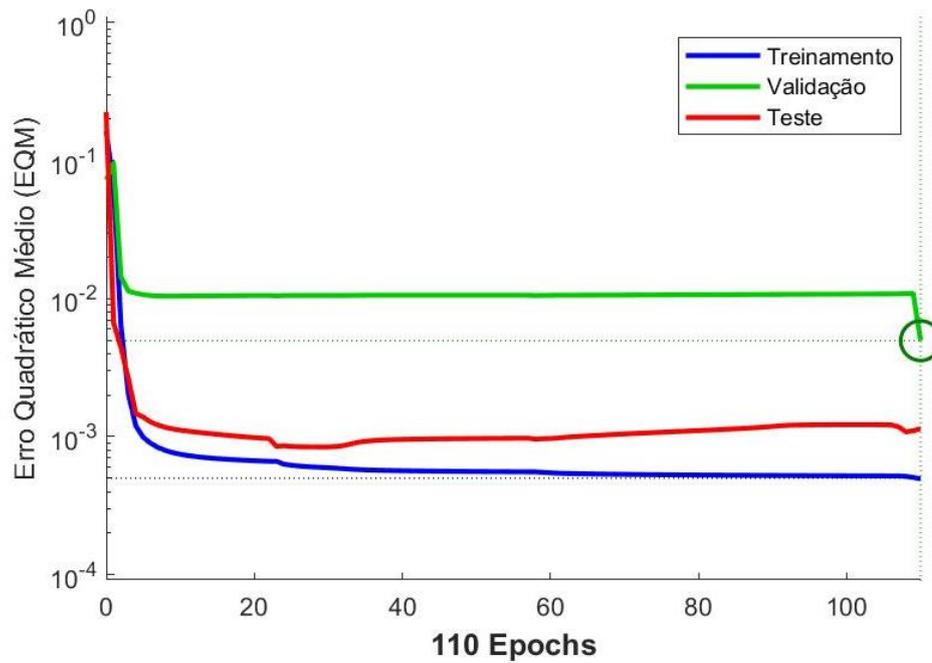


FIGURA 14. Representação gráfica da fase de treinamento da rede selecionada (2 neurônios e treinamento 574).

Fonte: autoria própria (2019).

Outro fator que se mostra de fundamental importância são as repetições, pois só após a repetição 574, a rede conseguiu ajustar os pesos de forma com que conseguisse se adequar melhor às estimativas de necessidade de calagem.

Em todas as fases de treinamento foram gerados gráficos de dispersão, onde os dados de necessidade de calagem observados (calculados pelo método tradicional de saturação por bases) estão no eixo X, e os dados de necessidade de calagem estimados pela rede estão no eixo Y. Sendo assim, a Figura 15 apresenta a tendência crescente do conjunto juntamente com os valores respectivos aos coeficientes de correlação de Pearson ( $r$ ) de cada fase da RNA1. Isso evidencia a capacidade que a rede tem de estimar os dados com acurácia.

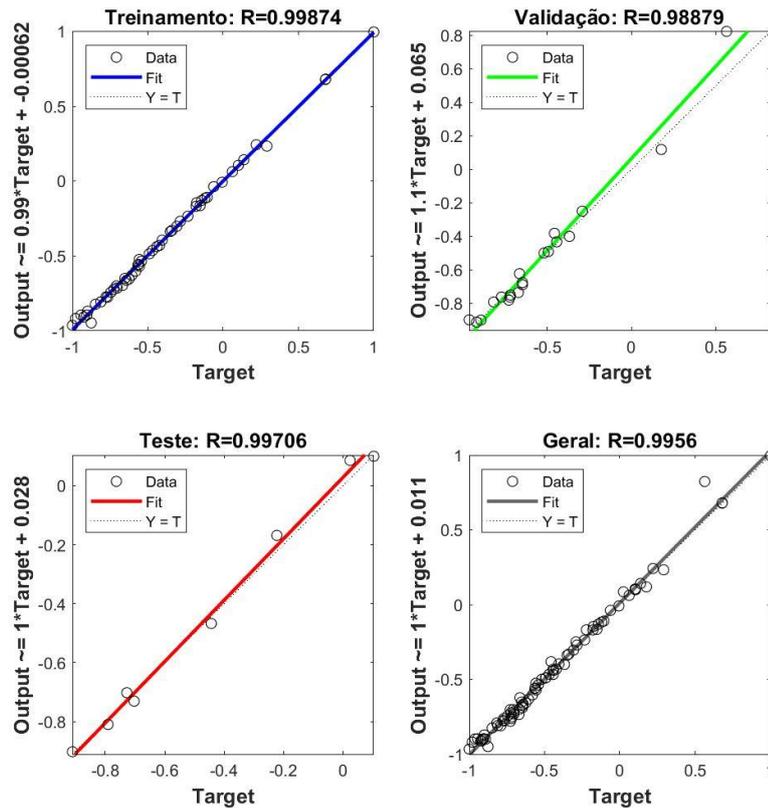


FIGURA 15. Representação gráfica do coeficiente de correlação (r) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (2 neurônios e treinamento 574).

Fonte: autoria própria (2019).

A Figura 16 apresenta duas linhas que representam os dados calculados pelo método tradicional de necessidade de calagem e os dados de necessidade de calagem estimados pela RNA, mais uma vez evidenciando o quanto a rede teve um baixo erro aleatório, uma vez que os valores estimados praticamente acompanham os valores calculados pelo método tradicional para os 88 pontos amostrados. Angélico (2005) em seu trabalho com latossolo vermelho conseguiu estimar atributos químicos do solo por meio de RNAs, em que os dados estimados pelas redes conseguiram um menor erro aleatório em relação a krigagem e a co-krigagem.

