

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE ENGENHARIA  
CÂMPUS DE ILHA SOLTEIRA**

**JOSÉ GUILHERME MARQUES CHITERO**

**QUALIDADE FÍSICA DE UM SOLO DEGRADADO EM RECUPERAÇÃO VIA  
REDES NEURAS ARTIFICIAIS**

**PHYSICAL QUALITY OF A SOIL DEGRADED IN RECOVERY VIA  
ARTIFICIAL NEURAL NETWORKS**

Ilha Solteira – SP

Março – 2020

**PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**  
**“SISTEMAS DE PRODUÇÃO”**

**JOSÉ GUILHERME MARQUES CHITERO**

**QUALIDADE FÍSICA DE UM SOLO DEGRADADO EM**  
**RECUPERAÇÃO VIA REDES NEURAIAS ARTIFICIAIS**

**PHYSICAL QUALITY OF A SOIL DEGRADED IN RECOVERY**  
**VIA ARTIFICIAL NEURAL NETWORKS**

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Mestre em Agronomia.

Dra. Carolina dos Santos Batista Bonini  
**Orientadora**

Dr. Alfredo Bonini Neto  
**Coorientador**

Ilha Solteira – SP

Março – 2020

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C543q Chitero, José Guilherme Marques.  
Qualidade física de um solo degradado em recuperação via redes neurais artificiais / José Guilherme Marques Chitero. -- Ilha Solteira: [s.n.], 2020  
62 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Sistemas de Produção, 2020

Orientador: Carolina dos Santos Batista Bonini

Coorientador: Alfredo Bonini Neto

Inclui bibliografia

1. Solos. 2. Redes neurais. 3. Área degradada.

  
Raiane da Silva Santos



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA DISSERTAÇÃO: QUALIDADE FÍSICA DE UM SOLO DEGRADADO EM RECUPERAÇÃO  
VIA REDES NEURAIS ARTIFICIAIS

**AUTOR: JOSÉ GUILHERME MARQUES CHITERO**

**ORIENTADORA: CAROLINA DOS SANTOS BATISTA BONINI**

**COORIENTADOR: ALFREDO BONINI NETO**

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA, área:  
Sistemas de Produção pela Comissão Examinadora:

Profa. Dra. CAROLINA DOS SANTOS BATISTA BONINI  
Curso de Engenharia Agrônoma / Faculdade de Ciências Agrárias e Tecnológicas de Dracena –  
UNESP

*Carolina dos Santos Batista Bonini*

Prof. Dr. VITOR CORRÊA DE MATTOS BARRETTO  
Departamento de Agronomia / Faculdade de Ciências Agrárias e Tecnológicas de Dracena – UNESP

Prof. Dr. JOÃO OSVALDO RODRIGUES NUNES  
Departamento de Geografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - UNESP

*João Osvaldo Rodrigues Nunes*

Ilha Solteira, 23 de março de 2020

“O segredo da vida é o solo, porque do solo dependem as plantas, a água, o clima e nossa vida. Tudo está interligado. Não existe ser humano sadio se o solo não for sadio”

- Ana Maria Primavesi

Dedico esta dissertação a educação pública de qualidade, ao SUS, a todos que quiserem ler e adquirir conhecimento a partir desta; a minha atual companheira a quem amo, que sem ela não poderia estar realizando esse mestrado: Talita Silveira Amador, e à pessoa mais importante da minha vida: Eu mesmo.

Deixo eternos agradecimentos para meus orientadores: Carolina e Alfredo Bonini.

**RESUMO:** Os solos sob um manejo inadequado, têm suas qualidades físicas, químicas e biológicas afetadas negativamente, dando origem a sua degradação. No estado de São Paulo, grande parte das pastagens estão degradadas e/ou em degradação. Entender como funciona um solo degradado e sua resiliência e iniciar seu processo de restauração, são fundamentais para desenvolver técnicas de manejo adequado do solo. Inúmeras técnicas estão sendo utilizadas para recuperação de solo degradado, descobrir e detalhar os índices físicos do solo ajuda em como proceder, e com qual técnica de recuperação utilizar; visando isso, este projeto teve por objetivo desenvolver um programa interativo (analisar e classificar) com a utilização das redes neurais artificiais (RNA) para estimar os níveis de recuperação do solo (recuperado (R), parcialmente recuperado (PR) e não recuperado (NR) em função dos atributos físicos e comparar com os dados obtidos via estatística convencional. O experimento foi realizado na Agência Paulista de Tecnologias dos Agronegócios – APTA do Extremo Oeste, no município de Andradina/SP no período de 2015 a 2017, em solo classificado como Argissolo Vermelho Amarelo cultivado com pastagem de *Urochloa*, com diferentes formas de introdução de Estilosantes cv. Campo Grande (*Stylosanthes capitata* e *S. macrocephala*). Os atributos do solo estudados foram: densidade do solo, porosidade do solo (macroporosidade e microporosidade), resistência mecânica a penetração, infiltração de água no solo e diâmetro médio ponderado, nas camadas do solo: 0-10; 0,10-0,20 e 0,20-0,40 m. Os dados foram avaliados pela estatística convencional (teste de Tukey a 5% de probabilidade) e via redes neurais artificiais. O programa foi desenvolvido no ambiente MATLAB e a simulação foi realizada por meio de uma interface gráfica. A RNA que foi utilizada neste trabalho é a Perceptron multicamadas (MLP), composta por três camadas, de entrada, intermediária e a de saída, com algoritmo de treinamento retropropagação (treinamento supervisionado). A camada de entrada é composta por 6 neurônios (atributos físicos) e a camada de saída por 1 neurônio, o qual tem a função de informar a classificação quanto a recuperação física do solo (R, PR e NR). Dos resultados obtidos pela RNA, verificou-se que a rede alcançou um treinamento adequado, com erro quadrado médio (mean square error) baixo, podendo gerar uma alternativa interessante e automática para a classificação e análise de solos em recuperação. Os resultados foram imprimidos em uma interface gráfica autoexplicativa, com gráficos e metadados dos índices físicos e suas classificações quanto à RNA.

**Palavras-chave:** qualidade física do solo, inteligência artificial, atributos físicos, RNA

**ABSTRACT:** Soils under inadequate management have their physical, chemical and biological qualities negatively affected, giving rise to their degradation. In the state of São Paulo, most of the pastures are degraded and / or in degradation. Understanding how a degraded soil and its resilience works and starting its restoration process are essential to develop proper soil management techniques. Countless techniques are being used to recover degraded soil, discovering and detailing the physical indexes of the soil helps in how to proceed, and with which recovery technique to use; with this in mind, this project has developed an interactive program (analyze and classify) using artificial neural networks (ANN) to estimate soil recovery levels (recovered (R), partially recovered (PR) and not recovered ( NR) as a function of physical attributes and compare with data obtained using conventional statistics. The experiment was carried out at the São Paulo Agribusiness Technologies Agency - APTA in the Far West, in the city of Andradina / SP from 2015 to 2017, on classified soil as Red Yellow Argisol cultivated on *Urochloa decumbens* pasture in recovery since 2012, with different ways of introducing Estilantes cv. Campo Grande (*Stylosanthes capitata* and *S. macrocephala*). The studied soil attributes are: soil density, soil porosity (macroporosity and microporosity), mechanical resistance to penetration, water infiltration in the soil and weighted average diameter, in soil layers: 0-10; 0.10-0.20 and 0.20-0.40 m. The was evaluated by conventional statistics (Tukey's test at 5% probability) and via artificial neural networks. The program was developed in the MATLAB environment and the simulation was performed through a graphical interface. The ANN that was used in this work is the multilayer Perceptron (MLP), composed of three layers, of input, intermediate and output, with backpropagation training algorithm (supervised training). The input layer is composed by 6 neurons (physical attributes) and the output layer by 1 neuron, which has the function of informing the classification regarding the physical recovery of the soil (R, PR and NR). From the results obtained by RNA, it was found that the network achieved adequate training, with a low mean square error, which could generate an interesting and automatic alternative for the classification and analysis of recovering soils. The results were printed on a self-explanatory graphical interface, with graphs and metadata of the physical indexes and their classifications regarding ANN.

**Keywords:** Soil quality, computational technology, physical indexes, ANN

## SUMÁRIO

1. INTRODUÇÃO .....	13
2. REVISÃO BIBLIOGRÁFICA.....	14
2.1 Solos.....	14
2.2 Redes neurais artificiais .....	15
3. OBJETIVO.....	18
4. MATERIAL E MÉTODOS .....	18
4.1 Localização, características da área experimental e tratamentos utilizados .	18
4.2 Atributos do solo estudados .....	19
4.3 Densidade do solo e porosidade do solo .....	19
4.4 Resistência mecânica a penetração .....	19
4.5 Infiltração de água.....	19
4.6 Estabilidade de agregados.....	20
4.7 Interface gráfica .....	20
4.8 Análise dos dados .....	21
4.8.1 Análise estatística.....	21
4.8.2 Análise via RNA .....	21
5. RESULTADOS E DISCUSSÃO .....	24
5.1 Análise estatística .....	24
5.2 Porosidade do solo e densidade do solo.....	27
5.3 Infiltração de água no solo.....	33
5.4 Resistência mecânica a penetração e teor de água no solo .....	35
5.5 Treinamento da Rede Neural Artificial .....	44
5.5.1 Operação (Diagnóstico) da Rede Neural Artificial .....	49
6. CONCLUSÕES.....	54
REFERÊNCIAS .....	55
ANEXO .....	60

## LISTA DE FIGURAS

<b>Figura 1</b> - Exemplo dos comandos e da criação de um botão.	21
<b>Figura 2</b> - Rede neural: (a) Neurônio biológico, (b) Neurônio artificial.	22
<b>Figura 3</b> - RNA utilizada neste trabalho.	23
<b>Figura 4</b> - Valores médios em porcentagem de macroporosidade, microporosidade, porosidade total e densidade do solo ( $\text{g dm}^{-3}$ ), na camada de 0,00-0,10 m, nos anos de 2015 a 2017. Andradina – SP.	33
<b>Figura 5</b> - Valores médios de resistência a penetração de raízes (A) ano de 2015, (B) ano de 2016 e (C) ano de 2017.	38
<b>Figura 6</b> - Tela inicial do programa.	40
<b>Figura 7</b> - Tela para inserção dos dados.	40
<b>Figura 8</b> - Tela para inserção dos dados com a visualização das dimensões das matrizes de entrada (física do solo) e saída dos dados. Saída desejada de acordo com Tabela 1.	40
<b>Figura 9</b> - Tela para visualização dos dados no Command Window do Matlab tanto da matriz de entrada como da matriz de saída desejada.	41
<b>Figura 10</b> - Tela para escolha do número de camadas intermediárias.	42
<b>Figura 11</b> - Tela para escolha do número de neurônios na camada intermediária.	42
<b>Figura 12</b> - Tela para escolha do número de neurônios nas 2 camadas intermediárias.	42
<b>Figura 13</b> - Tela para definir as funções de pertinência, algoritmos de aprendizado e especificar os parâmetros para o treinamento da RNA.	43
<b>Figura 14</b> - Tela com a inserção do botão “Simular” para operação (diagnóstico) da RNA.	44
<b>Figura 15</b> – Tela com a inserção do botão “Gráfico de superfície” para plotagem do gráfico dos diversos treinamentos da RNA.	44
<b>Figura 16</b> - Processo de treinamento da rede para 90 amostras dos atributos físicos do solo, (a) Saída obtida versus Saída desejada, (b) Performance do treinamento da rede neural artificial (MSE).	46
<b>Figura 17</b> – Análise de regressão entre as variáveis de saída desejada ( $Y_{des}$ ) e saída obtida ( $Y_{ob}$ ).	47
<b>Figura 18</b> - Processo de dez treinamentos da rede para as 90 amostras referentes aos atributos físicos do solo, (a) saída obtida (10 treinamentos) versus Saída desejada, (b) gráfico de superfície para os dez treinamentos.	48

<b>Figura 19</b> - Tela de inserção dos dados para operação ou diagnóstico da RNA.	50
<b>Figura 20</b> - Tela para visualização dos dados para fase de operação no Command Window do Matlab.	50
<b>Figura 21</b> - Resultados da classificação física do solo pela RNA em relação as profundidades e tratamentos.	51
<b>Figura 22</b> - Tela de inserção dos dados para operação ou diagnóstico da RNA com o botão “Gráfico de superfície”.	52
<b>Figura 23</b> - Resultados da classificação física do solo pela RNA, (a) gráfico de superfície visto de cima para cada tratamento e profundidade analisada, (b) gráfico de superfície, vista lateral.	53
<b>Figura 24</b> - Tela para inserção de dados de saída desejada para comparação com a saída obtida na fase de operação ou diagnóstico da RNA.	53

## LISTA DE TABELAS

<b>Tabela 1</b> - Classes dos atributos físicos do solo.	22
<b>Tabela 2</b> - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina - SP. 2015.	25
<b>Tabela 3</b> - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina – SP. 2016.	26
<b>Tabela 4</b> - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina – SP. 2017.	27
<b>Tabela 5</b> - Valores médios do índice de macroporosidade (MA) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.	28
<b>Tabela 6</b> - Valores médios do índice de microporosidade (MI) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.	29
<b>Tabela 7</b> - Valores médios do índice de porosidade total (PT) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.	30
<b>Tabela 8</b> - Valores médios do índice de densidade do solo (DS) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.	31
<b>Tabela 9</b> - Taxa constante de infiltração de água em função dos tratamentos.	34
<b>Tabela 10</b> - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2015.	35
<b>Tabela 11</b> - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2016.	36
<b>Tabela 12</b> - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2017.	37
<b>Tabela 13</b> - Valores especificados para o treinamento da rede.	48
<b>Tabela 14</b> - Resultados para os dez treinamentos da rede.	49

## 1. INTRODUÇÃO

Agronomia, entre muitas coisas, é a ciência que desenvolve manejo para uso e ocupação do nosso solo, conservando os recursos naturais não renováveis quando usados na geração de alimentos. Desenvolver pesquisa na área agrária requer tempo e tecnologia, em cima disso, o presente trabalho se propôs a utilizar Redes Neurais Artificiais que são uma ferramenta tecnológica da ciência de dados, para economizar tempo ao analisar centenas de dados, e reforçar o uso de novas tecnologias para a ciência agrária. Foram coletadas amostras de solo em uma área com solo degradado, dessas amostras foram analisadas seis atributos físicos, sendo eles: densidade do solo, porosidade do solo (macro e microporosidade), resistência a penetração do solo, infiltração de água e diâmetro dos agregados. Após feita as análises físicas em laboratório, se usou da estatística convencional para avaliar suas médias, procurando identificar qual tratamento surtiu mais efeito no objetivo de recuperar a área degradada; ficou mostrado durante a comparação de médias que houve pouca alteração nas características da física do solo na área experimental, evidenciando as eficácias ou ineficácias dos tratamentos no tempo em que a área esteve sob os efeitos deles. Procurando uma análise complementar para essas análises do solo, foi projetada uma interface gráfica no *software* MATLAB da *Mathworks*, com algoritmos e *scrpts* de programação capazes de gerar uma Rede Neural Artificial. Essa RNA foi elaborada com uma camada de entrada onde recebeu os atributos físicos do solo, uma camada intermediária e uma camada de saída, onde sua saída desejada foi embasada sua classificação no nível de recuperação do solo, baseada na literatura agrônômica. A funcionalidade do *software* foi eficaz e prática, sendo explicado cada etapa construtiva da rede durante a seção de resultados e discussão; a rede foi treinada, supervisionada, diagnosticada/simulada para obter os resultados de cada tratamento para cada amostra do solo.

## 2. REVISÃO BIBLIOGRÁFICA

### 2.1 Solos

A utilização dos recursos naturais de forma inadequada geralmente dá lugar a um sistema ecológico não sustentável. Com isso, solos utilizados intensamente e de forma inadequada, são levados à degradação (BONINI et al., 2015). A definição de degradação do solo está associada à própria definição de qualidade do solo, ou seja, à medida que as características determinantes da qualidade de um solo são alteradas negativamente, estabelece-se um processo de degradação (ALVES & SOUZA, 2008). Doran e Parkin (1994) definem que a qualidade do solo, como sendo a capacidade em manter a produtividade biológica, a qualidade ambiental e a vida vegetal e animal saudável na face da terra.

A recuperação de áreas degradadas pode ser definida como um processo de reversão dessas áreas em solos produtivos e autossustentáveis, de acordo com uma proposta preestabelecida de uso do solo (IBAMA, 1990); sendo também, um processo em constante aprimoramento que exige conhecimento, tecnologia e permanente monitoramento. Trata-se de criar condições para o restabelecimento de complexas redes de relações ecológicas entre solo, plantas, animais e microclima, que permitam o reequilíbrio dinâmico da natureza em áreas hoje desprovidas dessas condições (REIS; ZAMBONIM; NAKAZONO, 1999).

