

UNIVERSIDADE ESTADUAL DE GOIÁS
CAMPUS CENTRAL – SEDE: ANÁPOLIS – CET
MESTRADO *STRICTO SENSU* EM ENGENHARIA AGRÍCOLA

**REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DAS UMIDADES NA
CAPACIDADE DE CAMPO E NO PONTO DE MURCHIA PERMANENTE EM
SOLOS DO CERRADO DO CENTRO GOIANO**

Radson Murilo Veloso Silva Júnior

ANÁPOLIS – GO
SETEMBRO 2020

**REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DAS UMIDADES NA
CAPACIDADE DE CAMPO E NO PONTO DE MURCHA PERMANENTE EM
SOLOS DO CERRADO DO CENTRO GOIANO**

RADSON MURILO VELOSO SILVA JÚNIOR

Orientador: Prof. Dr. Francisco Ramos de Melo
Co-orientador: Prof^a. Dra. Sandra Máscimo da Costa e Silva

Dissertação apresentada à Universidade Estadual de Goiás – UEG, Campus Central – Sede: Anápolis – CET como parte das exigências do Programa de Pós-graduação *Stricto sensu* em Engenharia Agrícola – Engenharia de Sistemas Agroindustriais, para obtenção do título de MESTRE.

Anápolis
Goiás
2020

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

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

Dados do autor (a)

Nome Completo: **Radson Murilo Veloso Silva Júnior**
E-mail: **radson_murilo@hotmail.com**

Dados do trabalho

Título: **REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DAS UNIDADES NA CAPACIDADE DE CAMPO E NO PONTO DE MURCHA PERMANENTE EM SOLOS DO CERRADO DO CENTRO GOIANO**

Tipo

() Tese (X) Dissertação

Curso/Programa: **Programa de Pós-Graduação Mestrado Acadêmico em Engenharia Agrícola**

Concorda com a liberação do documento [X] SIM [] NÃO¹

Anápolis, 30/09/2020

Local

Data



Assinatura do autor (a)



Assinatura do orientador (a)

¹ Casos de impedimento:

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

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

SS|586r Silva Júnior, Radson Murilo Veloso

Redes neurais artificiais aplicadas na predição das umidades na capacidade de campo e no ponto de murcha permanente em solos do Cerrado do Centro Goiano / Radson Murilo Veloso Silva Júnior; orientador Francisco Ramos de Melo; co-orientador Sandra Máscimo da Costa e Silva. --Anápolis, 2020.

157p.

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

1. Limites de água no solo. 2. Regressão Linear Múltipla. 3. Funções de Pedotransferência. I. Melo, Francisco Ramos de, orient. II. Costa e Silva, Sandra Máscimo da, co-orient, III. Título.

**REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DAS UMIDADES NA
CAPACIDADE DE CAMPO E NO PONTO DE MURCHA PERMANENTE EM
SOLOS DO CERRADO DO CENTRO GOIANO**

Por
Radson Murilo Veloso Silva Júnior

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

Aprovado em: 02 / 09 / 2020



Prof. Dr. Francisco Ramos de Melo
Orientador
UEG/CET



Prof. Dr. Elton Fialho dos Reis
Membro
UEG/CET



Prof. Dr. Lucas da Costa Santos
Membro
UFVJM/FCA

Aos meus familiares, em especial à minha esposa, Bárbara Mateus Garcia, à minha mãe, Edna Lima Silva, ao meu pai, Radson Murilo Veloso Silva, aos meus avós, Altamiro Martins de Almeida e Belarmina Lima de Almeida (*in memoriam*), à minha prima/irmã, Daniela Lima Miranda de Brito e amigos próximos, pelo companheirismo, amor, dedicação e incentivo em todos os momentos.

AGRADECIMENTOS

Primeiramente a Deus, inteligência suprema, causa primeira de todas as coisas, que em virtude do seu amor infinito, concedeu-me com caridade a permissão e as ferramentas necessárias para a realização desse trabalho.

Ao meu professor e orientador Dr. Francisco Ramos de Melo, pela oportunidade desse feito.

Aos meus amigos e companheiros de mestrado, Carlos Eduardo, Felipe Alves, Rodrigo Starneck e Anderson Umbelino pela responsabilidade e companheirismo que sempre se fizeram presentes nesta jornada.

Aos professores: Ivandro José, Sandra Máscimo e Ródney Couto, por toda contribuição e orientação no desenvolvimento deste projeto.

Aos companheiros de jornada profissional em especial a Itzac Â. S. Albertin, Danilo Feitosa, Lucas Carneiro e Viviane Farias, que contribuíram na realização do trabalho.