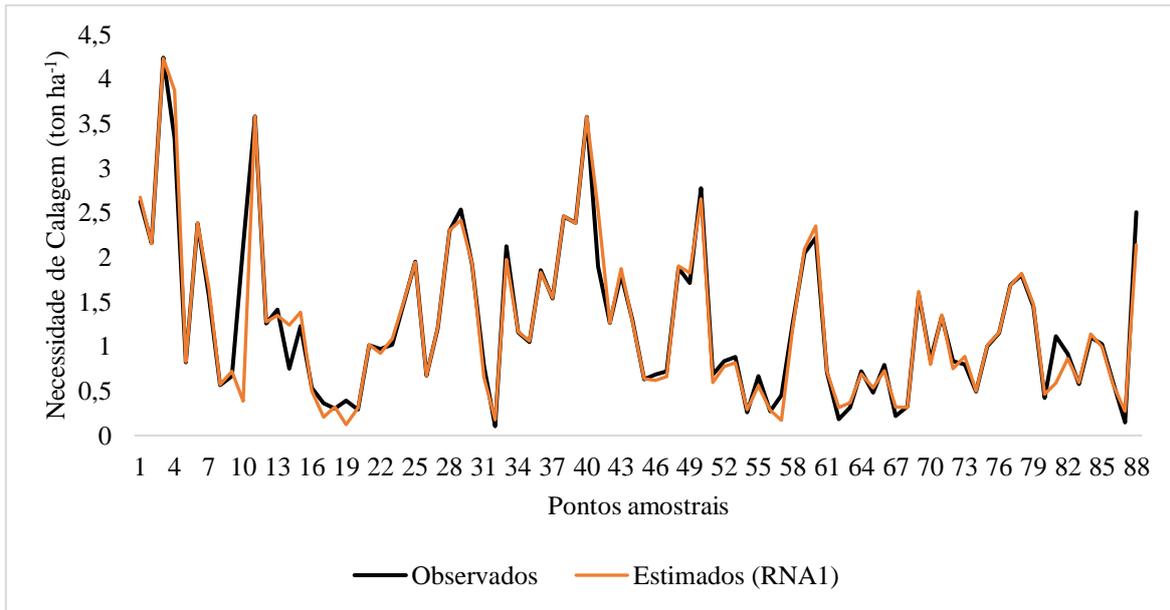


Figura 16. Comparativo geral dos valores observados (calculados pelo método tradicional de saturação por bases) e valores estimados de necessidade de calagem da rede selecionada (2 neurônios e treinamento 574).

Fonte: autoria própria (2019).

#### 4.2.1.3. Necessidade de calagem

A determinação da necessidade de calagem não apresenta metodologia unificada em todo o Brasil. São quatro os principais métodos para se estimar a necessidade de calagem dos solos no Brasil: método da solução tampão (SMP), método da saturação por bases, método da elevação dos teores de cálcio e magnésio, método da neutralização do  $Al^{3+}$  (FULIN, 2001). A determinação da necessidade de calagem por meio de RNAs possibilita modelar o problema levando em consideração mais variáveis como: as distâncias de altitude (m), a latitude e a longitude do ponto amostral em relação ao centro do pivô central, assim possibilitando a generalização da rede para qualquer pivô central.

Quando comparado ao método de saturação por bases, o modelo conseguiu estimar com precisão e acurácia a necessidade de calagem. Como pode-se observar na Tabela 7, que mostra o Teste-t para duas amostras, que não existe diferença significativa a 5% de probabilidade para os dados de necessidade de calagem estimados pela RNA1 em relação aos dados observados de necessidade de calagem.

TABELA 6. Teste-t para os dados observados de necessidade de calagem em relação aos dados de necessidade de calagem estimados pela RNA1.

	NC	RNA1
Média	1,27	1,26
Variância	0,75	0,80
Observações	88	88
gl	174	
p-value	0,90	

NC: necessidade de calagem observada pelo método de saturação por bases; RNA1: necessidade de calagem estimada pela RNA1; Gl: graus de liberdade; p-value: teste de t-student significativo a 5% de probabilidade.

Fonte: Autoria própria (2019).

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

Para se realizar o treinamento das RNAs, foi gerado um arquivo xls para inserção de dados na rede. O arquivo xls foi composto por 26 linhas, cada uma delas representando um ponto que a RNA estimou. Em 87 colunas estão as variáveis de entrada além de a última coluna ser preenchida pelos dados da variável de saída conforme a Figura 17.

Figura 17. Arquivo xls organizado e preparado para inserção na rede neural artificial.

Fonte: Autoria própria, (2020).

Utilizando novamente o programa de Rocha (2019), foram realizados 1.000 treinamentos para cada número de neurônios da camada oculta que variaram de 1 a 20, totalizando 20.000 RNAs.

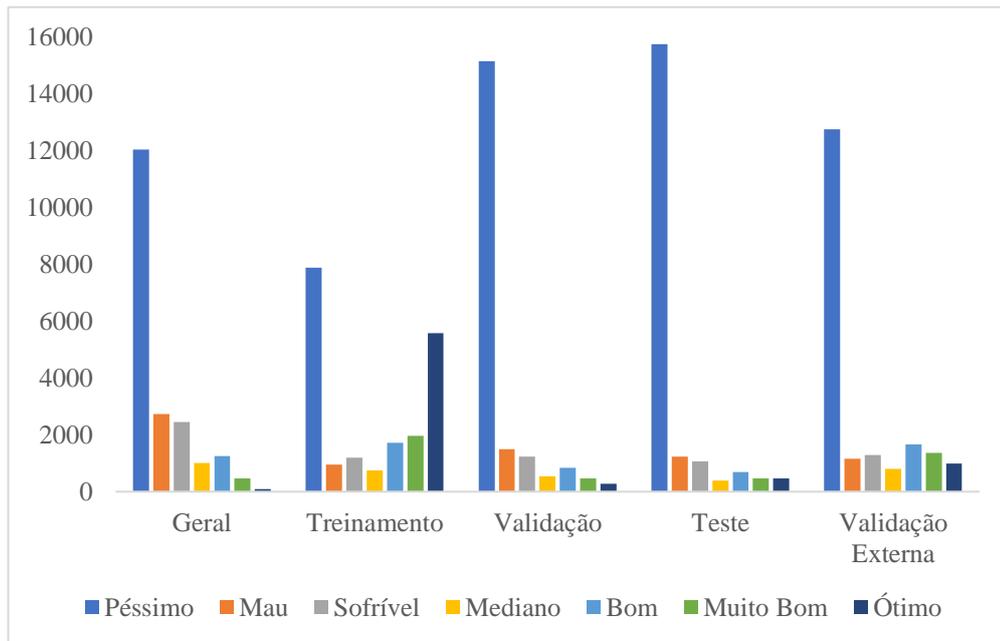


Figura 18. Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados de Necessidade de Calagem.