O uso de forrageiras mais rústicas, como as do gênero *Urochloa*, têm amenizado o problema da degradação, mas com o tempo, nem mesmo estas forrageiras têm conseguido bom desenvolvimento nesses solos. (Bonini et al., 2017)

A adoção de sistemas de manejo do solo considerados conservacionistas, como o plantio direto, tem se apresentado como alternativa viável para assegurar a sustentabilidade do uso agrícola do solo, principalmente nos Latossolos (SILVA et al., 2000). No Brasil, a área com plantio direto teve incremento de 84% entre os anos de 2006 e 2017 passando de 17,9 milhões de hectares para 32,9 milhões de hectares (SAUERESSIG, 2019). Este sistema é constituído pelos seguintes componentes: culturas de cobertura, formação de palhada, rotação de culturas e não mobilização do solo (RIBEIRO et al., 2001). Assim, o requisito principal para a implantação do sistema é a formação de palha sob o solo, embora tal formação e a manutenção da cobertura morta em regiões tropicais têm tido impedimentos para o seu estabelecimento pleno, principalmente no Cerrado. Isso devido às altas temperaturas e umidade da região, que proporcionam a rápida decomposição dos resíduos vegetais (KLUTHCOUSKI, 1998).

A escolha das espécies a serem empregadas na recuperação de áreas degradadas é fundamental para a obtenção de resultados positivos. Em fases iniciais de restauração, o objetivo prioritário é a reabilitação da função e dos serviços do ecossistema. Isso significa que, muitas vezes, torna-se impossível reabilitar a estrutura original de um ecossistema em um primeiro momento, sendo urgente a amenização dos agentes impactantes, por meio da cobertura imediata do solo (ROVEDDER & ELTZ, 2008).

O entendimento do comportamento físico de um solo, é de extrema importância, pois orienta as devidas atividades que devem ser executadas no sistema, para que desta forma alcance um adequado desenvolvimento das culturas. Este diagnóstico envolve a composição textural, o arranjo das partículas e poros, densidade de sólidos do solo, sua estrutura de agregação, resistência mecânica à penetração, infiltração de água no solo e disponibilidade de água às plantas (KLEIN, 2014).

De acordo com Guerra e Cunha (2003) os processos naturais, como a formação dos solos, lixiviação, erosão, deslizamentos, modificação do regime hidrológico e da cobertura vegetal, entre outros, ocorrem nos ambientes naturais, mesmo sem a intervenção humana. No entanto, quando o ser humano desmata, planta, constrói; ele acaba alterando o ambiente, nesse caso, esses processos naturais tendem a ocorrer com maior intensidade, e nesse caso as consequências para a sociedade são quase sempre desastrosas.

Tendo em vista a necessidade de um estudo aprimorado nos mais distintos indicadores de qualidade de um solo, estando, ou não, degradado; novas tecnologias e ferramentas computacionais estão surgindo para otimizar os diagnósticos, e encontrar, assim, possíveis soluções para os mais variados problemas encontrados na qualidade do solo.

## ***2.2 Redes neurais artificiais***

As redes neurais artificiais (RNAs) são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes que adquirem conhecimento através da experiência (BRAGA et al., 2000). Assim, a RNA é capaz de reconhecer padrões, ou seja, possui a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, o que torna a sua aplicação bastante eficiente na análise espacial (SOARES et al., 2015). Neste sentido, RNAs mimetizam neurônios biológicos absorvendo o dado, transformando em informação e armazenando em conhecimento, e assim torná-lo em uso.

A capacidade de aprender através de dados fornecidos pelo usuário e de processar esses dados em informação aprendida, é o atrativo principal da solução de problemas das

RNAs. A generalização desses dados, que está associada à capacidade da rede aprender por meio de um conjunto reduzido de exemplos e, posteriormente, proporcionar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícitas através de exemplos. Uma RNA produz saídas adequadas para entradas que não estavam presentes durante o seu treinamento, imitando, desta forma, a capacidade humana de aprender e generalizar fatos (padrões) (ELIASMITH e ANDERSON, 2003; KOVACS, 2006).

Segundo Haykin (2001) a utilização de um RNA na solução de uma tarefa passa, antes de tudo, por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação apresentados para ela, criando assim uma representação própria para o problema. Ainda segundo o mesmo autor, a etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Muitos estudos tem sido reportados sobre a aplicação das RNAs na agricultura (BALA et al., 2005; DIAMANTOPOULOU, 2005; MOVAGHARNEJAD e NIKZAD, 2007; ZHANG et al., 2007), sendo muitos destes estudos dedicados a predições (JIANG et al., 2004; UNO et al., 2005; SAVIN et al., 2007; BONINI et al. 2017; DE SOUZA et al. 2019). No Brasil, alguns trabalhos têm sido desenvolvidos utilizando RNA na aplicação em ciência do solo. Neste sentido, Bucene e Rodrigues (2004) desenvolveu um trabalho com o intuito de classificar a fertilidade química do solo via RNA, os autores avaliaram os atributos químicos do solo, como pH, capacidade de troca catiônica, saturação de base, fósforo, magnésio e potássio. A RNA foi uma ferramenta muito promissora na diferenciação do solo para fins de irrigação. Dos resultados obtidos a situação ótima da rede obteve 78% dos resultados iguais aos desejados, com duas camadas de neurônios, uma das quais intermediária, com 5 neurônios, e uma camada de saída.

De acordo com Bonini Neto et al. (2017), estudos iniciais foram desenvolvidos neste contexto. Foi proposto o desenvolvimento de uma RNA com o objetivo de analisar dados de solos em recuperação de forma que se possa classificá-los automaticamente em função de seus atributos físicos. Pode-se concluir que a partir de seu treinamento, e com todos os pesos ajustados e validados, a RNA construída poderá atuar como um classificador de dados. Em especial, a rede será capaz de fazer previsões/inferências a partir dos atributos do solo, permitindo a identificação de seus níveis de recuperação (solo

não recuperado, solo parcialmente recuperado e solo recuperado). Em De Souza et al. 2019 foi proposto uma RNA para estimar os dias da colheita dos cachos da banana em função dos dados meteorológicos. O erro médio na fase de operação da rede foi em torno de 0,0596, ou seja, 6% de erro em comparação da saída obtida em relação à saída desejada.

Proto (2009), propôs o desenvolvimento de uma interface gráfica voltada para a resolução do problema de planejamento da expansão das linhas de transmissão. A grande dificuldade encontrada por usuários ao interagir com estes programas, motivou o surgimento de uma aplicação com interface gráfica. Góes et al., (2015), desenvolve uma interface gráfica capaz de otimizar a utilização de métodos numéricos. A ideia consistiu na utilização de um grupo de painéis, sendo que, cada painel abriga a interface de um determinado método.

Não apenas nessa área, mas em muitas outras a interface gráfica tem demonstrado seu poder de aplicação.

Gabriel Filho et al., (2011) desenvolveu um *software* utilizando a lógica *fuzzy* para a comparação da massa corporal de bovinos entre si e identificação dos grupos para abate, e dos que necessitam de alimentação mais intensa, utilizando-se das variáveis “massa” e “altura”, e a saída *IMCFuzzy*.

Vários outros trabalhos envolvendo interface gráfica foram desenvolvidos nos últimos anos. (TEIXEIRA, 2011; LEAL NETO, 2007; GASPARINI, 2012; SILVA et al., 2010; BONINI NETO et al., 2012).

O desenvolvimento de uma interface gráfica interativa via RNA para estimar os índices de recuperação do solo (recuperado - R, parcialmente recuperado - PR e não recuperado - NR) em função dos atributos físicos e tratamentos, sendo os atributos físicos como dados de entrada da rede e como saída os índices (indicadores) da recuperação do solo; proporcionará não só um ambiente mais amigável para o usuário, mas também um pacote que auxilia e facilita o aprendizado para pesquisadores e os estudantes de graduação e de pós-graduação em engenharia, neste caso relacionados com a análise de solos degradados.

### 3. OBJETIVO

#### Objetivo geral:

O objetivo deste projeto foi analisar os parâmetros físicos de um solo degradado em recuperação utilizando as Redes Neurais Artificiais baseado nas saídas da rede (R, PR e NR) e discutir esses dados juntamente com os resultados obtidos pela estatística convencional.

#### Objetivos específicos:

- Desenvolver um programa interativo no *software* MATLAB (analisar e classificar) os dados de física do solo conforme dados de entrada e saída, utilizando das redes neurais artificiais (RNA) em análise dos atributos físicos de solo;
- Gerar uma classificação do nível de degradação do solo para cada tratamento.

### 4. MATERIAL E MÉTODOS

#### ***4.1 Localização, características da área experimental e tratamentos utilizados***

O experimento da coleta das análises do solo foi desenvolvido na área experimental do Polo Regional de Desenvolvimento Tecnológico dos Agronegócios do Extremo Oeste, sediado no município de Andradina-SP, localizado na região noroeste do Estado de São Paulo à 379 metros de altitude, latitude 20°55'S e longitude 51°23'W. O clima, segundo a classificação Köpen é tropical quente e úmido com inverno seco. A precipitação média anual é de 1.129,4 mm e a temperatura média anual é de 23°C. O solo do local foi classificado como Argissolo Vermelho Amarelo (SANTOS et al., 2018). A área que foi utilizada para o experimento é o pasto mais antigo da Estação Experimental, a gramínea (capim *Urochloa*) apresenta baixa capacidade de rebrota após o pastejo e algumas manchas de infestação de *Paspalum notatum* (grama mato grosso).

O experimento foi instalado em uma área de 3.500 m<sup>2</sup> numa pastagem de *Urochloa decumbens* estabelecida há cerca de doze anos, na qual se encontrou com baixa produção, mas sem grandes infestações de plantas invasoras, compactação do solo e trilhos formados pelos animais, onde foi plantada a leguminosa Estilosantes Campo Grande (*Stylosanthes capitata* (80%) e *S. macrocephala* (20%)). O experimento foi avaliado por um período de 40 meses a partir de setembro de 2015.

No experimento, o delineamento experimental foi em blocos ao acaso, com quatro repetições e compostos por sete estratégias em plantio direto da leguminosa na pastagem:

T1- Testemunha Capim *Urochloa* (TC);

T2- *Urochloa* + estilosantes com dessecação parcial com 1,5 L ha<sup>-1</sup> de glifosato (DP);

T3- *Urochloa* + estilosantes com dessecação total com 3,0 L ha<sup>-1</sup> de glifosato (DT);

T4- *Urochloa* + estilosantes com plantio direto (PD);

T5- *Urochloa* + estilosantes com escarificação do solo (E),

T6- *Urochloa* + estilosantes com gradagem rome (G) e

T7- *Urochloa* + estilosantes com aração + gradagem (AG).

Nos tratamentos com G e AG a semeadura foi realizada a lanço e os demais na forma de semeadura direta.

#### **4.2 Atributos do solo estudados**

As amostras foram coletadas no período de outubro/ novembro nos anos de 2015, 2016 e 2017. Tanto as coletas de amostras deformadas de solo para a análise física, quanto as coletas com os anéis volumétricos (amostras indeformadas) para avaliação da densidade do solo e porosidade do solo, foram realizadas concomitantemente para as seguintes camadas: 0-0,10; 0,10-0,20 e 0,20-0,40 m. Foram coletadas 252 amostras, 84 para cada camada, 12 para cada tratamento.

Foram determinados os atributos do solo, descritas a seguir:

#### **4.3 Densidade do solo e porosidade do solo**

A Densidade do solo foi determinada pelo método do anel volumétrico descrita por TEIXEIRA et al. (2017).

A porosidade total foi determinada pelo processo de saturação do solo (volume de poros totais do solo ocupado pela água), a microporosidade pelo método da mesa de tensão com coluna de água de 6 kPa e a macroporosidade foram calculadas por diferença entre a porosidade total e a microporosidade, segundo TEIXEIRA et al. (2017).

#### **4.4 Resistência mecânica a penetração**

Para a resistência do solo à penetração foi utilizado um penetrológ, modelo Falker, Automação Agrícola;

#### **4.5 Infiltração de água**

A taxa de infiltração de água foi determinada usando o mini infiltrômetro de disco (ZHANG, 1997).

#### 4.6 Estabilidade de agregados

A distribuição e estabilidade de agregados em água; representado pelo diâmetro médio ponderado dos agregados (DMP) foi determinado pelo método de Angers & Mehuys (2000);

#### 4.7 Interface gráfica

A plataforma utilizada para a criação da interface gráfica, implementação computacional da RNA, bem como para a obtenção dos resultados, foi o MATLAB (MATHWORKS, 2018). Esta ferramenta permite o desenvolvimento de programas em uma linguagem de fácil assimilação, com um bom desempenho computacional num ambiente mais amigável para o usuário. Os benefícios do uso do MATLAB no ambiente universitário têm se comprovado não só pelo grande número de livros textos que passaram a incorporar exercícios e problemas baseado neste pacote, mas também pelo grande número de artigos relacionados.


Entre as principais vantagens deste software estão:

- A linguagem comercial de alto nível e amplamente difundida nos cursos de engenharia;
- A vasta seleção de *Toolboxes*: *fuzzy logic*, *neural network*, *financial* entre outros;
- Possui recursos para o desenvolvimento de interfaces gráficas portáteis e poderosas;
- O ambiente de visualização dos resultados e programação simples.

A interface gráfica foi implementada aplicando a função *figure* e suas propriedades (*Color*, *Units*, *MenuBar*, *NumberTitle*, *Position*, *Resize* e *Name*). Também foi utilizado o comando de controle *Uicontrol* e suas propriedades: *Units*, *Position*, *String*, *Style*, *Enable*, *Callback*, *Visible*, *BackgroundColor*, *ForegroundColor* e *HorizontalAlignment* (MATHWORKS, 2018). Os parâmetros e a Figura 1 a seguir apresentam um exemplo da função e o comando *Uicontrol* para criação de um botão.

```
h1 = uicontrol('Parent',h0, ...  
             'Units','normalized', ...  
             'BackgroundColor',Cores.color01, ...  
             'Position',[0.4 0.22 0.2 0.1], ...  
             'String','Botão', ...  
             'FontSize',14,...  
             'Callback','clc ,teste2',...  
             'Tag','edit1');
```

**Figura 1** - Exemplo dos comandos e da criação de um botão.



**Fonte:** Dados do próprio autor.

## **4.8 Análise dos dados**

### *4.8.1 Análise estatística*

Os dados foram analisados efetuando-se a análise de variância, teste de Tukey a 5 % de probabilidade para a comparação de médias.

### *4.8.2 Análise via RNA*

Após coletadas e analisadas, os dados das amostras foram inseridas na RNA com 6 variáveis de entrada, representadas pela densidade do solo, porosidade do solo (macroporosidade e microporosidade), resistência mecânica à penetração, infiltração de água no solo e diâmetro médio ponderado e uma variável de saída, representado pelo nível de recuperação física do solo (não recuperado (NR), parcialmente recuperado (PR) e recuperado (R)).

A Tabela 1 apresenta as classes dos atributos físicos do solo (NR, PR e R), com os valores restritos respectivamente para cada classe (KIEHL, 1979; BRANDAO et al., 2006). A tabela também apresenta as saídas desejadas com valores entre 0 e 1, em que o 0 representa o solo não recuperado fisicamente e o valor 1 representa o solo recuperado. Outros valores poderiam ser especificados pelos autores, no entanto, uma única saída como proposto neste trabalho representa uma maior facilidade na interpretação dos resultados bem como a montagem dos gráficos comparando as saídas desejadas e as obtidas pela rede.

Convém notar, portanto, que embora a RNA tenha sido usada para a classificação de três classes de solo (NR, PR e R), com discretização de sua saída produzida, os resultados apresentados a seguir consideram as saídas numéricas da rede (expressas em valores contínuos).


**Tabela 1** - Classes dos atributos físicos do solo.

Atributos	Não recuperado (NR)	Parcialmente recuperado (PR)	Recuperado (R)
Densidade do solo (g/cm <sup>3</sup> )	(1,61 – 1,80)	(1,56 – 1,60)	(1,30-1,55)
Porosidade do solo (%)	Macro	10 – 13	14 – 17
	Micro.	37 – 40	33 – 36
Resistência do solo (MPa)	> 2,8	2,1 – 2.8	0 - 2,0
Infiltração de água no solo (mm h <sup>-1</sup> )	<10	10- 38,1	>38,1
Diâmetro médio ponderado (mm)	<1	1-2	>2
Saídas desejadas	0,0 - 0,33	0,34 – 0,66	0,67-1,0

Fonte: Elaboração do próprio autor.

A Figura 2 onde (a) e (b) mostram os modelos de um neurônio biológico e artificial, respectivamente, onde as funções do neurônio artificial simulam as que ocorrem no modelo biológico.

**Figura 2** - Rede neural: (a) Neurônio biológico, (b) Neurônio artificial.



Fonte: (a) Adaptado de Carvalho (2009). (b) Elaboração do próprio autor.