Aos professores do mestrado, em especial ao Prof. Dr. André José de Campos, a Profa. Dra. Roberta Passini e a Profa. Dra. Sueli Martins de Freitas Alves, pela humildade e prontidão às quais sempre estavam dispostos a ajudar.

Ao técnico do laboratório de Engenharia Agrícola, seu Waldeir, por todo o auxílio nas tarefas diárias.

À Universidade Estadual de Goiás - UEG, Campus Central – Sede: Anápolis – CET, ao departamento de Engenharia Agrícola, ao Programa de Pós-Graduação em Engenharia Agrícola e à CAPES pelo apoio financeiro necessário para o desenvolvimento dessa dissertação.

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

SUMÁRIO

	PÁGINA
LISTA DE TABELAS	vii
LISTA DE FIGURAS	viii
RESUMO	xi
ABSTRACT	xii
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	4
2.1 Região Centro Goiano (Eixo BR-153)	4
2.2 Definição, classes e tipos de solos da Região Centro Goiano (Eixo BR-153)	7
2.3 Umidades na capacidade de campo (CC) e no ponto de murcha permanente (PMP)	11
2.4 Fatores que influenciam as umidades na CC e no PMP	13
2.5 Importância das umidades na CC e no PMP	17
2.6 Determinação das umidades do solo	20
2.6.1 Determinação das umidades na capacidade de campo e no ponto de murcha permanente.....	22
2.7 Funções de Pedotransferência (FPT)	28
2.8 Regressão linear múltipla (RLM)	30
2.9 Redes neurais artificiais (RNAs)	33
2.9.1 Breve histórico	34
2.9.2 Neurônio Biológico.....	34
2.9.3 Neurônio artificial.....	35
2.9.4 Arquitetura da rede ou Topologia.....	36
2.9.5 Treinamento e aprendizado em RNAs.....	39
2.9.6 Backpropagation	40
2.9.7 Redes Multilayer Perceptron (MLP) ou Perceptron de Múltiplas Camadas.....	40
2.9.8 Trabalhos empregando RNAs nas áreas agrícolas.....	41
3. MATERIAL E MÉTODOS	43
3.1 Localização e caracterização da área experimental	43
3.2 Coleta das amostras de solo	45
3.3 Análises laboratoriais	47
3.3.1 Umidades na capacidade de campo (CC) e no ponto de murcha permanente (PMP)	47
3.3.2 Análise granulométrica	47
3.3.3 Densidade de partículas (Dp) e densidade do solo (Ds)	48
3.3.4 Porosidade total (Pt), Macroporosidade (Macro) e Microporosidade (Micro).....	48
3.3.5 Matéria orgânica (MO)	49

3.4	Análise descritiva e exploratória	49
3.5	Funções de pedotransferência	50
3.5.1	Regressão Linear Múltipla (RLM)	50
3.5.1.1	Definição do modelo	51
3.5.1.2	Verificação dos pressupostos básicos para a RLM	51
3.5.1.3	Escolha do modelo matemático para resolução da RLM	51
3.5.1.4	Separação do conjunto de dados	51
3.5.1.5	Critérios para seleção do modelo	52
3.5.2	Rede Neural Artificial (RNA).....	52
3.5.2.1	Escolha das variáveis de entrada e saída	52
3.5.2.2	Arquitetura da RNA	52
3.5.2.3	Normalização dos dados.....	53
3.5.2.4	Separação do conjunto de dados para treinamento, validação e teste	54
3.5.2.5	Escolha da melhor RNA.....	54
3.5.2.6	Desnormalização dos dados	54
3.6	Indicadores estatísticos que foram usados para avaliação de desempenho e eficiência das FPTs	55
3.7	Comparação dos resultados observados x estimados obtidos nos modelos de RLMs e RNAs	57
4.	RESULTADOS E DISCUSSÃO	59
4.1	Análise descritiva e exploratória	59
4.2	Correlações entre as variáveis dependentes e independentes.....	62
4.3	FPTs geradas por meio de regressões lineares múltiplas.....	63
4.3.1	Pressupostos básicos e seleção dos modelos	63
4.3.2	Desempenho e validação dos modelos de RLM	70
4.4	FPTs geradas por meio de redes neurais artificiais	73
4.4.1	Treinamento das RNAs	73
4.4.2	Escolha das RNAs	78
4.4.3	Apresentação e comparação dos resultados das RNAs escolhidas	87
4.5	Comparação das FPTs geradas pela RLM e pela RNA	100
5.	CONCLUSÕES.....	105
6.	REFERÊNCIAS.....	106
7.	APÊNDICES	130