Fonte: autoria própria (2020).

Após a realização dos treinamentos e validações, foram feitas as quantificações do índice de desempenho de todas as RNAs em cada fase de calibração, além da validação externa, como pode-se observar na Figura 18. Nota-se que o número de índices de desempenho classificados como “Péssimo” se destaca com mais de 15.000 redes para fases de calibração Validação e Teste, mais de 12.000 para a Validação Externa e mais de 7.000 para o treinamento. Freitas (2019) encontrou resultados parecidos para estimativas do índice de área foliar do tomate industrial, por meio de RNAs.

#### 4.2.2.1. Escolha da rede

O primeiro critério avaliado para a escolha da rede foi o desempenho na validação externa, uma vez que este se remete a capacidade da RNA de generalizar o problema (BRAGA et al., 2012). Na fase de validação externa 980 redes obtiveram um desempenho ótimo e pouco mais de 1300 redes obtiveram um desempenho muito bom. O segundo critério avaliado foi o desempenho nas fases de calibração do treinamento, tendo como meta encontrar desempenhos entre ótimo e muito bom. Com o segundo critério foi possível filtrar as redes e encontrar apenas duas que atendem a estes pressupostos, como pode-se observar na Tabela 8.

Também pode-se observar na Tabela 8, os valores referentes a todos os indicadores estatísticos que são fundamentais para a escolha da melhor rede. Com exceção do teste e validação externa que se obteve desempenho muito bom, a RNA1 obteve desempenho ótimo

nas demais fases de calibração, tendo 6 neurônios na camada oculta. A RNA1 também obteve um baixo erro aleatório (EQM) em todas as fases de calibração, que com exceção da validação externa obteve vantagem sobre a RNA2, ou seja, com valores de EQM mais baixos, mostrando que o grau de dispersão dos dados em relação à média foi menor na RNA1.

Os coeficientes de correlação ( $r$ ) foram todos próximos de 1, indicando que além de uma relação de linearidade muito forte, existe uma tendência crescente, para todos os conjuntos analisados (Tabela 8). Neste indicador a RNA1 também mostrou vantagens quando comparada a RNA2 que com exceção do teste na fase de calibração, obteve coeficientes  $r$  mais próximos de 1 em todas as demais fases.

Por fim, outro fator importante para escolha da RNA é o número de neurônios na camada oculta, que por sua vez quanto menor este número maior é a capacidade de generalização do problema, pois segundo Braga et al. (2012) redes com grande número de neurônios na camada oculta podem resultar em *overfitting*. Quanto maior a estrutura, maior o número de parâmetros livres ajustáveis e, conseqüentemente, maior a flexibilidade da rede, gerando redes que memorizam os dados de entrada. superdimensionadas.

RNA	Neur.	Calib.	EQM	P(%)	R <sup>2</sup>	r	c	id	Desempenho
1	6	Geral	0,025	25,055	0,908	0,953	0,974	0,929	Ótimo
		Treinamento	0,006	13,354	0,986	0,993	0,994	0,987	Ótimo
		Validação int.	0,040	34,639	0,865	0,930	0,937	0,871	Ótimo
		Teste	0,091	67,587	0,795	0,891	0,912	0,813	Muito bom
		Validação ext.	0,096	179,099	1,000	0,999	0,828	0,828	Muito bom
2	12	Geral	0,048	51,882	0,820	0,906	0,948	0,858	Ótimo
		Treinamento	0,036	39,332	0,907	0,952	0,967	0,921	Ótimo
		Validação int.	0,045	55,330	0,811	0,900	0,925	0,833	Muito bom
		Teste	0,108	108,886	0,991	0,995	0,813	0,809	Muito bom
		Validação ext.	0,011	30,163	0,998	0,992	0,954	0,952	Ótimo

RNA: rede neural artificial; Neur.: número de neurônios na camada oculta; Calib.: fase de calibração; EQM: erro quadrático médio; P(%): erro médio relativo; R<sup>2</sup>: coeficiente de determinação; id: índice de desempenho; Trein.: Fase de treinamento; Val. Int.: fase de validação interna; Val. Ext.: fase de validação externa.

#### 4.2.2.2. Rede escolhida

A rede selecionada tem 6 neurônios e foi encontrada no treinamento 714. Ela necessitou de 8 ciclos para chegar à convergência estipulada no programa de treinamento (Figura 19), interrompendo o treinamento também no ciclo 8. O treinamento da rede neural

ajustou os valores dos 6 neurônios da camada oculta e os valores dos *bias* de cada um, assim como do neurônio de saída. Com um EQM baixo, pode-se evidenciar a alta precisão da rede.

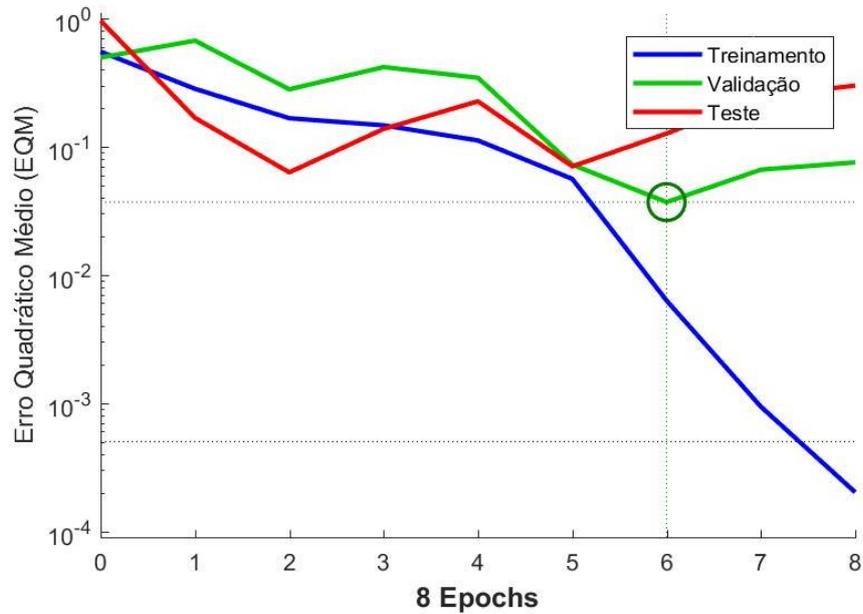


Figura 19. Representação gráfica da fase de treinamento da rede selecionada (6 neurônios e treinamento 714).