Em que  $\sum$  representa, na figura 2b, o somatório dos produtos das entradas pelos respectivos pesos, ou seja,  $u = \sum_{i=1}^n x_i w_i + \text{bias}$  (serve para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento à ela fornecido) e  $f(u)$  é a função de ativação para obter a saída. A função de ativação que foi utilizada neste trabalho para a saída de ambas as camadas é a função tangente hiperbólica para dados normalizados e a função linear para não normalizados, equações (1) e (2):

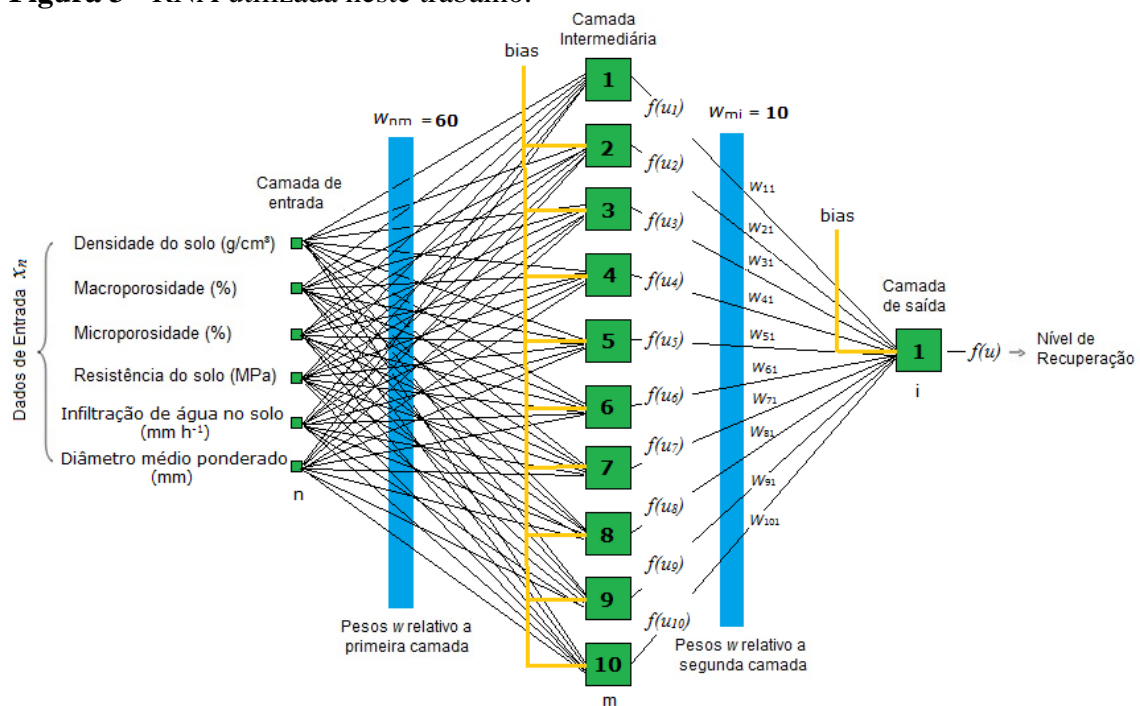
$$f(u) = (1 - e^{-\lambda u}) / (1 + e^{-\lambda u}) \quad (1)$$

$$f(u) = u \quad (2)$$

em que  $\lambda$  é uma constante arbitrária e corresponde a inclinação da curva.

Uma rede neural típica, que está sendo representada na Figura 3 é composta de  $n$  neurônios na camada de entrada,  $m$  neurônios na camada intermediária e  $i$  neurônios na camada de saída. Neste trabalho foram fixados  $n=6$  (densidade do solo, porosidade do solo (macroporosidade e microporosidade), resistência mecânica a penetração, infiltração de água no solo e diâmetro médio ponderado),  $m=10$  e  $i=1$  neurônio (nível de recuperação física do solo (NR, PR e R)).

**Figura 3** - RNA utilizada neste trabalho.



**Fonte:** Elaboração do próprio autor.

A RNA utilizada neste trabalho é a *Perceptron* multicamadas (MLP), composta por três camadas, entrada, intermediária e a de saída e com algoritmo de treinamento retropropagação não recorrente (treinamento supervisionado sem laços de realimentação) do inglês “*feedforward backpropagation*” (RUMMELHART e MCCLELLAND, 1986; HAYKIN, 2001). Optou-se em utilizar esse tipo de rede devido as características das amostras e do experimento.

Quando RNAs de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede. Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes

mapeamentos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias (CARVALHO, 2009). Por isso optou-se em utilizar pelo menos uma camada intermediária (uma camada intermediária é suficiente para aproximar qualquer função contínua e produzir praticamente quaisquer mapeamentos). Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema. Se existirem as conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias, pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediária (CARVALHO, 2009).

As amostras geradas para o processo de treinamento da rede foram desenvolvidas com base na Tabela 1.

## **5. RESULTADOS E DISCUSSÃO**

### ***5.1 Análise estatística***

A distribuição e estabilidade de agregados em água e o DMP (diâmetro médio ponderado dos agregados), nas camadas 0,00-0,10 m; 0,10-0,20 m e 0,20-0,40 m, referentes aos anos de 2015 a 2017 estão apresentados nas Tabelas 2 a 4, respectivamente.

Para o ano de 2015, os resultados apontaram que na camada de 0-0,10 m, o tratamento plantio direto + dessecação parcial apresentou o maior DMP, com maior quantidade de agregados de maior tamanho. Enquanto o tratamento gradagem apresentou menor estruturação do solo refletindo em um menor DMP, e maior número de agregados menores quando comparado aos demais tratamentos (Tabela 2). Já no ano de 2016, o tratamento controle foi o que obteve destaque.

Para os três anos avaliados, observou-se na camada de 0,10-0,20 m, que os tratamentos que compreendem ao plantio direto, sem ou com dessecação, parcial ou total apresentaram maior estruturação do solo com maior DMP, assim como o tratamento controle. Esses resultados podem ser atribuídos ao menor revolvimento do solo nestes sistemas de cultivo, mesmo que o manejo tenha ocorrido há quatro anos, uma vez que, a menor estruturação do solo e o menor DMP foi no tratamento Aração + gradagem, que intensifica manejo do solo.

Quanto à camada subsuperficial, ou seja, de 0,20-0,40 m de profundidade, o tratamento plantio direto sem dessecação apresentou menor estruturação do solo e menor DMP e maior quantidade de agregados de menor tamanho (classe > 0,25) em relação aos outros tratamentos. Solos com textura arenosa e com o clima favorável a degradação da matéria orgânica tende a ser menos estruturado, visto que a textura e a quantidade de agentes cimentantes estão diretamente ligadas a maior ou menor agregação do solo.

**Tabela 2** - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina - SP. 2015.

TRATA- MENTO	DMP	4	2	1	0,50	0,25	<0,25
----- mm -----							
<b>0-0,10 m</b>							
2	3,78 a	63,30 a	18,38 e	2,20 d	1,17b	0,78 d	14,17 d
4	2,40 d	31,05 e	23,57 c	5,10 c	1,58b	3,08 a	35,62 b
5	2,77 c	30,70 e	27,10 b	18,39 b	18,63a	0,20 f	4,99 f
6	0,45 e	34,60 d	24,01 c	4,87 c	2,64b	2,33 b	75,47 a
7	3,74 a	48,51 b	42,77 a	1,38 d	0,64b	0,44 e	6,26 e
1	3,41 b	43,76 c	28,92 b	21,50 a	4,65b	0,08 f	1,09 g
3	2,25 d	28,15 f	27,19 b	6,04 c	4,40b	1,98 c	32,20 c
F	28,98*	37,58*	33,88*	27,74*	13,46*	22,16*	24,13*
CV(%)	5,16	3,17	9,53	11,46	71,10	12,77	1,47
<b>0,10-0,20 m</b>							
2	3,89 a	63,84 a	22,58 a	0,25 c	0,35 c	0,17 c	12,79 c
4	3,78 a	57,60 b	27,41 a	3,40 b	2,19 b	1,47 b	7,92 d
5	3,44 a	56,24 b	18,43 b	3,35 b	1,34 c	1,22 b	22,91 b
6	2,48 b	25,51 d	24,54 a	20,70 a	19,25a	1,92 b	8,08 d
7	2,26 b	31,99 d	26,83 a	3,69 b	2,32 b	1,61 b	10,97 c
1	3,45 a	47,29 c	10,45 c	2,43 b	2,67 b	3,43 a	33,72 a
3	4,02 a	69,34 a	16,57 b	2,19 b	0,98 c	0,46 c	10,42 c
F	16,36*	32,46*	15,40*	91,72*	35,06*	48,49*	111,88*
CV(%)	10,30	11,39	14,96	28,21	17,24	20,85	11,89
<b>0,20-0,40 m</b>							
2	3,26 a	48,06 b	27,81 a	1,81 b	1,58 a	3,79 b	17,92 c
4	0,99 c	8,27 c	12,78 b	2,65 b	6,09 a	8,23 a	61,98 a
5	3,42 a	43,19 b	32,56 a	3,26 b	2,34 a	3,26 b	15,37 c
6	3,31 a	45,63 b	31,37 a	3,28 b	3,49 a	2,66 b	13,86 c
7	3,69 a	65,67 a	25,13 a	1,00 b	0,62 a	1,49 b	13,89 c
1	3,13 a	37,44 b	33,39 a	10,84 a	10,57 a	1,63 b	6,13 d
3	2,37 b	41,72 b	4,51 b	2,78 b	4,38 a	6,19 a	40,42 b
F	31,36*	9,35*	7,50*	3,39*	2,94*	12,94*	24,75*
CV(%)	11,52	27,10	33,62	36,85	34,19	35,35	11,41

Fonte: Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade.

**Tabela 3** - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina – SP. 2016.

TRATAMENTO	DMP	4	2	1	0,50	0,25	<0,25
----- mm -----							
<b>0-0,10 m</b>							
2	3,13 bc	50,00 bc	17,11 c	1,23 b	1,09	21,68a	8,89 cd
4	2,62 c	40,16 cd	17,41 c	2,46 ab	1,38	0,88 d	39,48 b
5	3,35 b	55,69 b	15,75 c	1,60 ab	1,16	12,42 b	13,39 cd
6	2,88 bc	39,95 cd	25,43 a	2,79 ab	1,95	12,23 b	17,64 c
7	3,25 bc	46,76 bc	27,10 a	3,05 a	1,45	5,54 c	16,09 c
1	4,26 a	71,63 a	21,77 b	1,08 b	1,35	1,00 d	5,00 d
3	1,85 d	29,09 d	11,29 d	1,06 b	1,60	5,00 c	60,00 a
F	24,98*	24,18*	60,76*	4,89*	1,83 <sup>ns</sup>	18,24*	74,33*
CV(%)	9,67	11,60	7,43	10,62	29,83	14,22	19,95
<b>0,10-0,20 m</b>							
2	0,37 f	36,54 c	13,11 f	0,43 c	0,02 d	3,80 bc	85,66 a
4	2,68 c	40,91 c	16,97 d	2,28 bc	5,24 a	4,80 bc	29,79 d
5	3,17 b	47,71 b	18,88 c	2,03 ab	1,51 bc	15,41 a	14,46 e
6	1,35 e	21,02 e	6,05 g	1,14 abc	0,71 ab	1,89 c	69,18 b
7	2,13 d	31,19 d	16,14 e	1,04 bc	0,60 d	0,56 c	50,48 c
1	3,49 a	53,76 a	23,62 b	2,43 a	1,56 b	10,63 ab	7,99 f
3	3,64 a	53,94 a	29,11 a	1,87 ab	0,82 bcd	6,41 bc	7,84 f
F	78,14*	16,59*	44,75*	7,13*	95,42*	9,06*	68,19*
CV(%)	3,74	4,68	11,25	24,67	23,80	24,06	6,30
<b>0,20-0,40 m</b>							
2	2,65 b	40,28 b	17,92 ab	1,63 b	1,28 c	7,36 d	31,50 b
4	3,72 a	61,47 a	18,04 ab	3,18 ab	1,78 bc	8,42 cd	7,12 d
5	3,81 a	65,94 a	14,23 ab	2,23 ab	2,64 abc	4,47 e	10,50cd
6	1,65 c	25,10 c	9,24 b	1,45 b	1,37 c	6,46 de	56,37 a
7	2,91 b	43,62 b	19,92 a	2,95 ab	2,87 ab	11,45 ab	19,16 bcd
1	2,60 b	39,60 b	15,76 ab	2,90 ab	3,40 a	11,12 bc	27,22 bc
3	3,12 ab	49,72 b	16,35 ab	3,64 a	3,22 ab	14,11 a	12,96 bcd
F	22,76*	34,38*	2,45*	4,04*	7,57*	29,20*	16,89*
CV(%)	10,55	10,21	27,58	31,80	27,00	13,61	35,04

Fonte: Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle *U. decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade.

Estes resultados corroboram com estudos realizados por Salton et. al., (2008), que avaliaram a estabilidade de agregados e formas de manejo do solo e verificaram que os sistemas com presença de pastagem permanente e em rotação com soja em plantio direto apresentaram maior quantidade de agregados grandes na camada de 0,0-0,5 m, em relação aos demais sistemas. Para as classes de agregados inferiores a 1 mm ocorreu o inverso, com os sistemas sem pastagens apresentaram maior porcentagem.

Ainda de acordo com Salton et. Al., (2008), destacam que a maior quantidade de agregados da classe de 4,76 mm no sistema pastagem permanente, também na profundidade de 10 a 20 cm, indicando a existência de efeito do sistema radicular da pastagem permanente no processo de formação dos macroagregados.

**Tabela 4** - Estabilidade de agregados em distintas profundidades do solo em função dos tratamentos. Andradina – SP. 2017.

TRATAMENTO	DMP	4	2	1	0,50	0,25	<0,25
----- mm -----							
<b>0-0,10 m</b>							
2	3,78a	56,65a	18,38b	2,02b	1,13b	0,78b	14,17b
4	2,40b	31,05a	23,57b	5,10b	1,48b	3,08a	35,62a
5	2,77b	30,71a	27,10b	18,39a	9,89a	0,72b	4,99b
6	0,45c	4,65b	24,01b	4,87b	2,29b	2,33a	75,47a
7	3,74a	48,51a	42,77a	1,38b	1,04b	0,44b	6,26b
1	3,41a	43,76a	28,92b	21,5a	3,00b	0,08b	1,09b
3	2,25b	28,15a	27,19b	6,04b	3,99b	1,98a	32,20a
F	15,98*	19,37*	47,28*	18,82*	7,65*	15,15*	34,65*
CV(%)	7,41	7,38	8,48	11,04	15,46	13,49	10,71
<b>0,10-0,20 m</b>							
2	3,89a	63,84a	22,58a	0,25c	0,35b	0,17b	12,79b
4	3,78a	57,60a	27,41a	3,40b	2,19b	1,47b	7,92b
5	3,44a	56,24a	18,43b	3,35b	1,34b	1,22b	22,91a
6	2,48b	25,51b	24,54a	20,70a	19,25a	1,92b	8,08b
7	2,26b	31,99a	26,83a	3,69b	2,32b	1,61b	10,97b
1	3,45a	47,29a	10,45b	2,43b	2,67b	3,43a	33,72a
3	4,02a	69,34a	16,57b	2,19b	0,98b	0,46b	10,42b
F	16,68*	32,46*	15,40*	19,72*	35,06*	48,41*	11,82*
CV(%)	7,02	11,39	9,82	28,21	14,25	20,85	11,89
<b>0,20-0,40 m</b>							
2	3,26a	48,06a	27,81a	1,81b	1,58b	3,79b	17,92b
4	0,99b	8,27b	12,78b	2,65b	6,09b	8,23a	61,98a
5	3,42a	43,19a	32,56a	3,26b	2,34b	3,26b	15,37b
6	3,31a	45,63a	31,37a	3,28b	3,49b	2,66b	13,86b
7	3,69a	65,67a	25,13a	1,00b	0,62b	1,49b	13,89b
1	3,13a	37,44a	33,39a	10,84a	10,57a	1,63b	6,13c
3	2,37a	41,72a	4,51c	2,78b	4,38b	6,19a	40,42a
F	31,36*	19,35*	11,59*	13,39*	12,96*	12,95*	24,75*
CV(%)	11,03	27,10	21,95	36,85	30,85	35,35	11,41

Fonte: Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle *U. decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade.

Carvalho, et. al., (2014) destacam que amostras de solo coletadas em situação de cerrado com pastagem nativa, apresentaram diâmetro médio maior que as amostras coletadas em solo com cultivo de milho, devido à ação do sistema radicular das gramíneas em contrapartida ao do cereal. Concluindo que quanto menor o tamanho do agregado maior a proporção de argilas, menor a densidade do agregado e maior a porosidade intra-agregado.

## 5.2 Porosidade do solo e densidade do solo

Os valores médios de macroporosidade, microporosidade, porosidade total e densidade do solo, nas camadas de 0,00-0,10 m; 0,10-0,20 m e 0,20-0,40 m, nos períodos

avaliados (2015-2017) encontram-se nas Tabelas 5 a 8, respectivamente. E na Figura 4 estão apresentadas a evolução por tratamento x anos das propriedades físicas estudadas.