LISTA DE TABELAS

	PÁGINA
TABELA 1 – Lista de municípios da Região Centro Goiano (Eixo BR-153).....	5
TABELA 2 – Elementos formativos e significados dos nomes das classes.....	8
TABELA 3 – Representação dos 5 grupamentos de classes de solos:	9
TABELA 4 – Municípios e localização das coletas de solo na Região Centro Goiano (Eixo BR-153).....	44
TABELA 5 – Modelos gerados pela RNA para as variáveis CC e PMP.	53
TABELA 6 – Classificação dos índices de desempenho de Camargo e Centelhas (1997) para escolha das funções de pedotransferência.	56
TABELA 7 – Estatística Descritiva das variáveis dependentes e independentes utilizadas nas formulações das FPTs, na profundidade de 0,0 – 0,20 m do solo.	60
TABELA 8 – Estatística Descritiva das variáveis dependentes e independentes utilizadas nas formulações das FPTs, na profundidade de 0,20 – 0,40 m do solo.	60
TABELA 9 – Coeficiente de correlação de Pearson (r) entre as variáveis dependentes e independentes para as profundidades 0,0 – 0,20 m e 0,20 – 0,40 m.	62
TABELA 10 – Resumo dos modelos estatísticos gerados para a variável dependente CC.	64
TABELA 11 – ANOVA da variável dependente CC.....	65
TABELA 12 – Tabela de coeficientes da variável CC para análise da RLM.	66
TABELA 13 – Resumo dos modelos estatísticos gerados para a variável dependente PMP. .	67
TABELA 14 – ANOVA da variável dependente PMP.	68
TABELA 15 – Tabela de coeficientes da variável PMP para análise da RLM.....	69
TABELA 16 – Resultados dos indicadores estatísticos da regressão linear múltipla selecionada para a capacidade de campo (33 kPa).....	71
TABELA 17 – Resultados dos indicadores estatísticos da regressão linear múltipla selecionada para o ponto de murcha permanente (1.500 kPa).	71
TABELA 18 – Parâmetros utilizados para realizar o treinamento das redes MLP.....	74
TABELA 19 – Quantificação das RNAs em relação ao desempenho nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, para os quatro modelos testados com a variável de saída Capacidade de Campo (CC – 33 kPa).	76
TABELA 20 – Quantificação das RNAs em relação ao desempenho nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, para os quatro modelos testados com a variável de saída Ponto de Murcha Permanente (PMP – 1.500 kPa).	77
TABELA 21 – Número de redes selecionadas a partir do critério de desempenho de Camargo e Sentelhas (1997).	78
TABELA 22 – Resultados dos indicadores estatísticos das redes selecionadas para os modelos propostos.....	79
TABELA 23 – Teste-t dos dados observados e estimados pelas RNAs, para a variável capacidade de campo (CC), a partir dos Modelos 1, 2, 3 e 4.	100
TABELA 24 – Teste-t dos dados observados e estimados pelas RNAs, para ponto de murcha permanente (PMP), a partir dos Modelos 5, 6, 7 e 8.	100
TABELA 25 – Comparação entre as metodologias para geração das FPTs (RLM x RNA) observando-se a fase de validação.....	101
TABELA 26 – Tabela de comparação e escolha dos modelos pelo critério de seleção de Akaike (AIC).....	103