Fonte: autoria própria (2020).

Na Figura 20 pode-se observar o gráfico de dispersão em todas as fases de treinamento, onde os dados de necessidade de calagem dos 26 pontos observados experimentalmente (calculados pelo método tradicional de saturação por bases) estão no eixo X, e os dados de necessidade de calagem dos 26 pontos estimados pela rede estão no eixo Y, além de evidenciar a capacidade que a RNA tem de estimar os dados com acurácia, uma vez que todos os coeficientes de correlação da fase de calibração foram maiores que 0,89, sendo assim também, mostrando uma forte tendência crescente.

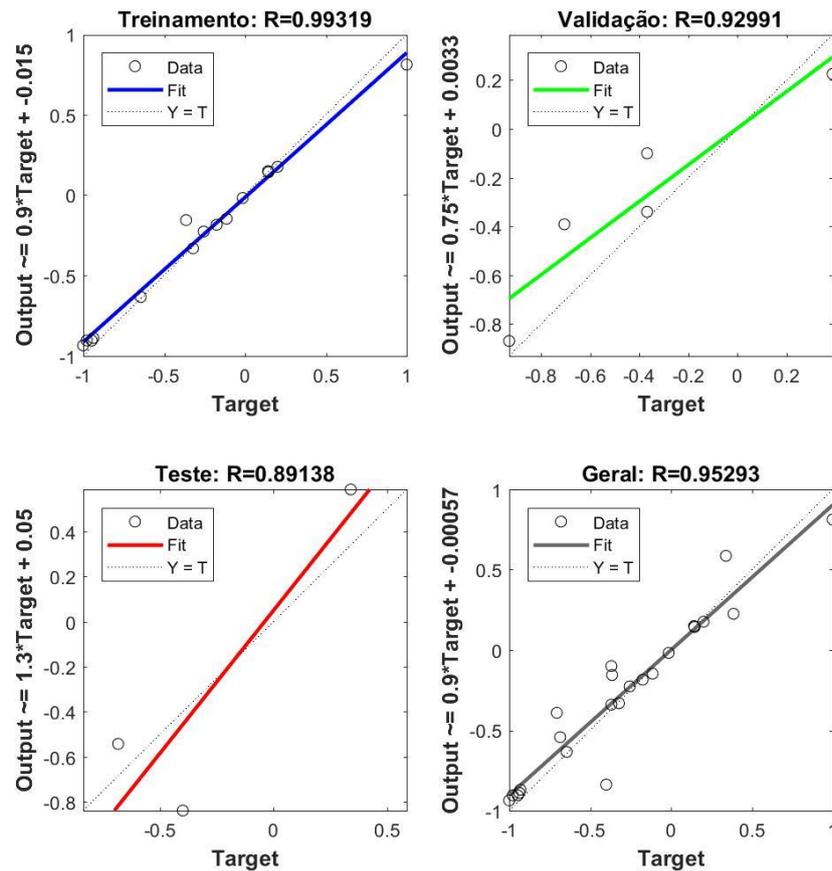


Figura 20. Representação gráfica do coeficiente de correlação ( $r$ ) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (6 neurônios e treinamento 714).

Fonte: autoria própria (2020)

A Figura 21 mostra duas linhas que representam os dados observados de necessidade de calagem e os dados estimados de necessidade de calagem, mais uma vez evidenciando o quanto a rede teve um baixo erro aleatório, uma vez que os valores estimados praticamente acompanham os valores observados (calculados pelo método tradicional de saturação por bases) para os 26 pontos amostrados. As estimativas realizadas por essa rede neural artificial encontraram erros aleatórios (EQM) entre 0,06% e 0,9% e podem ser consideradas muito boas, quando comparadas a outros trabalhos, como a estimativa de atributos químicos do solo apresentada por Freitas (2017), que encontrou erros aleatórios entre 8% e 16%.

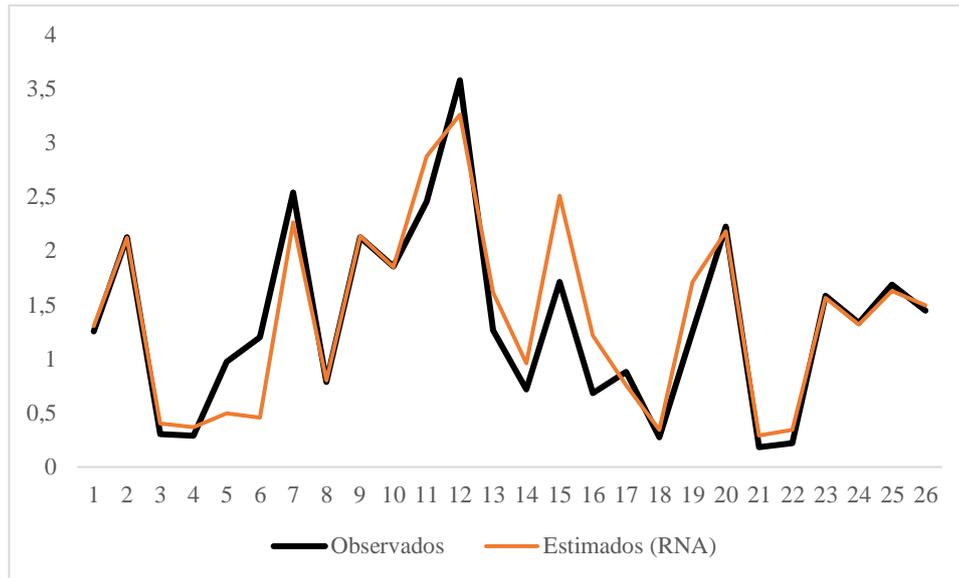


Figura 21. Comparativo geral da rede selecionada para os valores observados (calculados pelo método tradicional de saturação por bases) e estimados para redução de amostras necessárias para coleta de amostras (2 neurônios e treinamento 574).

Fonte: autoria própria (2020).