Não houve diferença significativa entre os tratamentos para nenhuma variável analisada. As camadas analisadas apresentaram valores de macroporosidade abaixo do valor considerado crítico para o bom desenvolvimento das plantas ( $0,10 \text{ m}^3 \text{ m}^{-3}$ ), indicando condições de degradação de solo. Os resultados foram semelhantes aos encontrados por Arruda et al. (2013) quando estudaram a macroporosidade em pastagem de *Urochloa decumbens* em função da adubação e verificaram variação de  $0,06$  a  $0,08 \text{ m}^3 \text{ m}^{-3}$  nas camadas mais superficiais.

**Tabela 5** - Valores médios do índice de macroporosidade (MA) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.

Tratamento	2015	2016	2017
0-0,10m			
2	0,045	0,053	0,062
4	0,038	0,080	0,072
5	0,031	0,090	0,102
6	0,034	0,085	0,055
7	0,034	0,070	0,075
1	0,040	0,078	0,067
3	0,020	0,075	0,062
F(5%)	0,790 <sup>NS</sup>	0,740 <sup>NS</sup>	2,063 <sup>NS</sup>
CV(%)	52,83	37,16	30,17
0,10-0,20m			
2	0,041	0,070	0,065
4	0,032	0,060	0,045
5	0,055	0,093	0,080
6	0,037	0,095	0,057
7	0,056	0,090	0,062
1	0,032	0,078	0,077
3	0,056	0,093	0,072
F(5%)	1,695 <sup>NS</sup>	0,885 <sup>NS</sup>	1,039 <sup>NS</sup>
CV(%)	37,55	34,89	36,50
0,20-0,40 m			
2	0,044	0,090	0,055
4	0,052	0,065	0,060
5	0,048	0,093	0,072
6	0,056	0,105	0,075
7	0,049	0,825	0,067
1	0,047	0,900	0,085

3	0,054	0,103	0,102
F(5%)	0,354 <sup>NS</sup>	1,220 <sup>NS</sup>	0,837 <sup>NS</sup>
CV(%)	27,06	26,94	47,32

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

Ao ocorrerem modificações nas condições da macroporosidade de um solo, a microporosidade e a porosidade total também sofrem alterações (ALVES, 2001). Estudos realizados por Kitamura et al. (2008) verificaram que a redução da macroporosidade nos solos degradados decorrem do aumento da compactação, que é evidenciada pelo aumento da densidade do solo. Bonini (2012) concluiu que na ocorrência de degradação tiveram como efeito imediato o aumento da densidade do solo e diminuição da macroporosidade.

**Tabela 6** - Valores médios do índice de microporosidade (MI) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.

Tratamento	2015	2016	2017
0-0,10m			
2	0,243	0,275	0,257
4	0,256	0,248	0,247
5	0,256	0,220	0,252
6	0,272	0,208	0,247
7	0,241	0,305	0,245
1	0,247	0,215	0,257
3	0,229	0,248	0,270
F(5%)	1,304 <sup>NS</sup>	1,171 <sup>NS</sup>	0,367 <sup>NS</sup>
CV(%)	9,69	26,53	11,24
0,10-0,20m			
2	0,239	0,253	0,232
4	0,222	0,253	0,222
5	0,242	0,235	0,220
6	0,223	0,260	0,225
7	0,241	0,248	0,222
1	0,236	0,240	0,217
3	0,240	0,228	0,215
F(5%)	1,090 <sup>NS</sup>	0,510 <sup>NS</sup>	0,453 <sup>NS</sup>
CV(%)	6,92	12,99	7,59
0,20-0,40m			
2	0,237	0,180	0,220
4	0,245	0,250	0,217

5	0,245	0,225	0,220
6	0,234	0,235	0,227
7	0,242	0,263	0,212
1	0,241	0,243	0,215
3	0,243	0,223	0,205
F(5%)	0,315 <sup>NS</sup>	1,105 <sup>NS</sup>	0,485 <sup>NS</sup>
CV(%)	5,91	21,81	9,31

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

Desta maneira, a degradação do solo, proporciona modificações no arranjo de suas partículas, diminuindo o tamanho dos poros, levando a redução na área da seção transversal para o fluxo de água, afetando diretamente o processo de infiltração (SOUZA; ALVES, 2003).

**Tabela 7** - Valores médios do índice de porosidade total (PT) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.

Tratamento	2015	2016	2017
0-0,10m			
2	0,287	0,327	0,320
4	0,292	0,325	0,320
5	0,286	0,307	0,355
6	0,305	0,297	0,307
7	0,275	0,377	0,317
1	0,287	0,292	0,327
3	0,248	0,317	0,337
F(5%)	0,943 <sup>NS</sup>	1,090 <sup>NS</sup>	0,521 <sup>NS</sup>
CV(%)	12,96	16,91	13,24
0,10-0,20m			
2	0,279	0,325	0,292
4	0,253	0,310	0,265
5	0,297	0,325	0,300
6	0,259	0,355	0,282
7	0,297	0,327	0,287
1	0,268	0,317	0,295
3	0,279	0,322	0,290
F(5%)	1,708 <sup>NS</sup>	0,904 <sup>NS</sup>	0,948 <sup>NS</sup>
CV(%)	9,45	9,07	8,12
0,20-0,40m			
2	0,280	0,270	0,275

4	0,296	0,315	0,275
5	0,292	0,322	0,290
6	0,289	0,340	0,302
7	0,290	0,342	0,282
1	0,287	0,332	0,300
3	0,296	0,327	0,310
F(5%)	0,234 <sup>NS</sup>	1,224 <sup>NS</sup>	0,517 <sup>NS</sup>
CV(%)	7,86	13,85	13,30

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

O processo de recuperação de áreas degradadas ocorre a longo prazo. Devido ao pequeno período que compreende o experimento (3 anos) não foi possível detectar modificações na qualidade física do solo. Resultados discordantes foram encontrados por Marchão et al. (2007) que verificou mudanças na estrutura do solo estudado, possivelmente pelo tempo de avaliação (1991 a 1999). Diferentes formas de manejo do solo foram adotadas por LanzaNova et al. (2007) e Flores (2007) obtendo resultados positivos com as modificações na distribuição do tamanho de poros, diferente deste experimento. Vale ressaltar que os estudos de Marchão et al. (2007), LanzaNova et al. (2007) e Flores (2007) foram em solos de textura média, enquanto no presente trabalho foi em textura arenosa.

**Tabela 8** - Valores médios do índice de densidade do solo (DS) referente aos anos de 2015, 2016 e 2017, CV (%) e teste F a 5% de probabilidade. Andradina-SP.

Tratamento	2015	2016	2017
0-0,10m			
2	1,600	1,625	1,615
4	1,528	1,597	1,600
5	1,612	1,595	1,587
6	1,571	1,617	1,635
7	1,586	1,512	1,620
1	1,564	1,650	1,600
3	1,638	1,597	1,610
F(5%)	1,120 <sup>NS</sup>	1,873 <sup>NS</sup>	0,264 <sup>NS</sup>
CV(%)	4,26	4,07	3,77
0,10-0,20m			
2	1,589	1,625	1,662
4	1,628	1,670	1,667

5	1,568	1,602	1,612
6	1,601	1,615	1,687
7	1,562	1,560	1,660
1	1,622	1,622	1,612
3	1,596	1,607	1,650
F(5%)	0,503 <sup>NS</sup>	1,402 <sup>NS</sup>	2,759 <sup>NS</sup>
CV(%)	4,36	3,42	2,06
0,20-0,40m			
2	1,597	1,690	1,635
4	1,548	1,675	1,675
5	1,590	1,642	1,672
6	1,589	1,570	1,660
7	1,575	1,625	1,665
1	1,539	1,617	1,635
3	1,572	1,617	1,575
F(5%)	0,494 <sup>NS</sup>	1,602 <sup>NS</sup>	0,643 <sup>NS</sup>
CV(%)	3,95	3,87	5,32

**Fonte:** Adaptado de Bonini et al., (2017).


2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

Desta maneira, é provável que neste experimento o impacto do pastejo tenha sido maior, deixando a desestruturação do solo mais evidente.

Foi verificado aumento na macroporosidade do solo ao longo do tempo (Figura 4). Nota-se que a microporosidade praticamente não mudou, pois, essa propriedade não é modificada pelo manejo do solo.

Verificou-se que os valores estão abaixo do recomendado na Tabela 1 para que sejam classificadas como solo recuperado, para a macroporosidade e para o bom desenvolvimento das culturas. De forma geral, a recuperação da estrutura do solo é lenta e gradativa. De acordo com os dados mostrados, esse processo já se iniciou e com alguns anos a recuperação desta propriedade será mais evidente.

**Figura 4** - Valores médios em porcentagem de macroporosidade, microporosidade, porosidade total e densidade do solo (g dm<sup>-3</sup>), na camada de 0,00-0,10 m, nos anos de 2015 a 2017. Andradina – SP.



Fonte: Bonini et al., 2017.

Legenda: 1- testemunha capim *Urochloa*; 2- *Urochloa* + estilosantes com 1,5 L ha<sup>-1</sup> de glifosato; 3 - *Urochloa* + estilosantes com dessecação total com 3,0 L ha<sup>-1</sup> de glifosato; 4 - *Urochloa* + estilosantes com plantio direto; 5 - *Urochloa* + estilosantes com escarificação do solo, 6 - *Urochloa* + estilosantes com gradagem rome e 7 - *Urochloa* + *Urochloa* com aração + gradagem.

### 5.3 Infiltração de água no solo

As taxas de infiltração de água e a infiltração média acumulada não apresentaram diferença significativa e os resultados estão apresentados na Tabela 9 (2015 a 2017).

**Tabela 9** - Taxa constante de infiltração de água em função dos tratamentos. Andradina – SP. 2015, 2016 e 2017.

Tratamento	Taxa constante de infiltração (mm h <sup>-1</sup> )		
	2015	2016	2017
2	44,5408	91,1163 ab	54,5408 a
4	36,8650	108,4658 ab	50,5016 a
5	41,5666	112,7085 a	60,2675 a
6	40,1183	104,4100 ab	46,2350 b
7	40,1166	97,0597 ab	35,3200 b
1	40,9933	117,5217 a	43,9908 b
3	33,1050	79,7012 b	33,2883 b
F (5%)	0,332 <sup>NS</sup>	3,002*	5,279*
CV (%)	21,42	25,92	31,90

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

A capacidade de infiltração de água no solo pode ser afetada por diversos fatores, entre eles destacam-se, o tempo, a umidade inicial, a porosidade e a textura, e a condutividade hidráulica (LIBARDINI, 2005).

Segundo Klein (2014), a textura do solo relacionada ao tamanho das partículas determina a classificação do diâmetro dos poros do solo. Assim, quanto maior for o volume de macroporos, maior será a capacidade de infiltração de água em profundidades.

Os valores obtidos neste trabalho foram semelhantes aos encontrados por Brandão et al (2012). Segundo estes autores, solos com pastagem e de textura arenosa possuem valor médio de infiltração que variam de 38,1 a 111,8 mm h<sup>-1</sup>. Também Romeiro; Bonini; Bonini Neto (2014) que estudaram o comportamento da infiltração da água no solo em 3 áreas distintas (vegetação nativa, cultivo perene (eucalipto) e pastagem degradada) e verificaram valores semelhantes nos tratamentos vegetação nativa e pastagem degradada, concordando com este trabalho.

Segundo Klein (2014), os sistemas de manejo adotados possuem grande efeito sobre a taxa de infiltração no solo. Avaliando tais fatores, o autor relata que em alguns casos, estudos comprovaram maior taxa de infiltração no plantio direto quando comparado ao sistema convencional de preparo. Tal fato pode ser explicado pela grande variação da quantidade e qualidade dos restos culturas sobre a superfície do solo e a variação do volume de macroporos que existem nas diferentes formas de manejo.

Nota-se que houve um aumento expressivo na taxa constante de infiltração de um ano para outro, sendo que esse comportamento mostra uma influência positiva dos tratamentos estudados.

#### 5.4 Resistência mecânica a penetração e teor de água no solo

Os resultados da resistência do solo à penetração e do teor de água no solo, nas camadas de 0,0-0,10 m; 0,10-0,20 m e 0,20-0,40 m estão compilados nas Tabela 10 a 12 (2015 a 2017) e os valores medios dos três anos estudados estão apresentados na Figura 5.

**Tabela 10** - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2015.

Tratamentos	Resistência do solo à Penetração – MPa		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	0,88	2,70	1,07
4	1,12	3,11	0,65
5	1,08	3,34	0,70
6	0,61	2,62	0,94
7	0,91	3,23	0,97
1	0,99	3,15	1,01
3	0,94	3,35	0,81
F	1,018 <sup>NS</sup>	1,450 <sup>NS</sup>	0,501 <sup>NS</sup>
CV (%)	61,47	27,68	90,13
	Teor de água no solo – %		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	9,25	8,20	8,73
4	8,01	7,68	7,84
5	8,75	8,11	8,43
6	8,61	6,85	7,73
7	8,54	8,89	8,71
1	9,19	7,44	8,32
3	7,95	7,55	7,75
F	0,855 <sup>NS</sup>	0,743 <sup>NS</sup>	1,088 <sup>NS</sup>
CV (%)	12,28	19,27	9,97

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

Nos anos estudados, nota-se que as camadas estudadas podem ser classificadas como de baixa resistência à penetração, pois os valores encontrados estão abaixo do sugerido pela classe média de resistência (2,0-5,0 Mpa). Segundo Canarache (1990) nesta classe as raízes podem sofrer algumas limitações em seu crescimento, fato que não ocorreu neste trabalho, pois a resistência mecânica a penetração não interferiu no desenvolvimento das raízes.

Somente a camada de 0,20-0,40 m apresentou diferença significativa entre os tratamentos em que o tratamento aração + gradagem apresentou menor resistência à penetração (RP), enquanto o plantio direto com escarificação do solo apresentou a maior RP.

**Tabela 11** - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2016.

Tratamentos	Resistência do solo à Penetração – MPa		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	0,88	0,48	0,07 c
4	0,93	0,61	0,06 c
5	0,80	1,38	0,21 a
6	0,83	1,08	0,11 b
7	1,14	1,03	0,05 c
1	1,03	0,86	0,10 b
3	0,94	0,50	0,06 c
F	0,835 <sup>NS</sup>	1,276 <sup>NS</sup>	2,846*
CV (%)	27,68	70,37	57,90
	Teor de água no solo – %		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	8,34	8,05	8,21
4	7,62	8,00	8,41
5	7,54	8,37	9,32
6	8,54	8,94	8,54
7	8,37	8,57	9,13
1	7,61	8,43	8,55
3	8,71	8,71	8,71
F	0,827 <sup>NS</sup>	0,984 <sup>NS</sup>	0,906 <sup>NS</sup>
CV (%)	13,52	8,11	9,53

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

Estudando a resistência mecânica a penetração de um Latossolo Vermelho compactado, Campo e Alves (2006) relataram que uma área com estado avançado de degradação na profundidade de 0-0,05m apresentou classe de resistência do solo à penetração alta com 5,92 MPa, enquanto o solo em condições naturais de cerrado apresentou classe de resistência a penetração considerada baixa (0,72 MPa).

Na avaliação do teor de água no solo, em todas as camadas estudadas, não apresentaram diferença significativa entre os tratamentos. Segundo Campos e Alves (2006) a determinação da umidade do solo no momento da avaliação da resistência à penetração, é fundamental para se realizar adequadamente a interpretação dos resultados encontrados.

O grau de umidade intervém, modificando a coesão entre as partículas do solo, que é maior no solo seco e decresce na medida em que a quantidade de água aumenta, provocando a separação das partículas e menor resistência à penetração (KLEIN et. al., 2014).


**Tabela 12** - Valores médios para resistência do solo à penetração e umidade gravimétrica, nas camadas de solo estudadas. Andradina – SP. 2017.

Tratamentos	Resistência do solo à Penetração – MPa		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	1,02	1,05	0,13
4	1,17	0,79	0,14
5	0,96	0,77	0,12
6	0,90	0,57	0,06
7	1,14	0,58	0,27
1	1,11	0,59	0,03
3	1,19	1,28	0,16
F	0,820 <sup>NS</sup>	1,221 <sup>NS</sup>	0,779 <sup>NS</sup>
CV (%)	19,73	10,54	22,03
	Teor de água no solo – %		
	0,00-0,10m	0,10-0,20m	0,20-0,40 m
2	10,59	9,86	10,41
4	10,77	10,54	11,70
5	12,06	10,90	11,46
6	11,29	11,51	10,44
7	11,48	10,18	11,61
1	10,59	11,61	11,07
3	10,37	10,07	9,42
F	1,060 <sup>NS</sup>	1,271 <sup>NS</sup>	1,961 <sup>NS</sup>
CV (%)	10,74	11,59	10,90

**Fonte:** Adaptado de Bonini et al., (2017).

2= dessecação parcial; 4= plantio direto sem dessecação; 5= escarificação do solo; 6= gradagem; 7= aração + gradagem; 1= controle U. *decumbens*; 3= dessecação total; CV: coeficiente de variação; F: teste F. Médias seguidas de letras iguais na coluna não diferem entre si pelo teste de Tukey a 5% de probabilidade. \* significativo a 5% de probabilidade. <sup>NS</sup> não significativo.