LISTA DE FIGURAS

	PÁGINA
FIGURA 1 – a) Países da América Latina – Brasil; b) Estado de Goiás; c) Região Centro Goiano (Eixo BR-153).	4
FIGURA 2 – Distribuição quantitativa (%) das classes de cobertura do solo em Goiás.	6
FIGURA 3 – Triângulo textural, utilizado para a determinação das classes texturais do solo. .9	9
FIGURA 4 – Mapa pedológico da Região Centro Goiano (Eixo BR-153).....	10
FIGURA 5 – Representação da distribuição de água no solo. a) distribuição de areia, argila, macro e microporos no solo. b) representação do solo como um reservatório de água e seus respectivos limites de distribuição hídrica.....	12
FIGURA 6 – Representação da curva característica de água no solo para solos com teores de argila, silte e areia.	15
FIGURA 7 – Distribuição dos poros em solos argilosos e arenosos.	16
FIGURA 8 – Conjunto para determinação da curva de retenção de água no solo – Mesa de Tensão + extrator de membrana.	25
FIGURA 9 – Conjunto para determinação da curva de retenção de água no solo – Painel ou Câmara de Richard.	26
FIGURA 10 – Sequência para determinar as funções de pedotransferência.....	30
FIGURA 11 – Representação de um neurônio biológico.....	35
FIGURA 12 – Modelo de um neurônio artificial.	36
FIGURA 13 – Representação de uma Rede Feedforward de 1 camada.....	37
FIGURA 14 – Representação de uma Rede Feedforward Multicamadas.	38
FIGURA 15 – Representação de uma Rede Recorrente.....	38
FIGURA 16 – Representação de uma Rede Neural Artificial de 2 camadas com 4 neurônios de entrada e dois neurônios de saída.	41
FIGURA 17 – Municípios de coleta de solo, Região Centro Goiano (Eixo BR-153).	43
FIGURA 18 – Mapa pedológico dos municípios onde foram realizadas as coletas de solo, na Região Centro Goiano (Eixo BR-153).	44
FIGURA 19 – a) Coleta de solo das amostras indeformada; b) anel volumétrico com amostra de solo; c) estojo transportador onde as amostras ficaram armazenadas.	45
FIGURA 20 – Amostra deformada de solo identificada e armazenada em saco plástico.....	46
FIGURA 21 – a) extrator de membrana – Eijkelkamp (Pressure Membrane Apparatus); b) mesas de areia sintética – Eijkelkamp (Sandbox for pF -determination).....	47
FIGURA 22 – Determinação granulométrica pelo método da pipeta.	48
FIGURA 23 – Determinação da densidade de partículas e densidade do solo.	48
FIGURA 24 – a) Preparação da amostra de solo para análise de matéria orgânica (MO); b) resfriamento (em dessecador) da amostra após passar pelo ensaio de MO.	49
FIGURA 25 – Triângulo textural com os respectivos resultados das análises granulométricas dos diferentes solos avaliados.....	59
FIGURA 26 – Comparativo geral dos valores observados e estimados do modelo 2, com dois preditores para a variável CC (33 kPa).....	72
FIGURA 27 – Comparativo geral dos valores observados e estimados do modelo 4, com quatro preditores para a variável PMP (1.500 kPa).	72

FIGURA 28 – Exemplo de arquitetura de rede com 10 neurônios na camada de entrada, 5 neurônios na camada oculta e 1 neurônio na camada de saída.....	74
FIGURA 29 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).....	83
FIGURA 30 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).	83
FIGURA 31 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).	84
FIGURA 32 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds).	84
FIGURA 33 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).	85
FIGURA 34 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).	85
FIGURA 35 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade).	86
FIGURA 36 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).	86
FIGURA 37 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).	88
FIGURA 38 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).	89
FIGURA 39 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).	90
FIGURA 40 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds).	91
FIGURA 41 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).	92
FIGURA 42 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).	93
FIGURA 43 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha	

permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).	94
FIGURA 44 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).....	95
FIGURA 45 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).....	96
FIGURA 46 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).	96
FIGURA 47 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).	97
FIGURA 48 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds). ..	97
FIGURA 49 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).	98
FIGURA 50 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).....	98
FIGURA 51 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).....	99
FIGURA 52 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).	99

REDES NEURAI ARTIFICIAIS APLICADAS NA PREDIÇÃO DAS UMIDADES NA CAPACIDADE DE CAMPO E NO PONTO DE MURCHA PERMANENTE EM SOLOS DO CERRADO DO CENTRO GOIANO