#### 4.2.2.3. Redução de amostras de coleta de dados visando estimativas para análise geoestatística

Por meio da técnica de seleção de variáveis a RNA utilizada para as estimativas conseguiu diminuir em torno de 30% o número de amostras em campo necessárias e com isso estimar os valores necessários para a análise geoestatística a serem usados para avaliar a variabilidade espacial na área de plantio e a partir dessa análise uma possível aplicação regionalizada de calcário. Segundo Molin et al., (2015) o número de amostras é imprescindível para a qualidade do mapa final e da sua capacidade de representar adequadamente a realidade, deste modo um fator limitante para a máxima eficiência econômica é a quantidade de pontos amostrais necessários para se conseguir realizar a aplicação de corretivo a taxa variada, sendo assim a principal vantagem deste modelo é reduzir de 88 para 62 amostras necessárias, uma vez que por meio de 62 amostras o modelo consegue estimar a necessidade de calagem nos 26 pontos restantes.

Quando comparados aos dados experimentais dos 26 pontos amostrais, os dados estimados pela RNA também se mostram acurados e precisos. Quando submetidos ao Teste-t a 5% de probabilidade não apresentou diferenças significativas (Tabela 9), desta forma pode-se inferir que a RNA conseguiu estimar a necessidade de calagem com um bom grau de confiança. Aitkenhead et al. (2012), em seus estudos conseguiram prever com um bom grau de confiança

a composição química e física do solo utilizando informações de observações de campo em uma rede neural.

Tabela 8. Teste-t para os dados observados de necessidade de calagem em relação aos dados de necessidade de calagem estimados pela RNA1.

	Observado	Estimado (RNA)
Média	1,34	1,40
Variância	0,71	0,72
Observações	26	26
gl	50	
p-value	0,41	

Observado: necessidade de calagem observada pelo método de saturação por bases; Estimado (RNA): necessidade de calagem estimada pela RNA1; Gl: graus de liberdade; p-value: teste de t-student significativo a 5% de probabilidade.

Fonte: Autoria própria (2020).

Desta forma a técnica de vizinhança que foi adaptada e se mostrou bastante satisfatória, conseguindo diminuir consideravelmente o número de amostras a serem demandadas (Figura 22), tornando este modelo mais viável que o método tradicional, uma vez que reduzindo o número de amostras a serem coletadas, se reduz também a mão-de-obra, o tempo gasto e o custo das análises de solo, viabilizando ainda um possível mapeamento da necessidade de calagem a taxa variada. Entretanto faz-se necessário o aprimoramento da técnica para diminuir ainda mais o número de pontos a serem coletados.

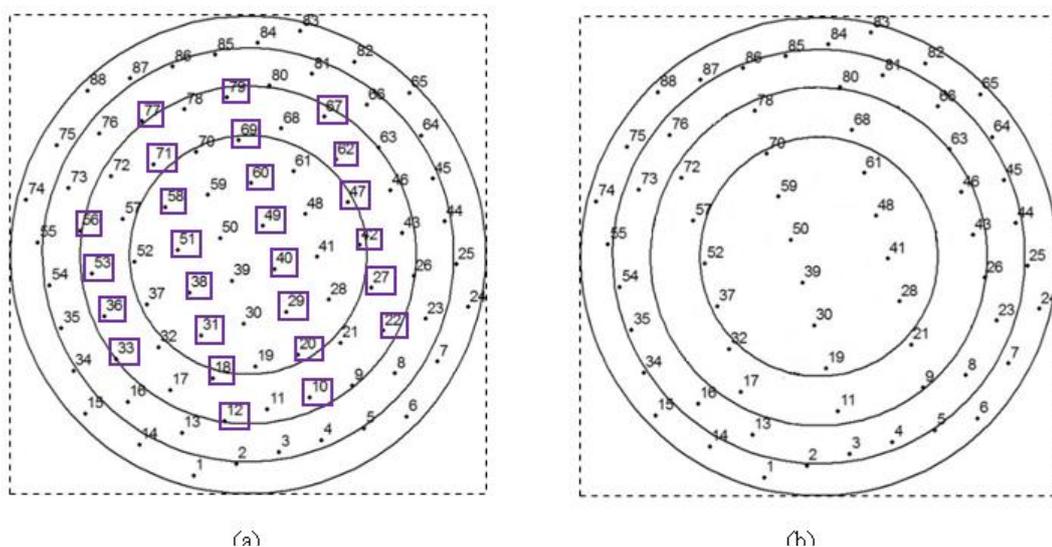


Figura 22- (a) Esboço da grade amostral destacando os pontos que podem ser estimados pela Rede Neural Artificial (RNA) na área experimental. (b) Esboço da nova grade amostral da área experimental sem os 26 pontos que podem ser estimados pela RNA.

Fonte: Autoria Própria (2020).

## 5. CONCLUSÃO

A RNA do tipo Multilayer Perceptron (MLP) com treinamento supervisionado conseguiu estimar com coeficiente de correlação acima de 99% a necessidade de calagem.

Para validar as RNAs é necessário implementar e executar a validação externa, com dados ainda não apresentados para a rede na fase de treinamento.

A arquitetura que melhor estimou necessidade de calagem foi de 2 neurônios na camada oculta, na repetição 574.

A metodologia utilizada para a obtenção das coordenadas X e Y, e altitude, possibilita a universalização da RNA escolhida em relação ao pivô no qual a rede foi desenvolvida, sendo necessário a aplicação da rede treinada em outros pivôs para validá-la.

A técnica de vizinhança dos pontos adaptada para inserção de dados na rede, conseguiu diminuir o número de amostras necessárias para possíveis estudos visando a aplicação regionalizada de calcário em aproximadamente 30%.

A arquitetura que melhor estimou a necessidade de calagem para a redução de amostras necessárias para aplicação regionalizada foi de 6 neurônios na camada oculta, na repetição 714, com a correlação (r) acima de 89%.

Sugere-se mais estudos para aprimoramento para a técnica de vizinhança de pontos adaptada, visando uma redução maior do número de amostras coletadas em campo.