**Figura 5** - Valores médios de resistência a penetração de raízes (A) ano de 2015, (B) ano de 2016 e (C) ano de 2017.



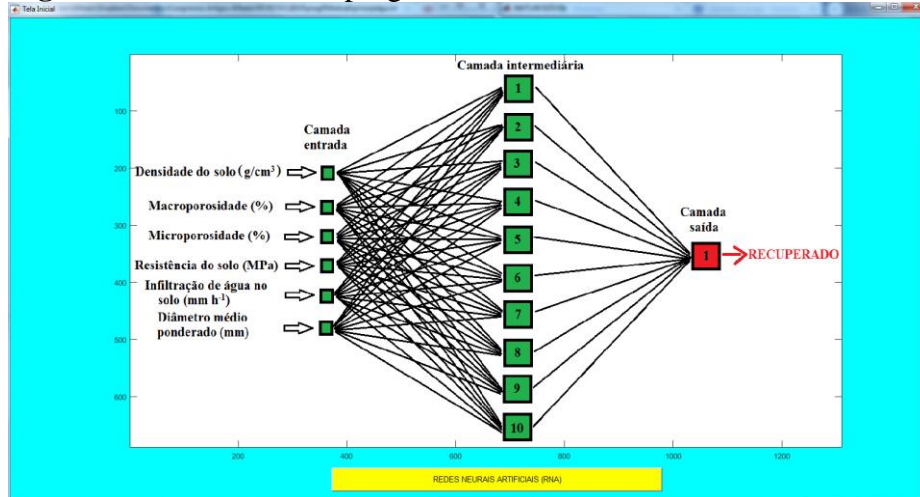
**Fonte:** Adaptado de Bonini et al., (2017).

Os dados apresentados anteriormente foram avaliados pela estatística convencional e foi constatado que não houve diferença significativa na maioria dos atributos físicos estudados. Para o DMP, o tratamento 04 (PD) foi o que apresentou melhor resultado, de acordo com a Tabela 1, já, na RP, houve diferença estatística, mas não teve um único tratamento que apresentou melhor resultado entre os demais, com isso, fica claro que: o uso da estatística convencional, não consegue explorar os resultados de pesquisa de tal forma que, consigamos eleger o melhor sistema de manejo. Atualmente o uso de *Machine Learning* para análise de dados agrônômicos tem sido difundido e adotado para tais análises.

Neste trabalho foi desenvolvido uma interface gráfica baseada em Redes Neurais Artificiais (RNAs) para a classificação de solos. A partir de seu treinamento, e com todos os pesos ajustados e validados, a RNA construída pôde atuar como um classificador de dados. Em especial, a rede foi capaz de fazer previsões/inferências a partir dos atributos do solo, permitindo a identificação de seus níveis de recuperação.

A Figura 6 apresenta a tela inicial do programa. Clicando no botão “REDES NEURAIAS ARTIFICIAIS” uma outra tela se abre para inserção dos dados, Figura 7. Nessa tela o usuário poderá inserir os dados de entrada da rede e os dados de saída desejada da rede, a tela consta com três botões “Criar a RNA”, “Limpar dados” e “Verificar dados no Command Window”. Clicando em “Limpar dados”, todos os dados inseridos serão excluídos, possibilitando a inserção de novos dados. Caso o usuário clique em “Verificar dados no Command Window” aparecerá um aviso na tela mostrando as dimensões das matrizes de entrada e saída, e no Command Window do Matlab aparecerá o vetor com todos os dados inseridos tanto de entrada como de saída, conforme Figura 8 e Figura 9. Na Figura 9, temos os dados da entrada e dados de saída, colocados de forma aleatória, onde os dados de entrada são os dados dos parâmetros de física do solo que foram estipulados pela Tabela 1; os dados de saída desejada, se dá pelo intervalo de 0 a 1, também se aplica uma classificação entre o intervalo desses números, conforme Tabela 1.

**Figura 6** - Tela inicial do programa.



Fonte: Elaboração do próprio autor.

**Figura 7** - Tela para inserção dos dados.

Tela de inserção de dados para a RNA. O campo de entrada contém o vetor [62068966,4.89682758620690] e o campo de saída contém o vetor [1379310,0.761034482758621]. Botões: Criar a RNA, Limpar dados, Verificar dados no ...

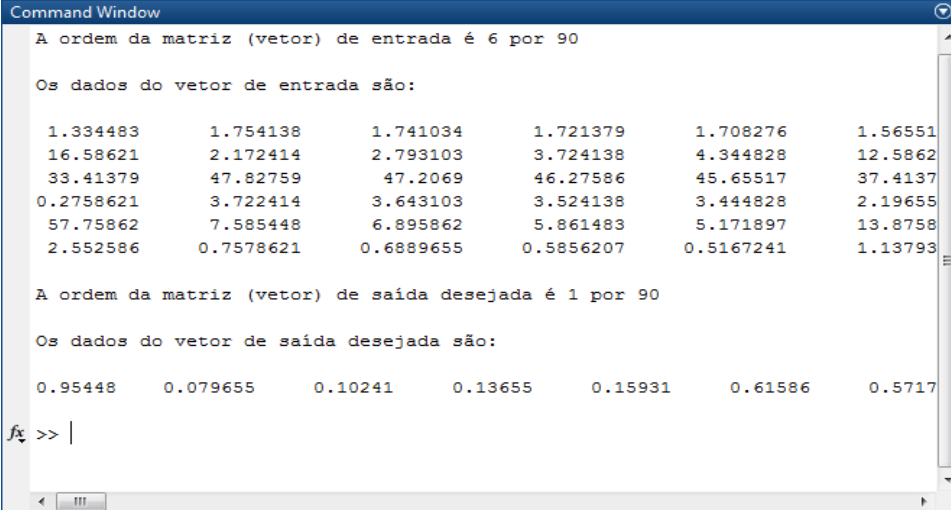
Fonte: Elaboração do próprio autor.

**Figura 8** - Tela para inserção dos dados com a visualização das dimensões das matrizes de entrada (física do solo) e saída dos dados. Saída desejada de acordo com Tabela 1.

Tela de inserção de dados com visualização das dimensões das matrizes. O campo de entrada contém o vetor [62068966,4.89682758620690] e o campo de saída contém o vetor [1379310,0.761034482758621]. Dimensão da matriz entrada: 6 x 90. Dimensão da matriz saída: 1 x 90. Botões: Criar a RNA, Limpar dados, Verificar dados no ...

Fonte: Elaboração do próprio autor.

**Figura 9** - Tela para visualização dos dados no Cammand Window do Matlab tanto da matriz de entrada como da matriz de saída desejada.



```
Command Window
A ordem da matriz (vetor) de entrada é 6 por 90

Os dados do vetor de entrada são:

1.334483    1.754138    1.741034    1.721379    1.708276    1.56551
16.58621   2.172414   2.793103   3.724138   4.344828   12.5862
33.41379   47.82759   47.2069    46.27586   45.65517   37.4137
0.2758621  3.722414   3.643103   3.524138   3.444828   2.19655
57.75862   7.585448   6.895862   5.861483   5.171897   13.8758
2.552586   0.7578621  0.6889655  0.5856207  0.5167241  1.13793

A ordem da matriz (vetor) de saída desejada é 1 por 90

Os dados do vetor de saída desejada são:

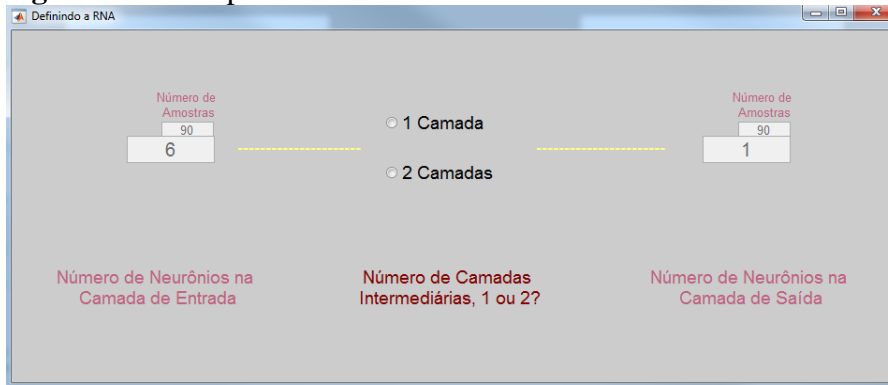
0.95448    0.079655    0.10241    0.13655    0.15931    0.61586    0.5717

fx >> |
```

**Fonte:** Elaboração do próprio autor.

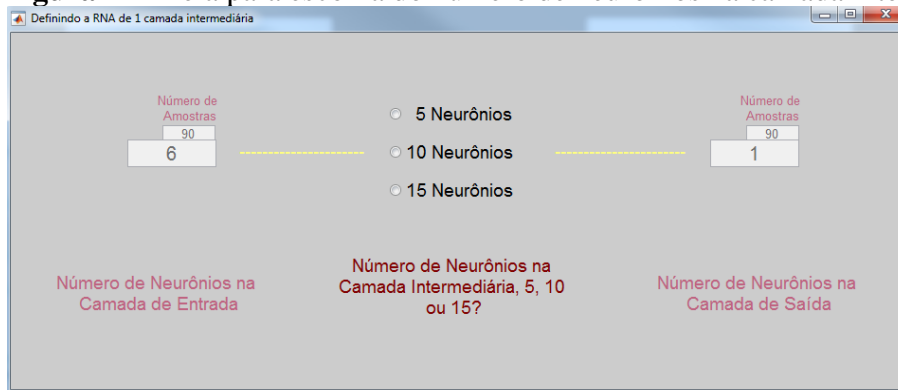
A tela da Figura 10 a seguir aparecerá caso o usuário clique no botão “Criar a RNA” da tela de inserção de dados na Figura 8. Essa tela tem a função de escolher quantas camadas intermediárias a RNA terá. Para este trabalho conforme comentado em materiais e métodos, optou-se em 1 camada intermediária pelas características do experimento e modelagem utilizada (seis camadas de entrada e uma de saída, quantidade de dados entre outros), outras opções poderiam ser inseridas ao programa (três, quatro ou mais camadas intermediárias). Clicando em 1 camada a tela criada é mostrada na Figura 11 e clicando em 2 camadas a tela criada é mostrada na Figura 12. Essas telas têm a função de escolher quantos neurônios a camada intermediária possuirá (5, 10 ou 15 neurônios). Como muitos trabalhos falam que a camada intermediária tem que ser maior ou igual a camada de entrada ou de saída, optou-se em utilizar 10 neurônios na camada intermediária, mas isso não impede de utilizar 5 ou 15 neurônios.

**Figura 10** - Tela para escolha do número de camadas intermediárias.



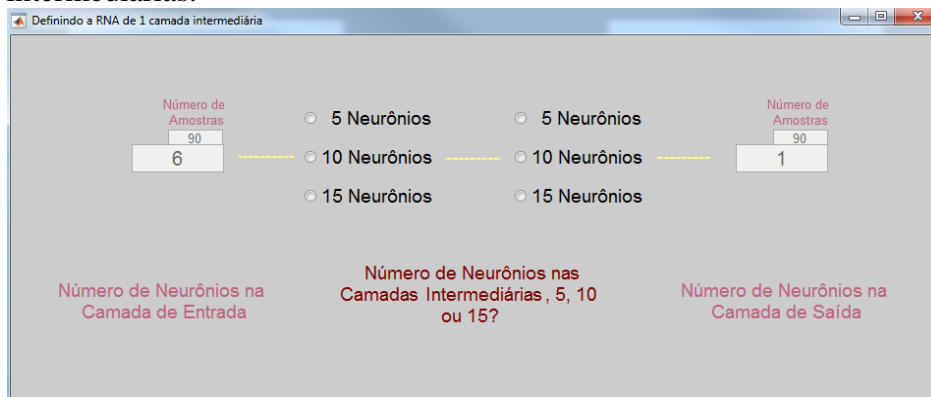
**Fonte:** Elaboração do próprio autor.

**Figura 11** - Tela para escolha do número de neurônios na camada intermediária.



**Fonte:** Elaboração do próprio autor.

**Figura 12** - Tela para escolha do número de neurônios nas 2 camadas intermediárias.



**Fonte:** Elaboração do próprio autor.

Ao escolher o número de neurônios na camada intermediária (10 neurônios na tela da Figura 11) uma nova tela se abre conforme mostrado na Figura 13 a seguir. Os parâmetros de treinamento que constituem a Figura 13 é o usuário que define seus valores. Essa tela tem a função de definir as funções de pertinência, algoritmos de aprendizado e especificar os parâmetros para o treinamento da RNA em termos de

número máximo de iterações (épocas), erro desejado, taxa de aprendizado e tempo de CPU em segundos; esses parâmetros interferem no diagnóstico final da rede, permitindo ou não uma simulação mais adequada/normalizada dos dados, ou algo menos sensível e podendo permitir maiores taxas de erros. Após escolher todas as opções para o treinamento basta clicar no botão “Treinar” que a RNA entrará em processo de treinamento. O botão “Redefinir” apaga todas as opções escolhidas deixando a tela limpa para outras escolhas de parâmetros.

**Figura 13** - Tela para definir as funções de pertinência, algoritmos de aprendizado e especificar os parâmetros para o treinamento da RNA.

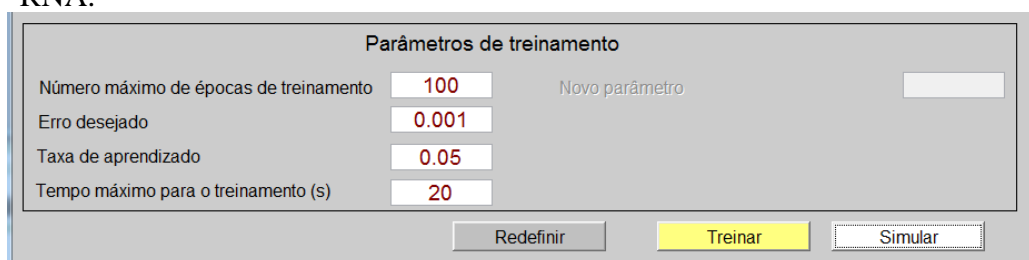
A interface de configuração da RNA apresenta os seguintes elementos:

- Arquitetura da Rede:** Três campos para o número de neurônios por camada. O campo "Número de Neurônios na Camada de Entrada" contém o valor 6, "Número de Neurônios na Camada Intermediária" contém 10, e "Número de Neurônios na Camada de Saída" contém 1. Cada campo possui um botão "Número de Amostras" com o valor 90.
- Funções de Transferência:** Dividido em duas colunas: "Camada Intermediária" e "Camada de Saída". Ambas as colunas oferecem opções de funções de transferência: Linear, Tangente hiperbólica (selecionada), Sigmóide, Linear com saturação e Nova função.
- Algoritmos de Aprendizado:** Lista de algoritmos com "Backpropagation Levenberg-Marquardt" selecionado. Outras opções incluem Backpropagation de gradiente decrescente, com momentum, com taxa adaptativa e com momentum e taxa.
- Parâmetros de treinamento:** Campos de entrada para "Número máximo de épocas de treinamento" (100), "Erro desejado" (0.001), "Taxa de aprendizado" (0.05) e "Tempo máximo para o treinamento (s)" (20). Há também um campo "Novo parâmetro" vazio.
- Botões de Ação:** "Redefinir" (cinza) e "Treinar" (verde amarelo).

**Fonte:** Elaboração do próprio autor.

Após clicar no botão “Treinar”, ocorrerá o que está descrito no item 5.2; feito isso, um novo botão surge na tela com nome de “Simular” e tem a função de fazer a operação ou diagnóstico da RNA para amostras que não fizeram parte do treinamento, conforme Figura 14. Caso o usuário resolva treinar a rede várias vezes, a partir de dois treinamentos outro botão surge na tela de nome “Gráfico de superfície” que tem a finalidade de montar o gráfico de superfície de todos os treinamentos realizados pelo usuário, a Figura 15 apresenta este botão.

**Figura 14** - Tela com a inserção do botão “Simular” para operação (diagnóstico) da RNA.



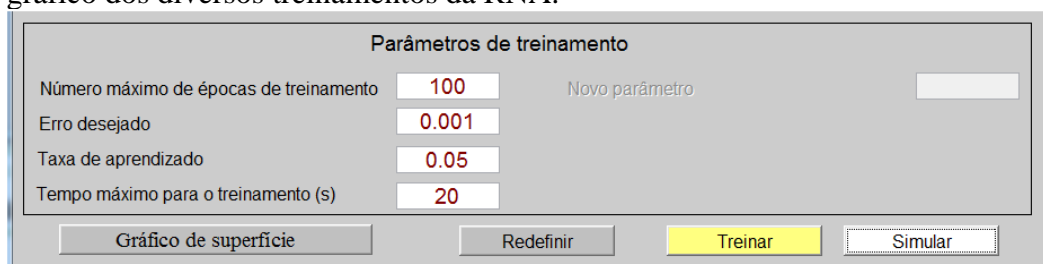
The screenshot shows a window titled "Parâmetros de treinamento" with the following parameters and controls:

Parâmetro	Valor	Controle
Número máximo de épocas de treinamento	100	Input field with "Novo parâmetro" label and empty box
Erro desejado	0.001	Input field
Taxa de aprendizado	0.05	Input field
Tempo máximo para o treinamento (s)	20	Input field

Buttons at the bottom: "Redefinir", "Treinar" (highlighted in yellow), and "Simular" (highlighted in white).