## 6. REFERÊNCIAS

- AITKENHEAD, M.J.; COULL, M.C.; TOWERS, W.; HUDSON, G.; BLACK, H.I.J. Predicting soil chemical composition and other soil parameters from field observations using a neural network. **Computers and Electronics in Agriculture**, Oxford, v.82, s/n, p.108–116, 2012.
- ALEKSANDER, I.; MORTON, H. **An introduction to neural computing**. Lodon: Int Thomson Comput Press, 1995.
- ALVES, G.R. Estimativa da produtividade da soja com redes neurais artificiais 2016. 76p. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás, Anápolis, 2016.
- 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. Agronomy**, Maringá, e. 35250, v.40, n.1 , mar. 2018.
- AMADO, T.J.C; SCHWALBERT, R.A.; CORASSA, G.M. **Agricultura de precisão: As zonas de manejo e o novo salto de qualidade na ap**. Revista A Granja, 816. ed. Porto Alegre: Centaurus. 2016. Disponível em:  
<<https://edcentaurus.com.br/agranja/edicao/816/materia/8087>>. Acesso em: 02 fev. 2016.
- AMARO FILHO, J.; NEGREIROS, R.F.D.; ASSIS JÚNIOR, R.N. & MOTA, J.C.A. Amostragem e variabilidade espacial de atributos físicos de um Latossolo Vermelho em Mossoró, RN. **Revista Brasileira de Ciências do Solo**, 31:415-422, 2007.
- ANGELICO, J. C. Desempenho Das Redes Neurais Artificiais Na Estimativa das Variáveis Físicas e Químicas do Solo. 2005. 160 f. Tese Doutorado em Agronomia - Faculdade de Ciências Agrônômicas da UNESP, 2005. Botucatu. Disponível em:  
<<http://hdl.handle.net/11449/101867>>. Acesso em 30 Nov 2019.
- ANJOS, L. H. C. dos; JACOMINE, P. K. T.; SANTOS, H. G. dos; OLIVEIRA, V. A. de; OLIVEIRA, J. B. Sistema Brasileiro de Classificação de Solo. In: KER, J. C; CURTI, N.; SCHAEFER, C. E. G. R.; VIDAL-TORRADO, P. (Eds). **Pedologia: Fundamentos**. ViçosaMG: Sociedade Brasileira de Ciência do Solo, p.303-343, 2012.
- ARBESTAIN, M.C. Extractability and leachability of heavy metals in Technosols prepared from mixtures of unconsolidated wastes. *Waste Management*, v. 28, n. 12, p. 2653-2666, 2008.
- ARRUDA, M.R.; MOREIRA, A.; PEREIRA, J.C.R. Amostragem e cuidados na coleta de solo para fins de fertilidade. Manaus: Embrapa Amazônia Ocidental, 2014. 18p.
- 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.; ALVES, S.M.F.; MELO, F.R. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, v.31, n.7, 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., 2012. 226p.

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*, v.5, n.1, p. 89-97, 1997.

CAMARGO, F.A.O; ALVAREZ V., V.H.; BAVEYE, P.C.; Brazilian soil science: from its inception to the future, and beyond. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 34, n. 3, p. 589-599, 2010.

CARVALHO, L.C.; SILVA, F.M.; FERRAZ, G.S.A.; STRACIERI, J.; FERRAZ, P.F.P.; AMBROSANO, L. Análise geoestatística de produção de café árabe em duas safras. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.21, n.6, p.410-414, 2017.

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

CHERUBIN, M.R.; SANTI, A.L.; EITELWEIN, M.T.; ROS, C.O.; BISOGNIN, M.B. Sampling grids used to characterise the spatial variability of pH, Ca, Mg and V% in Oxisols. **Revista Ciência Agronômica**, v. 45, n. 4, p. 659-672, 2014.

COELHO, Antônio Marcos. Comunicado Técnico 100: Eficiência de Calcário de diferentes granulometrias na correção da acidez do solo. Sete Lagoas - Mg: Embrapa, 2004

COLAÇO, A.F.; MOLIN, J. P. Amostragem Georreferenciada. Piracicaba: LAP - Laboratório de Agricultura de Precisão, 2015. Disponível em: <[http://www.agriculturadeprecisao.org.br/upimg/publicacoes/pub\\_boletim-tecnico-02---amostragem-georreferenciada-03-02-2015.pdf](http://www.agriculturadeprecisao.org.br/upimg/publicacoes/pub_boletim-tecnico-02---amostragem-georreferenciada-03-02-2015.pdf)>. Acesso em: 26 nov. 2018.

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

COSTA, J. R. da; PEDRON, F. de A.; DALMOLIN, R.S.D.; SCHENATO, R.B. Field Description and Identification of Diagnostic Qualifiers for Urban Soils in Brazil. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 43, e0180121, 2019.

DONAGEMMA, G.K.; FREITAS, P.L.; BALIEIRO, F.C.; FONTANA, A.; SPERA, S.T.; LUMBRERAS, J.F.; VIANA, J.H.M.; ARAUJO FILHO, J.C.; SANTOS, F.C.;