Fonte: Elaboração do próprio autor.

**Figura 15** – Tela com a inserção do botão “Gráfico de superfície” para plotagem do gráfico dos diversos treinamentos da RNA.



This screenshot is identical to Figure 14 but includes an additional button labeled "Gráfico de superfície" located to the left of the "Redefinir" button.

Fonte: Elaboração do próprio autor.

### ***5.5 Treinamento da Rede Neural Artificial***

O treinamento de uma rede neural pode ser não supervisionado ou supervisionado. Enquanto o treinamento não supervisionado não requer uma saída desejada (i.e., a rede realiza um treinamento auto organizável levando em conta apenas os dados de entrada), o treinamento supervisionado considera a aprendizagem da rede a partir de dados de entrada e suas respectivas saídas desejadas (BRAGA et al., 2007). Em outras palavras, o treinamento supervisionado, que foi adotado neste trabalho, consiste em conhecer um alvo a ser acertado para que a rede consiga adaptar seus pesos de modo que, posteriormente, no processo de operação, conhecido também como diagnóstico da rede, possa se classificar ou estimar dados que não fizeram parte no processo de treinamento. Portanto, pode-se dizer que, a aprendizagem de uma RNA se dá pelo ajuste de seus pesos,  $W_i$ , durante o treinamento e em função de dados de entrada cujas saídas são conhecidas.

Para o treinamento da rede foram utilizadas seis entradas referente aos atributos físicos apresentados na Tabela 1, os quais apresentam as restrições de cada atributo que foram utilizados como as entradas da RNA e suas respectivas saídas desejadas.

Utilizou-se um total de 90 amostras para o treinamento, pois foram coletadas 252 amostras de solo, dividido por três camada, deram exatos 84 amostras por camada, 12 por


tratamento, sendo 07 tratamentos. Cada amostra é composta pelos atributos físicos como a densidade do solo, porosidade do solo (macroporosidade e microporosidade), resistência do solo à penetração, infiltração de água no solo e diâmetro médio ponderado (seis dados de entrada). Após clicar no botão “Treinar”, a RNA entrará em processo de treinamento, em seguida, as 90 amostras foram comparadas com as saídas desejadas conforme a Figura 16a. Observa-se que as curvas que representam as saídas obtidas ( $\mathbf{Y}_{ob}$ ) pela RNA e as saídas desejadas ( $\mathbf{Y}_{des}$ ) são muito similares, indicando que a rede foi bem treinada, sendo capaz de classificar solos, não apenas amostras de treinamento, mas também qualquer tipo de amostra. Durante o treinamento com o algoritmo retropropagação (*backpropagation*), a rede opera em uma sequência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado. Este resultado enfatiza o potencial de aplicação de RNAs, as quais podem atuar tanto como ferramentas de classificação, como também de previsão (CARVALHO, 2009). O erro quadrado médio do treinamento (do inglês *Mean Square Error* - MSE) calculado por meio da equação (3) ficou em torno de  $10^{-4}$  ( $8,6884 \times 10^{-004}$ ), conforme Figura 16(b), mostrando que os pesos  $\mathbf{W}_i$  foram todos ajustados para a rede desenvolvida.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\mathbf{Y}_{ob} - \mathbf{Y}_{des})^2 \quad (3)$$

Para validação da rede, a Figura 17 descreve a relação entre as variáveis  $\mathbf{Y}_{des}$  (saída desejada) e  $\mathbf{Y}_{ob}$  (saída obtida) com  $m = 10$ . Observa-se que o valor do R (grau de ajuste para o modelo) é de 0.99828, mostrando que aproximadamente 99% da variável


$Y_{ob}$  consegue ser explicada em relação a  $Y_{des}$ , ou seja, mais homogêneo são os dados (PAGANO e GAUVREAU, 2012) para o treinamento realizado em função da Tabela 1.

**Figura 16** - Processo de treinamento da rede para 90 amostras dos atributos físicos do solo, (a) Saída obtida versus Saída desejada, (b) Performance do treinamento da rede neural artificial (MSE).



**Fonte:** Elaboração do próprio autor.

**Figura 17** – Análise de regressão entre as variáveis de saída desejada ( $Y_{des}$ ) e saída obtida ( $Y_{ob}$ ).



**Fonte:** Elaboração do próprio autor.

A Tabela 13 apresenta os parâmetros do treinamento da rede. O tempo do processador utilizado para o treinamento da rede foi de 1,00 segundo em um equipamento “Intel Core i5 4570S de 8 GB de memória” para as 8 iterações, ou seja, na oitava iteração o valor do MSE especificado (0.001) foi atingido (0.00086884) fazendo com que o processo de treinamento fosse interrompido. As redes neurais que utilizam algoritmo retropropagação (*backpropagation*), assim como muitos outros tipos de redes neurais artificiais, podem ser vistas como “caixas pretas”, na qual quase não se sabe porque a rede chega a um determinado resultado, uma vez que os modelos não apresentam justificativas para suas respostas. Neste sentido, muitas pesquisas vêm sendo realizadas visando a extração de conhecimento de redes neurais artificiais, e na criação de procedimentos explicativos, onde se tenta justificar o comportamento da rede em determinadas situações (ICMC, 2017). Neste contexto, pode-se notar que sempre um valor diferente será obtido para cada vez que a rede for novamente treinada. A Figura 18(a) apresenta as saídas dos resultados dos dez treinamentos, mostrando a similaridade entre os treinamentos. O gráfico de superfície na Figura 18(b) também apresenta essa similaridade, mas sempre um resultado diferente do outro. Os valores especificados para o treinamento foram escolhidos após vários testes realizados, outros valores poderiam ser utilizados.

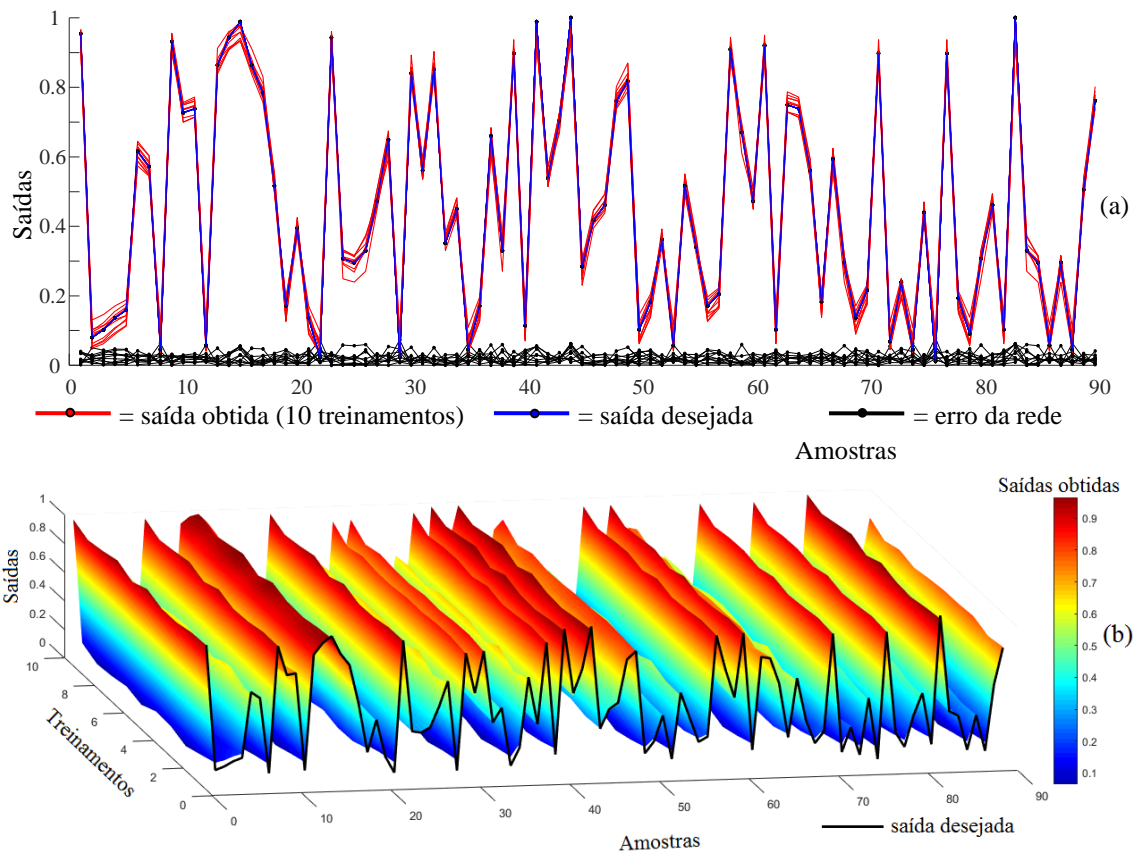
**Tabela 13** - Valores especificados para o treinamento da rede.

	Valor especificado na rede	Melhor valor de treinamento atingido
Iterações	100	8
Tempo	20	1 seg
Performance (MSE)	0.001	*0.00086884

\* critério atingido

Fonte: Elaboração do próprio autor.

**Figura 18** - Processo de dez treinamentos da rede para as 90 amostras referentes aos atributos físicos do solo, (a) saída obtida (10 treinamentos) versus Saída desejada, (b) gráfico de superfície para os dez treinamentos.



Fonte: Elaboração do próprio autor.

A Tabela 14 a seguir apresenta resultados para os dez treinamentos realizados pela RNA, para todos os treinamentos, o critério atingido foi a performance (MSE), sempre abaixo do seu valor especificado de 0.001 com tempo de treinamento rápido, abaixo ou igual a um segundo e com o número de iterações em média de 4 iterações, bem abaixo do seu valor especificado de 100 iterações.

**Tabela 14** - Resultados para os dez treinamentos da rede.

Treinamentos	Iterações	Tempo (s)	Performance (MSE)
1	4	< 1	*0.000256
2	2	1	*0.000687
3	5	1	*0.000672
4	3	< 1	*0.000320
5	2	1	*0.000731
6	3	1	*0.000605
7	4	< 1	*0.000353
8	5	1	*0.000695
9	5	< 1	*0.000497
10	4	< 1	*0.000435

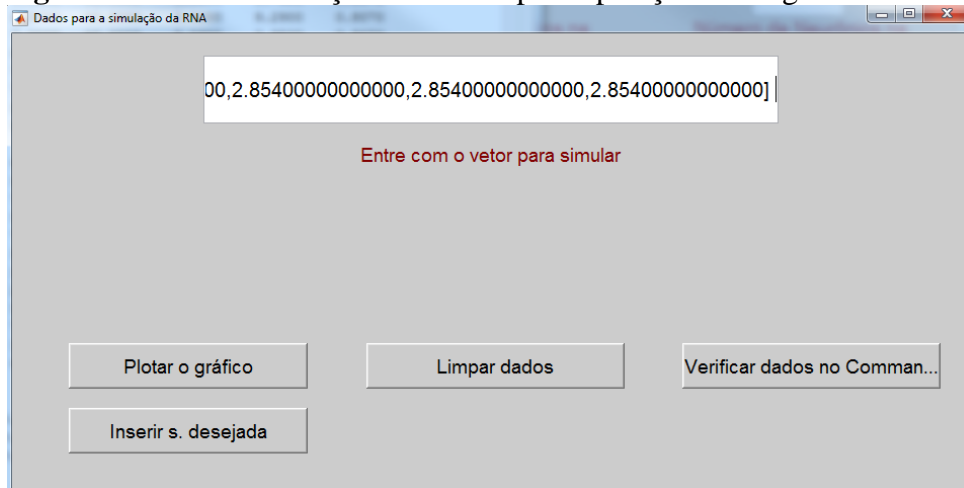
\* critério atingido

**Fonte:** Elaboração do próprio autor.

#### 5.5.1 Operação (Diagnóstico) da Rede Neural Artificial

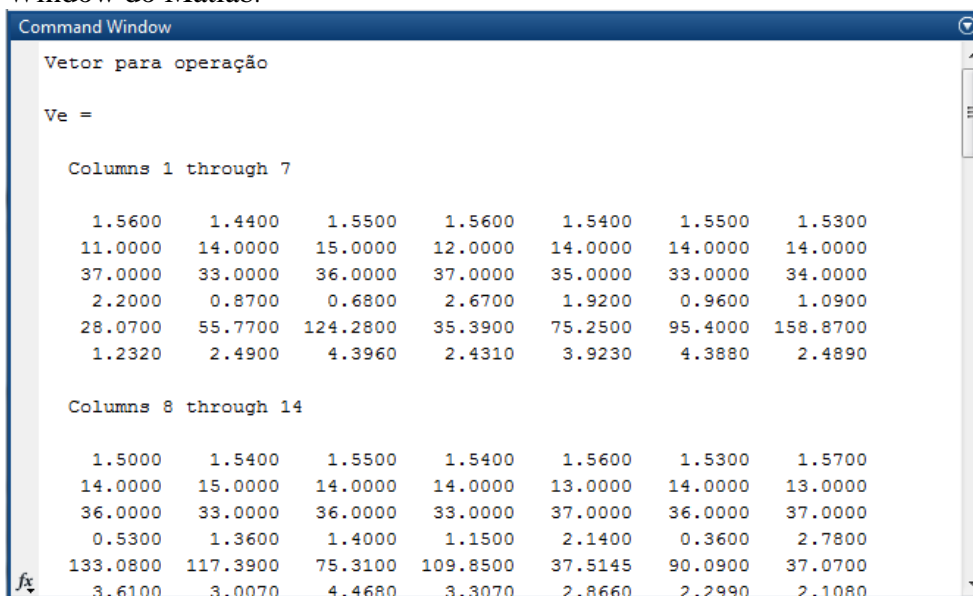
A tela da Figura 19 a seguir, obtida clicando no botão “Simular” da Figura 14 representa a tela de inserção dos dados que não fizeram parte do treinamento, neste caso, os dados colhidos do experimento. Esses dados referentes aos atributos físicos do solo podem ser verificados no *Command Window* do Matlab, clicando no botão “Verificar dados no *Command Window*” gerará a tela conforme Figura 20. Caso o usuário deseje limpar os dados, basta clicar no botão “Limpar dados”.

**Figura 19** - Tela de inserção dos dados para operação ou diagnóstico da RNA.



Fonte: Elaboração do próprio autor.

**Figura 20** - Tela para visualização dos dados para fase de operação no Command Window do Matlab.



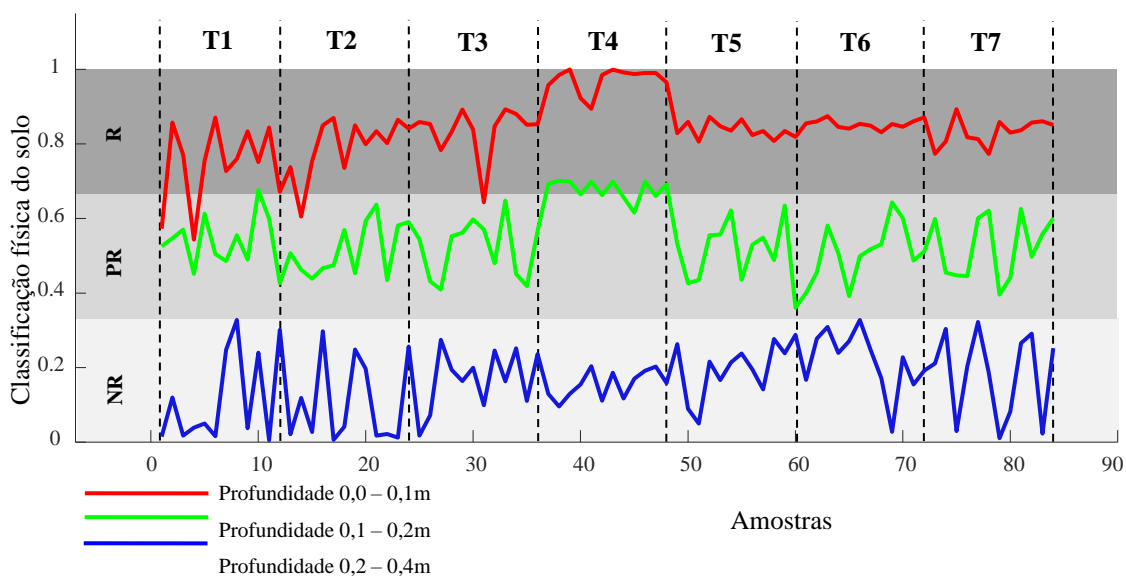
Fonte: Elaboração do próprio autor.

Clicando no botão “Plotar o gráfico” da Figura 19, os resultados da fase de simulação da RNA serão plotados; a rede já treinada, com seus pesos ajustados, diagnosticou uma interação dos atributos para os valores dos dados do experimento. A Figura 21 apresenta os resultados da fase de operação da rede para as 252 amostras de solos referentes aos atributos físicos que não fizeram parte do treinamento, as quais foram obtidas do experimento apresentado no **item 4.1**. As 252 amostras foram subdivididas conforme as três profundidades e sete tratamentos, ficando com 84 amostras para cada

profundidade e 36 amostras para cada tratamento (doze para cada profundidade) conforme distribuído na Figura 21.

Com MSE (erro quadrático médio) de  $8,6884 \times 10^{-004}$  para o treinamento, ou seja, todos os pesos ajustados abaixo do limite de erro que foi estipulado nos parâmetros de treinamento que estão na Figura 14 e 15, a rede está pronta para classificação das 252 amostras. Dos resultados apresentados na Figura 21, pode-se observar que nas profundidades 0,0 – 0,1 m e 0,1 – 0,2 m o tratamento T4 apresentou uma pequena vantagem em relação aos demais, principalmente na profundidade 0,1 – 0,2 m, isso se dá pelo fato da RNA entregar de uma forma geral, a somatória dos atributos físicos, e não apenas um em particular, além disso, a RNA indicou sete amostras na faixa de solo recuperado (R). No tratamento T1, na profundidade 0,0 – 0,1 m, duas amostras ficaram na faixa de solo parcialmente recuperado (PR) e nos tratamentos T2 e T3, uma amostra cada na faixa de solo parcialmente recuperado (PR).

**Figura 21** - Resultados da classificação física do solo pela RNA em relação as profundidades e tratamentos.



**Fonte:** Elaboração do próprio autor.

T1- Testemunha Capim Urochloa (TC);

T2- Urochloa + estilosantes com dessecação parcial com 1,5 L ha<sup>-1</sup> de glifosato (DP);

T3- Urochloa + estilosantes com dessecação total com 3,0 L ha<sup>-1</sup> de glifosato (DT);

T4- Urochloa + estilosantes com plantio direto (PD);

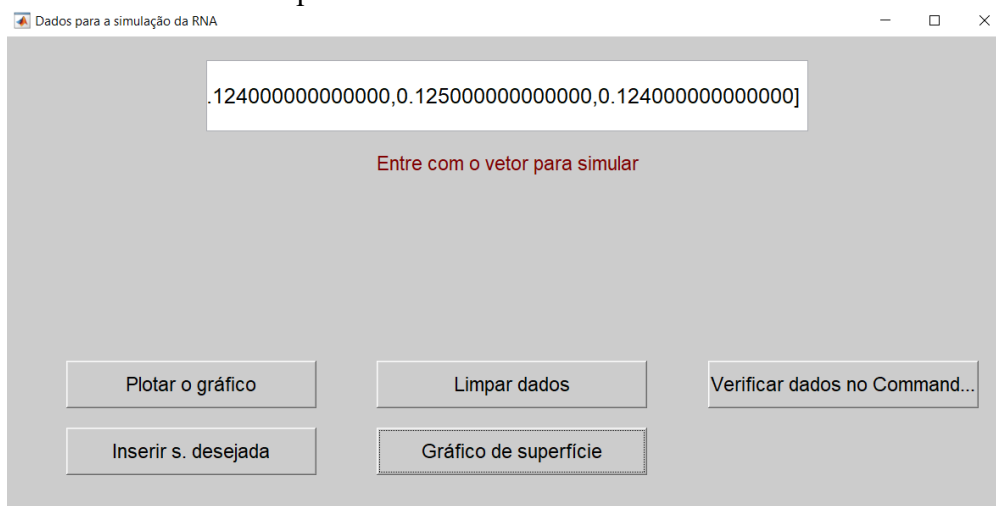
T5- Urochloa + estilosantes com escarificação do solo (E),

T6- Urochloa + estilosantes com gradagem rome (G) e

T7- Urochloa + estilosantes com aração + gradagem (AG).

Clicando no botão “Plotar o gráfico” da Figura 22, o botão “Gráfico de superfície” surge na tela conforme Figura 23. Ao clicar no botão é possível ver o gráfico de superfície dos dados inseridos para operação da RNA.

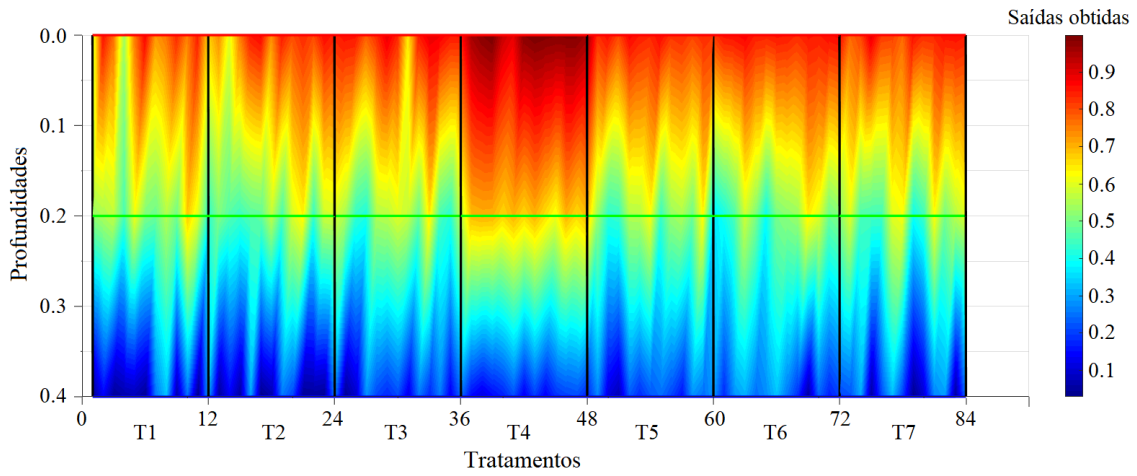
**Figura 22** - Tela de inserção dos dados para operação ou diagnóstico da RNA com o botão “Gráfico de superfície”.




**Fonte:** Elaboração do próprio projeto.

Na Figura 23(a), é apresentado os resultados através do gráfico de superfície com vista de cima. Neste caso, pode-se observar, toda a trajetória de solução em função das profundidades e tratamentos (cores quentes, solo recuperado (R) e parcialmente recuperado (PR) e cores frias, solo não recuperado (NR)). Na Figura 23(b) é apresentado o gráfico de superfície com vista lateral em função das profundidades e tratamentos. A Figura 24 representa uma tela de inserção de dados da saída desejada caso o usuário pretenda comparar a saída da RNA obtida na fase de operação com uma saída desejada. Neste trabalho não houve uma saída desejada, pelo fato de os dados usados para treinamento da rede já serem os dados ideais para classificação do solo conforme seus dados físicos, mas caso eu estivesse comparando com algum valor já determinado, poderia adotar esse valor como a saída desejada e a comparação com o que a RNA gerar com os dados imputados.

**Figura 23** - Resultados da classificação física do solo pela RNA, (a) gráfico de superfície visto de cima para cada tratamento e profundidade analisada, (b) gráfico de superfície, vista lateral.



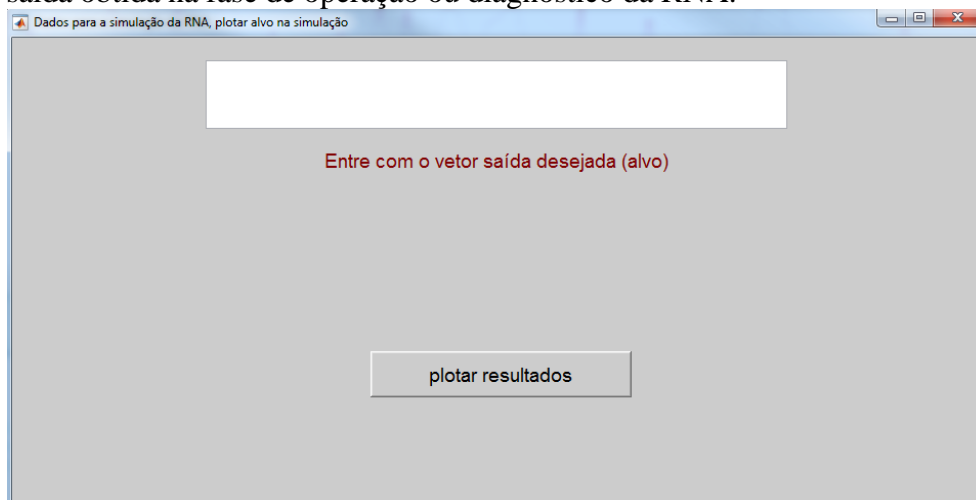
(a)



(b)

**Fonte:** Elaboração do próprio autor.

**Figura 24** - Tela para inserção de dados de saída desejada para comparação com a saída obtida na fase de operação ou diagnóstico da RNA.



**Fonte:** Elaboração do próprio autor.

## **6. CONCLUSÕES**

Analisando estatisticamente os dados dos atributos físicos do solo verificou uma homogeneidade dos tratamentos estudados. O DMP (Diámetro médio ponderado) apresentou diferença estatística com resultado com valor médio superior apresentado pelo tratamento T4 (plantio direto). A resistência à penetração também apresentou diferença na última camada estudada, no segundo ano do experimento. Nos demais atributos estudados, não houve diferença significativa.

Utilizando as RNAs, verificou que o tratamento T4 (plantio direto) sobressai em uma média geral de todos os atributos do solo estudado. Isso se dá pela alta sensibilidade e robustez da rede.

## REFERÊNCIAS

- ANGERS, D.A.; MEHUYS, G.R. *Aggregate stability to water*. In: CARTER, M.R. *Soil sampling and methods of analysis*. **Canadian Society of Soil Science**. Lewis Publishers, Boca Raton, Florida. p.529-539. 2000.
- ALVES, M. C. Recuperação do subsolo de um Latossolo Vermelho usado para terrapleno e fundação da usina hidrelétrica de Ilha Solteira - SP. 2001. 83 f. Tese (Livre Docência em Solos) - **Faculdade de Engenharia, Universidade Estadual Paulista**. Ilha Solteira. 2001.
- ALVES, M. C.; SOUZA, Z. M. Recuperação de área degradada por construção de hidroelétrica com adubação verde e corretivo. **Revista Brasileira de Ciência do Solo**, v.32, p.2505-2516, 2008.
- ARRUDA, O. G.; ALVES, M. C.; SANTOS BATISTA BONINI, CAROLINA DOS; MARCHINI, DÉBORA DE CÁSSIA. Atributos físicos de um Latossolo degradado tratado com bio sólido há cinco anos. **Científica (jaboticabal. Online)**, v. 41, p. 73-81-81, 2013.
- BALA, B. K.; ASHRAF, M. A.; UDDIN, M. A.; JANJAI, S. *Experimental and neural network prediction of the performance of a solar tunnel drier for a solar drying jack fruit bulbs and leather*. **J. Food Proc**, v. 28, p.552–566. 2005.
- BISHOP, C. M. *Pattern Recognition and Machine Learning, Information Science and Statistics*. **Springer-Verlag** New York. 2006.
- BONINI, C.S.B.; ALVES, M. C. Qualidade física de um latossolo vermelho em recuperação há dezessete anos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16. n. 4 p.329-336, 2012.
- BONINI, C.S.B.; ALVES, M.C.; MONTANARI, R. Recuperação da estrutura de um Latossolo vermelho degradado utilizando lodo de esgoto. **Agrária (Recife. Online)**, v. 10, p. 34-42, 2015.
- BONINI, C. S. B.; HEINRICHS, R. ; COSTA, N. R. ; MEIRELLES, G. C. . Estado da arte e fatores intrínsecos na física de solos no manejo de pastagens. In: Reges Heinrichs; Cecilio Viegas Soares Filho; Carolina dos Santos Batista Bonini. (Org.). **Simpósio de Adubação e Manejo de Pastagens / Simpósio de Produção Animal a Pasto**. 1ed.São Paulo: Cultura Academica, 2017, v. 1, p. 58-75.
- BONINI NETO, A.; BONINI, C. S. B.; BISI, B. S.; REIS, A. R.; COLETTA, L. F. S. *Artificial Neural Network for Classification and Analysis of Degraded Soils*. **Revista IEEE América Latina**, v. 15, p. 503-509, 2017.
- BONINI NETO A., PUTTI F. F., SANT'ANA R. C. G., BONINI JUNIOR N. A. *Descriptive Statistics for Data Analysis (Soy Production) via Iterative Program*. **Brazilian Journal of Biosystems Engineering**. v. 6, n. 2, p. 61-70, 2012.

- BRAGA A. DE P., CARVALHO A. P. DE L. F. DE, LUDERMIR T. B. Redes neurais artificiais: teoria e aplicações. 2. ed. Rio de Janeiro: **LTC** Editora, 2007.
- BRANDÃO, V.S.; CECÍLIO, R.A.; PRUSKI, F.F.; SILVA, D.D. Infiltração da água no solo. 3. ed. Viçosa: **UFV**, 2006. 120 p.
- BUCENE L. C., RODRIGUES L. H. A. Utilização das Redes Neurais Artificiais para avaliação da produtividade do solo, visando classificação de terras para irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. VIII, n. 2-3, p. 326-329, 2004.
- CARVALHO, André Ponce de Leon F. de. **Redes Neurais Artificiais**. 2009. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/index.htm>. Acesso em: 12 jan. 2020.
- CARVALHO, M.A.; RUIZ, H.A.; COSTA, L.M.; PASSOS, R.R.; ARAUJO, C.A.S. Composição granulométrica, densidade e porosidade de agregados de Latossolo Vermelho sob duas coberturas do solo. **Revista Brasileira Engenharia Agrícola Ambiental**, v.18, n.10, p.1010–1016, 2014.
- CERVI, E. U. A. A revolução da palha. *Revista Plantio Direto*, v.73, p. 8-12. 2003.
- SAUERESSIG, Denise. Sistema Plantio Direto: os pilares do equilíbrio. **A Granja**, Porto Alegre, v. 845, p.1-1, 21 jun. 2019. Mensal. Disponível em: <https://febrapdp.org.br/noticias/680/sistema-plantio-direto-os-pilares-do-equilibrio>. Acesso em: 12 jan. 2020.
- DE SOUZA, A. V.; BONINI NETO, A.; PIAZENTIN, J. C.; DAINESE JUNIOR, B. J.; GOMES, E. P.; BONINI, C. S. B.; PUTTI, F. F. *Artificial neural network modelling in the prediction of bananas' harvest*. **SCIENTIA HORTICULTURAE**, v. 257, p. 108724, 2019.
- DORAN, J.W.; PARKIN, T.B. *Defining and assessing soil quality*. In: DORAN, J.W. et al. (Eds) *Defining soil quality for a sustainable environment*. **Madison**: ASA / SSSA, p.3-21, 1994.
- DIAMANTOPOULOU, M. J. *Artificial neural networks as an alternative tool in pine bark volume estimation*. **Comp. Elect. Agric.** v.48, p.235–244. 2005.
- ELIASMITH C., ANDERSON C. H. *Neural engineering: Computation, representation, and dynamics in neurobiological systems*. **MIT Press**, Cambridge, MA, 2003.
- GABRIEL FILHO L. R. A., PUTTI F. F., CREMASCO, C. P., BORDIN D., CHACUR M. G. M., GABRIEL L. R. A. *Software to Assess Beef Cattle Body Mass Through the Fuzzy Body Mass Index*. **Engenharia Agrícola (Online)**, v. 36, p.179-193, 2016.
- GASPARINI R. T. Desenvolvimento de um Software em Ambiente Matlab para Simulação de Campo Ultrassônico. Dissertação apresentada à **UNICAMP**. 107p., 2012.
- GÓES D. B. R., DA SILVA G. M., GUEDES D. L., SILVA O. F. Desenvolvimento de Interface em MATLAB para Aprendizado e Comparação de Métodos Numéricos. **XXXV CNMAC - Brazilian Society of Applied and Computational Mathematics**. v.3, n. 1, 2015.

GUERRA, A.J.T.; CUNHA, S.B. **Geomorfologia e meio ambiente**. 4.ed. Rio de Janeiro: Bertrand Brasil, 394p., 2003.

HAYKIN S. *Neural networks: a comprehensive foundation*. 2. ed. **Tsinghua University Press**. 2001.

IBAMA – Instituto Brasileiro do Meio Ambiente. Manual de Recuperação de áreas degradadas pela mineração. Brasília: **IBAMA**, 96p.,1990.

JIANG, S.D.; JIANG, D.; YANG, X.; CLINTON, N.; WANG, N. *An artificial neural network model for estimating crop yields using remotely sensed information*. **Int. J. Remote Sens.** v.25, p.1723–1732. 2004.

KITAMURA, A. E.; ALVES, M. C.; SUZUKI, L. G. A. S.; GONZALEZ, A. P. Recuperação de um solo degradado com aplicação de adubos verdes e lodo de esgoto. **Revista Brasileira de Ciência do Solo**, v.32, p.405-416, 2008.