- ALBUQUERQUE, M. R.; MACEDO, M.C.M.; TEIXEIRA, P.C.; AMARAL, A.J.; BORTOLON, E.; BORTOLON, L. Caracterização, potencial agrícola e perspectivas de manejo de solos leves no Brasil. **Pesquisa Agropecuária Brasileira**, vol. 51, n. 9, p. 1003-1020, 2016.
- EGERIC, M.; SMIČIKLAS, I.; DOJCINOVIC, B; SIKIRIC, B.; JOVIĆ, M.; ŠLJIVIĆ-IVANOVIĆ, M.; CAKMAK, D. Interactions of acidic soil near copper mining and smelting complex and waste-derived alkaline additives. **Geoderma**, v. 352, p. 241-250, 2019.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Centro Nacional de Pesquisa em Solos. Sistema brasileiro de classificação de solos. Brasília, DF: Embrapa Produção de Informação, 2018. 590p.
- FERNANDES, M.S. Nutrição mineral de plantas. Sociedade Brasileira de Ciência do Solo. Viçosa. 2006. 432p.
- FERRAZ, G.A.S.; SILVA, F.M.; COSTA, P.A.N.; SILVA, A.C.; CARVALHO, F.M. Agricultura de precisão no estudo de atributos químicos do solo e da produtividade de lavoura cafeeira. **Revista Coffee Science**, Lavras, v.7, n.1, p.59-67, 2012.
- FERREIRA, D.F. Sisvar: um sistema computacional de análise estatística. *Ciência e Agrotecnologia*, Lavras, v.35, n.6, p.1039-1042, 2014.
- FRAZÃO, L.A.; PÍCCOLO, M.C.; FEIGL, B.J.; CERRI, C.C.; CERRI, C.E.P. Propriedades químicas de um Neossolo Quartzarênico sob diferentes sistemas de manejo no Cerrado mato-grossense. **Pesquisa Agropecuária Brasileira**, Brasília, v.43, n.5, p.641-648, 2008.
- 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.
- FULLIN, E.A. Acidez do solo e calagem. In: DADALTO, G. G.; FULLIN, E. A. Manual de Necessidade de Calagem e Adubação para o Estado do Espírito Santo. Vitória: SEEA/ INCAPER, p.70-98. 2001.
- Gazzaniga M, Ivry R, Mangun G., **Cognitive neuroscience**, 4th edn. W.W. Norton & Co, New York, 2013.
- GOOGLE. GOOGLE EARTH WEBSITE. Disponível em: <<http://earth.google.com/>>. Acesso em: 18 jul. 2018.
- HAYKIN, S. S. **Redes Neurais – Princípios e Práticas**. 2ª. ed. Porto Alegre: Bookman, 2001. 900 p.
- HOLLAND, J.E.; WHITE, P.J.; GLENDINING, M.J.; GOULDING, K.W.T.; MCGRATH, S.P. Yield responses of arable crops to liming – An evaluation of relationships between yields and soil pH from a long-term liming experimente. **European Journal of Agronomy**, v. 105, p. 176-188, 2019.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Levantamento Sistemático da Produção Agrícola, 2018. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/lspa/tabelas>> . Acesso em: 21 jan. 2018.

INSTITUTO DA POTASSA & FOSFATO. **Manual internacional de fertilidade do solo**. Tradução e adaptação: Alfredo Scheid Lopes. 2. ed. rev. ampl. Piracicaba: POTAFOS, 1998. 177p.

JIANG, Y.; LIAO, P.; GESTEL, N.V.; SUN, Y.; ZENG, Y.; HUANG, S.; ZHANG, W.; GROENIGEN, K.J.V. Lime application lowers the global warming potential of a double rice cropping system. **Geoderma**, v.325, p. 1-8, 2018.

KUNHIKRISHNAN, A.; THANGARAJAN, R.; BOLAN, N.S.; XU, Y.; MANDAL, S.; GLEESON, D.B.; SESHADRI, B.; BARTON, B.; TANG, C.; LUO, J.; DALAL, R.; DING, W.; KIRKHAM, M.B.; NAIDU, R. Chapter One - Functional Relationships of Soil Acidification, Liming, and Greenhouse Gas Flux. **Advances in Agronomy**, v. 139, p. 1-71, 2016.

GONZALEZ, R.C.; WOODS, R.E.. **Processamento Digital de Imagens**, 3.ed. Pearson, 2010.

LEAL, A.J.F.; MIGUEL, E.P.; BAIO, F.H.R.; NEVES, D.C.; LEAL, U.A.S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. *Bragantia*, Campinas, v.74, n.4, p.436-444, 2015.

LEAL, A.J.F.; MIGUEL, E.P.; BAIO, F.H.R.; NEVES, D.C.; LEAL, U.A.S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, Campinas, v.74, n.4, 2015.

LEPSCH, I.F. **Formação e Conservação do Solo**. São Paulo, Oficina de Texto, 2010. 216 p.

LI, Y.; LI, Z.; CUI, S.; ZHANG, Q. Liming effects on soil pH and crop yield depend on lime material type, application method and rate, and crop species: a global meta-analysis. **Journal of Soils and Sediments**, v. 19, n.3 p. 1393-1406, 2019.

LOPES, A. S.; GUILHERME, L. R. G. A career perspective on soil management in the Cerrado Region of Brazil. In: SPARKS, D. (ed.). **Advances in Agronomy** 137. Cambridge: Academic Press, p. 1-72, 2016.

LOPES, A. S.; GUILHERME, L. R. G.; RAMOS, S. J. The saga of the agricultural development of the brazilian Cerrado. **Electronic International Fertilizer Correspondent**, Switzerland, n. 32, p. 29-57, 2012.

LOPES, Alfredo Scheid; SILVA, Marcelo de Carvalho; GUILHERME, Luiz Roberto Guimarães. *Acidez do Solo e Calagem*. São Paulo: Anda, 1991.

MALAVOLTA, E. **ABC da adubação**. São Paulo: ed. Agronômica Ceres, 1989. 292p.

- MEDEIROS, G. de O.R.; GIAROLLA, A.; SAMPAIO, G.; MARINHO, M.A. Diagnosis of the Accelerated Soil Erosion in São Paulo State (Brazil) by the Soil Lifetime Index Methodology. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 40, e0150498, 2016.
- MINASNY, B.; McBRATNEY, A.B. Latin hypercube sampling as a tool for digital soil mapping. **Digital soil mapping: An introductory perspective**. Amsterdam, Elsevier, v. 32, n. 9, p.153-165, 2006.
- MOLIN, J.P.; AMARAL, L.R.; COLAÇO, A.F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de textos. 2015. 238p.
- MONDO, V. H. V. et al. Spatial variability of soil fertility and its relationship with seed physiological potential in a soybean production area. **Revista Brasileira de Sementes**, Londrina, v. 34, n. 2, p. 193- 201, 2012.
- NAWARATHNA, T.H., NAKASHIMA, K., FUJITA, M., TAKATSU, M. AND KAWASAKI, S. Effects of Cationic Polypeptide on CaCO<sub>3</sub> Crystallization and Sand Solidification by Microbial-Induced Carbonate Precipitation. **ACS Sus. Chem. Eng.**, v. 6, n.8, p.10315-10322, 2018.
- NOLLA, Antonio; ANGHINONI, Ibanor. Métodos utilizados para a correção da acidez do solo no Brasil. **Revista Ciências Exatas e Naturais**, Paraná, v. 6, n. 1, p.97-111, jan. 2004.
- PEIXOTO, A.L.; LUZ, J.R.P.; BRITO, M.A. **Conhecendo a Biodiversidade**. Brasília, CNPq: Ministério da Ciência, Tecnologia, Inovações e Comunicações, 2016. 195 p.
- PEREIRA, G.H.A.; CENTENO, J.A.S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e laser scanner. **Boletim de Ciências Geodésicas**, Curitiba, v. 23, n.2, p.268 - 283, 2017.
- PRIMAVESI, O.; PRIMAVESI, A.C.; CÔRREA, L.A. Calagem em pastagem de *Brachiaria decumbens* recuperada com adubação nitrogenada em cobertura. São Carlos: Embrapa, 2004. 32p.
- R Core Team. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2015. Disponível em: <<https://www.R-project.org/>>.
- RAHMAN, K.A.; OTHMAN, R. Influence of pH levels on disease development in oil palm seedling roots infected with *Ganoderma boninensis*. **Rhizosphere**, v.13, n.1, 2020.
- RAIJ, B.V. **Fertilidade do solo e manejo de nutrientes**. Piracicaba, IPNI, 2011, 420 p.
- REATTO, A.; CORREIA, J.R.; SPERA, S.T. Solos do Bioma Cerrado: aspectos pedológicos. In: SANO, S.M.; ALMEIDA, S.P. (Ed.). **Cerrado: ambiente e flora**. Planaltina: Embrapa-CPAC, 1998. p.47-87.

- RESCK, D.V.S.; VASCONCELLOS, C.A.; VILELA, L.; MACEDO, M.C.M. Impact of conversion of Brazilian cerrados to cropland and pastureland on soil carbon pool and dynamics. In: LAL, R.; KIMBLE, J.M.; STEWART, B.A. (Ed.). **Global climate change and tropical ecosystems**. Boca Raton: CRC Press, 1999. p.169-196.
- RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ, V.H. (ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**, 5ª aproximação. Viçosa, MG: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999. 359p.
- 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. 107P. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás. Anápolis, 2019.
- RUSSELL, S.; NORVIG, P. **Inteligência artificial**. 3a ed. CAMPUS, 2010.
- SANTIAGO, Antonio Dias; ROSSETTO, Raffaella. **Calagem**. Disponível em: <[https://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01\\_34\\_711200516717.html](https://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_34_711200516717.html)>. Acesso em: 15 ago. 2019.
- SANTOS RD, LEMOS RC, SANTOS HG, KER JC, ANJOS LHC, SHIMIZU SH. **Manual de descrição e coleta de solo no campo**. 7. ed. rev. ampl. Viçosa, MG: Sociedade Brasileira de Ciência do Solo; 2015.
- SANTOS, H. G. et al. **Sistema brasileiro de Classificação de Solos**. 5. ed. Brasília: Embrapa, 2018. 590 p.
- SCHIAVO, M. LO; PRINARI, B.; GRONSKI, J. A.; SERIO, A. V. An artificial neural network approach for modeling the ward atmosphere in a medical unit. **Mathematics and Computers in Simulation**, v. 116, p. 44–58. 2015.
- SCHNEIDER, P.R. **Análise de regressão aplicada à Engenharia Florestal**. Santa Maria: ed. UFSM/CEPEF, 1998. 236p.
- SEIDEL, E.J.; OLIVEIRA, M.S. Novo índice geoestatístico para a mensuração da dependência espacial. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 38, n. 3, p. 699-705, 2014.
- 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.
- SHOEMAKER, H.E.; Mc LEAN E.O.; PRATT, P.F. Buffer methods for determining lime requirement of soil with appreciable amounts of extractable aluminium. **Soil Science Society of America Proceedings**, Madison, v.25, p.274-277, 1961.
- SILVA NETO, W.A. Relação de longo prazo entre os preços do tomate nos estados de São Paulo. *Informações Econômicas*, São Paulo, v.44, n.2, p.17-21, 2014.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. Cap. 1, 393 p.

- 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, J.; GUEDES, I.M.R.; LIMA, C.E.P. Calagem para cultura do tomate. Disponível em: <<http://www.agencia.cnptia.embrapa.br/gestor/tomate/arvore/CONT000gn0jymr102wx5ok0liq1mqkfb2l9d.html>>. Acesso em: 27 out. 2018.
- SILVA, S.H.M.G.; LEON, A.C.P.; CARVALHO, F.; ROMERO, R.A.F.; CRUVINEL, P.E.; NATALE, W. Redes neurais artificiais e agricultura de precisão para recomendação de adubação da cultura da goiabeira. **Revista Brasileira de Agrocomputação**, Ponta Grossa, v.2 n.1, p.37-42, 2004.
- 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, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L.; VIVAN, G.A. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.293-300, 2014.
- SOBRINHO, T.A.; RODRIGUES, D. B. B.; OLIVEIRA, P. T. S.; REBUCCI, L. C. S.; PERTUSSATTI, C.A.. Estimativa de evapotranspiração de referência através de redes neurais artificiais. **Revista Brasileira de Meteorologia**, Campo Grande. V. 6, n. 2, p. 197 – 203, 2011.
- SOUSA, D.M.G.; LOBATO, E.; REIN, T.A. Uso de gesso agrícola nos solos do cerrado. EMBRAPA-CPAC. Planaltina, 2005. 103p.
- SOUZA, Z. M.; SOUZA, G. S.; JÚNIOR, J. M.; 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.
- VILELA, Nirlene Junqueira. Estatísticas: Tomate. Disponível em: <<http://www.agencia.cnptia.embrapa.br/gestor/tomate/arvore/CONT000fa2qor2u02wx5eo01xezlsfsc150.html>>. Acesso em: 19 ago. 2019.
- WILLMONT, C.J. **On the validation of models**. *Physical Geography*, Palm Beach, v.2, n. 2, p.184-194, 1981.
- YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. 1. ed. São Paulo: Ed. Oficina de Textos, 2013. 215p.
- ZARIFNESHAT, S.; ROHANI, A.; GHASSEMZADEH, H.R.; SADEGHI, M.; AHMADI, E.; ZARIFNESHAT, M. Predictions of apple bruise volume using artificial neural network. *Computers and Electronics in Agriculture*, Mashhad, v.82, n.6, p.75–86. 2012.