KLEIN, V. A. **Física do solo**.3. ed. Passo Fundo: UPF, 263p., 2014.

KOVACS Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações: Um texto básico**. 4ª ed. Editora Livraria da Física. 177 p., 2006.

KLUTHCOUSKI, J. Efeito de manejo em alguns atributos de um Latossolo roxo sob cerrado e nas características produtivas de milho, soja, arroz e feijão, após oito anos de plantio direto. Tese de Doutorado. **Universidade de São Paulo-ESALQ**, Piracicaba. 179 p., 1998.

LEAL NETO V. Desenvolvimento de uma Interface Gráfica de Usuário para Modelos Computacionais de Exposição Externa. Dissertação apresentada à **Universidade Federal de Pernambuco**. 81p., 2007.

MARCHÃO, R.L.; BALBINO, L.C.; SILVA, E.M. da; SANTOS JUNIOR, J. de D.G. dos; SÁ, M.A.C. de; VILELA, L.; BECQUER, T. Qualidade física de um Latossolo Vermelho sob sistemas de integração lavoura-pecuária no Cerrado. **Pesquisa Agropecuária Brasileira**, v.42, p.873-882, 2007.

MATHWORKS. MATLAB (**MATrix LABoratory**) Disponível em: <<http://www.mathworks.com>>. Acesso em 02. fev. 2020.

MOVAGHARNEJAD, K.; NIKZAD, M. *Modelling of tomato drying using artificial neural network*. **Comp. Elect. Agric.** v.59, p.78–85. 2007.

PAGANO, M.; GAUVREAU, K. Princípios de Bioestatística. São Paulo: **Cengage Learning**, 506p., 2012.

PROTO A. B. Interface Gráfica para o Planejamento da Expansão da Transmissão de Energia Elétrica. Dissertação apresentada à **UNESP – Campus de Ilha Solteira**. 102p., 2009.

REIS, A.; ZAMBONIN, R.M.; NAKAZONO, E.M. Recuperação de áreas florestais degradadas utilizando a sucessão e as interações planta-animal. São Paulo: **Conselho**

**Nacional da Reserva da Biosfera da mata atlântica/Governo do Estado de São Paulo**, 42p., 1999. (Série Cadernos da Biosfera, 14).

RIBEIRO, M.F.S., F.S. NETO & J.A.B. SANTOS. Plantio Direto na pequena propriedade. **Informe Agropecuário**, v.22, p.100-108. 2001.

ROVEDDER, A. P. M & ELTZ, F. L. F Desenvolvimento de *Pinus elliotti* e do *Eucalyptus tereticornis* consorciado com plantas de cobertura em solos degradados por arenização. In: **Ciência Rural**. Santa Maria. v. 38, n. 1, 2008.

RUMMELHART D. E., MCCLELLAND J. L. PDP *Research Group. Parallel Distributed Processing - Explorations in the Microstructure of Cognition: Foundations. A Bradford Book - The MIT Press*. v. 1. 1986.

SALTON, J.C.; MIELNICZUK, J.; BAYER, C.; BOENI, M.; Paulo Cesar Conceição, P.C.; Carvalho, F.A.; Macedo, M.C.M; Broch, D. L. Agregação e estabilidade de agregados do solo em sistemas agropecuários em Mato Grosso do Sul. **Revista Brasileira de Ciência do Solo**, v.32, p.11-21., 2008.

SANTOS, H. G.; JOCOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBREARAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; FILHO, J. C. A; OLIVEIRA, J. B; CUNHA, T. J. F. Sistema Brasileiro de Classificação de Solos. 5.ed. rev. ampli. **Rio de Janeiro: EMBRAPA**. 531p., 2018.

SAVIN, I.Y.; STATHAKIS, D.; NEGRE, T.; ISAEV, V.A. *Prediction of crop yields with the use of neural networks*. **Russian Agric. Sci**. v.33, p.361–363, 2007.

SILVA, V. R.; REINERT, D.; REICHERT, J. M. Densidade do solo, atributos químicos e sistema radicular do milho afetados pelo pastejo e manejo do solo. **Revista Brasileira de Ciência do Solo**. Viçosa, MG, v. 24, n. 1, p.191-199, 2000.

SILVA L. H. S., MISHINA K. D. V., FARIAS C. T. T., RODRIGUES M. C., RIBEIRO I. S. Desenvolvimento de uma Interface Gráfica no Ambiente *Matlab* para Avaliação do Risco em Oleodutos *On-Shore*. **VI Congresso Nacional De Engenharia Mecânica**. 2010.

SOUZA. Z. M.; ALVES. M. C. Propriedades químicas de um LATOSSOLO VERMELHO distrófico de cerrado sob diferentes usos e manejo. **Revista Brasileira de Ciência do Solo**. v.27, p.133-139, 2003.

TEIXEIRA A. S. B. Desenvolvimento de uma Interface Gráfica para Classificadores de Imagem. Dissertação apresentada ao **Instituto Politécnico de Castelo Branco**. 74p, 2011.

TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. Manual de Métodos de Análise de Solo. 3. ed. rev. ampl. Brasília: **EMBRAPA**. 574p, 2017.

UNO, Y.; PRASHER, S.O.; LACROIX, R.; GOEL, P.K.; KARIMI, Y.; VIAU, A.; PATEL, R.M. *Artificial neural networks to predict corn yield from compact airborne spectrographic imager data*. **Comp. Elect. Agric**. v.47, p.149–161, 2005.

WASSERMAN, P.D. *Neural computing: theory and practice*. New York: **van Nostrand Reinhold**. 1989.

ZHANG, R. *Determination of soil sorptivity and hydraulic conductivity from the disk infiltrometer*. *Soil Science Society of American Journal*, v.61, p.1024-1030, 1997.

ZHANG, W.; BAI, X.C.; LIU, G. *Neural network modeling of ecosystems: a case study on cabbage growth system*. *Ecol. Model* v.201, p.3-4. 2007.

## ANEXO

Comandos da interface gráfica do programa desenvolvido no Matlab.

### 1. Tela principal

```
clc
clear all
clear
home
clear global

psatver = '1.0.0';
psatdate = date;
disp(['Host:          Matlab ',version])
disp(['Session:      ', datestr(now,0)])
disp(['Usage:        Graphical User Interface'])

clear

Cores = struct('color01',[0.800 0.800 0.800], ...
              'color02',[0.753 0.753 0.753], ...
              'color03',[0.502 0.502 0.502], ...
              'color04',[1.000 1.000 1.000], ...
              'color05',[0.000 0.000 0.002], ...
              'color06',[1.000 1.000 0.502], ...
              'color07',[0.502 0.000 0.000], ...
              'color08',[0.750 0.390 0.503], ...
              'color09',[0.300 0.300 0.300], ...
              'color10',[1.000 1.000 1.000], ...
              'color11',[0.920 0.920 0.920], ...
              'color12',[0.831 0.815 0.784], ...
              'color13',[1 0 0], ...
              'color14',[0 1 0], ...
              'color15',[0 1 1], ...
              'font01','Courier','hdl',zeros(18,1));

h0 = figure('Color',Cores.color15, ...
           'Units','normalized', ...
           'MenuBar','none', ...      % tela principal
           'NumberTitle','off', ...
           'PaperPosition',[1 1 1 1], ...
           'PaperType','A4', ...
           'PaperUnits','points', ...
           'Position',[0.18 0.2 0.6 0.6], ...
           'Resize','on', ...
           'name','Tela Inicial ');

% replace with an image of your choice
%img = imread('fig_rna.png');
%img = imread('fig_rna.jpg');
img = imread('fig_rna2.png');
imagesc(img);
```

```

pause(3)
%vdados = xlsread('pasta2');
h1 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'Position',[0.35 0.018 0.36 0.05], ...
    'String','REDES NEURAIS ARTIFICIAIS (RNA)', ...
    'FontSize',14,...
    'Callback','close,metodo',...
    'Tag','edit1');

```

## 2. Segunda tela do programa (inserção dos dados)

```

% Segunda tela do programa (tela 2)

ponto=1;

h0 = figure('Color',Cores.color01, ...
    'Units','normalized', ...
    'MenuBar','none', ... % tela principal
    'NumberTitle','off', ...
    'PaperPosition',[18 18 57 4], ...
    'PaperType','A4', ...
    'PaperUnits','points', ...
    'Position',sizefig(0.9248,0.5876), ...
    'Resize','on', ...
    'name','Tela 2 - Dados de entrada e de saída desejada da RNA');

h1 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color07,...
    'HorizontalAlignment','Center', ...
    'Position',[0.01 0.68 0.4 0.08], ...
    'String','Entre com o vetor (dados de entrada)', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

vet1 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color04,...
    'HorizontalAlignment','left',...
    'Position',[ 0.06 0.8 0.3 0.15 ], ...
    'ForegroundColor',Cores.color05,...
    'String','', ...
    'FontSize',15,...
    'HorizontalAlignment','center',...
    'Style','edit', ...
    'Tag','edit1');

h1 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...

```

```

        'ForegroundColor',Cores.color07,...
        'HorizontalAlignment','Center', ...
        'Position',[0.59 0.68 0.4 0.1], ...
        'String','Entre com o vetor (dados da saída desejada)',
...
        'FontSize',14,...
        'Style','text', ...
        'Tag','StaticText1');

vet2 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color04,...
    'HorizontalAlignment','left',...
    'Position',[ 0.64 0.8 0.3 0.15 ], ...
    'ForegroundColor',Cores.color05,...
    'String','', ...
    'FontSize',15,...
    'HorizontalAlignment','center',...
    'Style','edit', ...
    'Tag','edit1');

h1 = uicontrol('Parent',h0, ...
'Units','normalized', ...
'BackgroundColor',Cores.color01, ...
'Position',[0.1 0.22 0.2 0.1], ...
'String','Criar a RNA', ...
'FontSize',14,...
'Callback','teste1',...
'Tag','edit1');

h1 = uicontrol('Parent',h0, ...
'Units','normalized', ...
'BackgroundColor',Cores.color01, ...
'Position',[0.4 0.22 0.2 0.1], ...
'String','Limpar dados', ...
'FontSize',14,...
'Callback','clc ,teste2',...
'Tag','edit1');

h1 = uicontrol('Parent',h0, ...
'Units','normalized', ...
'BackgroundColor',Cores.color01, ...
'Position',[0.7 0.22 0.2 0.1], ...
'String','Verificar dados no Command Window', ...
'FontSize',14,...
'Callback','teste3',...
'Tag','edit1');

```

### 3. Tela onde a RNA é criada

```

jo=1;
for jo=1
clc
vent = str2num (get(vet1,'String'));
vsaid= str2num (get(vet2,'String'));

```

```

ordx1=size(vent);
ordx11=ordx1(1);
ordx12=ordx1(2);
ordy1=size(vsaid);
ordy11=ordy1(1);
ordy12=ordy1(2);

%Verificando se os vetores possuem elemntos e são iguais (número de
%amostras

if ordx11==0 & ordy11==0
    h1 = uicontrol('Parent',h0, ...
        'Units','normalized', ...
        'BackgroundColor',Cores.color01, ...
        'ForegroundColor',Cores.color13,...
        'HorizontalAlignment','Center', ...
        'Position',[0.0 0.39 1 0.27], ...
        'String','!!! Os Vetores de entrada e de saída desejada
não possuem elementos, entre com os dados !!!', ...
        'FontSize',14,...
        'Style','text', ...
        'Tag','StaticText1');
    break
end

if ordx11==0
    h1 = uicontrol('Parent',h0, ...
        'Units','normalized', ...
        'BackgroundColor',Cores.color01, ...
        'ForegroundColor',Cores.color13,...
        'HorizontalAlignment','Center', ...
        'Position',[0.0 0.39 1 0.27], ...
        'String','!!! O Vetor de entrada não possui elementos,
entre com os dados de entrada !!!', ...
        'FontSize',14,...
        'Style','text', ...
        'Tag','StaticText1');
    break
end

if ordy11==0
    h1 = uicontrol('Parent',h0, ...
        'Units','normalized', ...
        'BackgroundColor',Cores.color01, ...
        'ForegroundColor',Cores.color13,...
        'HorizontalAlignment','Center', ...
        'Position',[0.0 0.39 1 0.27], ...
        'String','!!! O Vetor de saída desejada não possui
elementos, entre com os dados de saída !!!', ...
        'FontSize',14,...
        'Style','text', ...
        'Tag','StaticText1');
    break
end

if ordx12 ~= ordy12
    h1 = uicontrol('Parent',h0, ...
        'Units','normalized', ...
        'BackgroundColor',Cores.color01, ...
        'ForegroundColor',Cores.color13,...
        'HorizontalAlignment','Center', ...
        'Position',[0.0 0.39 1 0.27], ...

```

```

        'String','!!! Os Vetores de entrada e de saída desejada
devem ser iguais no número de amostras !!!', ...
        'FontSize',14,...
        'Style','text', ...
        'Tag','StaticText1');
    break
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Cobrir a faixa de erro

h1 = uicontrol('Parent',h0, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color13,...
    'HorizontalAlignment','Center', ...
    'Position',[0.0 0.39 1 0.27], ...
    'String','', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

h00 = figure('Color',Cores.color01, ...
    'Units','normalized', ...
    'MenuBar','none', ...
    'NumberTitle','off', ...
    'PaperPosition',[18 18 57 4], ...
    'PaperType','A4', ...
    'PaperUnits','points', ...
    'Position',sizefig(0.9248,0.4876), ...
    'Resize','on', ...
    'name','Definindo a RNA');
% camada de entrda
h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color08,...
    'HorizontalAlignment','Center', ...
    'Position',[0.015 0.18 0.3 0.15], ...
    'String','Número de Neurônios na Camada de Entrada', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color08,...
    'HorizontalAlignment','Center', ...
    'Position',[0.15 0.74 0.1 0.09], ...
    'String','Número de Amostras', ...
    'FontSize',10,...
    'Style','text', ...
    'Tag','StaticText1');
h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...

```

```

        'BackgroundColor',Cores.color04,...
        'HorizontalAlignment','left',...
        'Position',[ 0.17 0.69 0.06 0.05], ...
        'ForegroundColor',Cores.color13,...
        'String',ordx12, ...
        'Enable','off',...
        'FontSize',10,...
        'HorizontalAlignment','center',...
        'Style','edit', ...
        'Tag','edit1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color06,...
    'HorizontalAlignment','Center', ...
    'Position',[0.20 0.62 0.25 0.08], ...
    'String','-----', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color04,...
    'HorizontalAlignment','left',...
    'Position',[ 0.13 0.62 0.10 0.08], ...
    'ForegroundColor',Cores.color13,...
    'String',ordx11, ...
    'Enable','off',...
    'FontSize',15,...
    'HorizontalAlignment','center',...
    'Style','edit', ...
    'Tag','edit1');
% camada intermediária

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color07,...
    'HorizontalAlignment','Center', ...
    'Position',[0.345 0.18 0.3 0.15], ...
    'String','Número de Camadas Intermediárias, 1 ou 2?', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','points', ...
    'BackgroundColor',Cores.color01, ...
    'Position',[ 299.25 200.25 96 15 ], ...
    'FontSize',14,...
    'Enable','on',...
    'String','1 Camada', ...
    'Style','radiobutton', ...
    'Callback','close; RNA1c ', ...
    'Tag','Radiobutton2');

h11 = uicontrol('Parent',h00, ...
    'Units','points', ...

```

```

    'BackgroundColor',Cores.color01, ...
    'Position',[ 299.25 160.25 96 15 ], ...
    'FontSize',14,...
    'Enable','on',...
    'String','2 Camadas', ...
    'Style','radiobutton', ...
    'Callback','close; RNA2c ', ...
    'Tag','Radiobutton2');

% camada de saída

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color08,...
    'HorizontalAlignment','Center', ...
    'Position',[0.7 0.18 0.27 0.15], ...
    'String','Número de Neurônios na Camada de Saída', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color08,...
    'HorizontalAlignment','Center', ...
    'Position',[0.8 0.74 0.1 0.09], ...
    'String','Número de Amostras', ...
    'FontSize',10,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color04,...
    'HorizontalAlignment','left',...
    'Position',[ 0.82 0.69 0.06 0.05], ...
    'ForegroundColor',Cores.color13,...
    'String',ordy12, ...
    'Enable','off',...
    'FontSize',10,...
    'HorizontalAlignment','center',...
    'Style','edit', ...
    'Tag','edit1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color01, ...
    'ForegroundColor',Cores.color06,...
    'HorizontalAlignment','Center', ...
    'Position',[0.54 0.62 0.25 0.08], ...
    'String','-----', ...
    'FontSize',14,...
    'Style','text', ...
    'Tag','StaticText1');

h11 = uicontrol('Parent',h00, ...
    'Units','normalized', ...
    'BackgroundColor',Cores.color04,...
    'HorizontalAlignment','left',...

```

```
        'Position',[ 0.78 0.62 0.10 0.08], ...
        'ForegroundColor',Cores.color13,...
        'String',ordy11, ...
        'Enable','off',...
        'FontSize',15,...
        'HorizontalAlignment','center',...
        'Style','edit', ...
        'Tag','edit1');
end %for
```