RESUMO

A obtenção das umidades na capacidade de campo (CC) e no ponto de murcha permanente (PMP) são ferramentas essenciais para o manejo da irrigação. Métodos diretos de laboratório (Mesa de tensão e Câmara de pressão) para obtenção das CC e PMP são relativamente caros, demandam muito tempo para obtenção dos dados e são dependentes de profissionais capacitados para o manuseio dos aparelhos. Dessa forma, funções de pedotransferência (FPTs) obtidas por regressões lineares múltiplas (RLMs) ou redes neurais artificiais (RNAs) têm se mostrado como soluções viáveis na predição dessas umidades. O presente trabalho teve por objetivo avaliar o uso de RNAs e RLMs na modelagem de funções de pedotransferência para a predição das umidades na capacidade de campo e no ponto de murcha permanente em solos do Centro Goiano (Eixo BR-153). Foram coletadas amostras de solo em 10 municípios da Região Centro Goiano (Eixo BR-153) com 12 pontos amostrais para cada município e em duas profundidades (0,0 – 0,20 m e 0,20 – 0,40 m). As análises laboratoriais foram feitas para os atributos físicos (areia, silte, argila, densidade do solo, densidade de partículas, porosidade total, macroporosidade e microporosidade), hídricos (CC e PMP) e químico (matéria orgânica) do solo. Estes atributos foram utilizados no estudo e desenvolvimento das RLMs e das RNAs. As variáveis preditoras para as FPTs foram: areia, silte, argila, densidade do solo, densidade de partículas, porosidade total, matéria orgânica e profundidade. As variáveis preditas foram CC e PMP. Após o processamento dos dados e modelagem das funções, foram escolhidos os melhores modelos pelas duas metodologias propostas. O Modelo 2 de RLM foi selecionado para a variável CC com as variáveis Micro e Ds como preditores. O Modelo 4 de RLM foi selecionado para PMP e possui Micro, Pt, MO e Argila como variáveis preditoras. Os modelos testados na RNA foram: Modelo1: Areia, Silte e Argila (CC); Modelo 2: Areia, Silte, Argila, Ds, Dp e MO (CC); Modelo 3: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (CC); Modelo 4: Micro e Ds (CC); Modelo5: Areia, Silte e Argila (PMP); Modelo 6: Areia, Silte, Argila, Ds, Dp e MO (PMP); Modelo 7: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (PMP) e Modelo 8: Micro, Pt, MO e Argila (PMP). Tanto a RNA quanto a RLM conseguiram estimar com boa acurácia a variável CC em seus modelos escolhidos. Todos os modelos gerados pela RNA se mostraram superiores na predição do PMP em relação ao modelo de RLM. Os Modelos 2 (AIC=7,518; R²=0,890) da RLM e o Modelo 4 (AIC=7,816; R²=0,856) da RNA foram indicados pelo critério de informação de Akaike (AIC), para estimativa da CC. O Modelo 6 (AIC=6,619; R²=0,616) da RNA foi indicado pelo AIC para a estimativa do PMP.

Palavras-chave: Limites de água no solo; Regressão linear múltipla; Funções de Pedotransferência.

ARTIFICIAL NEURAL NETWORKS APPLIED IN THE PREDICTION OF HUMIDITIES IN THE FIELD CAPACITY AND IN THE PERMANENT MURCHA POINT IN SOILS OF THE CERRADO OF CENTRO GOIANO

ABSTRACT

Obtaining moisture in the field capacity (CC) and at the permanent wilt point (PMP) are essential tools for irrigation management. Direct laboratory methods (tension table and pressure chamber) for obtaining CC and PMP are relatively expensive, require a lot of time to obtain data and are dependent on trained professionals to handle the devices. Thus, pedotransfer functions (FPTs) obtained by multiple linear regressions (RLMs) or artificial neural networks (RNAs) have been shown as viable solutions in the prediction of these humidity. The present work aimed to evaluate the use of RNAs and RLMs in the modeling of pedotransfer functions for the prediction of humidity in the field capacity and in the permanent wilt point in soils of Centro Goiano (Axis BR-153). Soil samples were collected in 10 municipalities in the Centro Goiano Region (Axis BR-153) with 12 sampling points for each municipality and in two depths (0.0 - 0.20 m and 0.20 - 0.40 m). Laboratory analyzes were made for the physical attributes (sand, silt, clay, soil density, particle density, total porosity, macroporosity and microporosity), water (CC and PMP) and chemical (organic matter) of the soil. These attributes were used in the study and development of RLMs and RNAs. The predictive variables for FPTs were: sand, silt, clay, soil density, particle density, total porosity, organic matter and depth. The predicted variables were CC and PMP. The predicted variables were CC and PMP. After processing the data and modeling the functions, the best models were chosen using the two proposed methodologies. Model 2 of RLM was selected for variable CC with variables Micro and Ds as predictors. Model 4 of RLM was selected for PMP and has Micro, Pt, MO and Clay as predictor variables. The models tested at the ANN were: Model1: Sand, Silt and Clay (CC); Model 2: Sand, Silt, Clay, Ds, Dp and MO (CC); Model 3: Sand, Silt, Clay, Ds, Dp, MO, Pt, Micro, Macro and Depth (CC); Model 4: Micro and Ds (CC); Model5: Sand, Silt and Clay (PMP); Model 6: Sand, Silt, Clay, Ds, Dp and MO (PMP); Model 7: Sand, Silt, Clay, Ds, Dp, MO, Pt, Micro, Macro and Depth (PMP) and Model 8: Micro, Pt, MO and Clay (PMP). Both RNA and RLM were able to estimate the CC variable in their chosen models with good accuracy. All models generated by the ANN proved to be superior in predicting the PMP in relation to the model of RLM. Models 2 (AIC=7,518; R²=0,890) of RLM and Model 4 (AIC=7,816; R²=0,856) of RNA were indicated by the Akaike information criterion (AIC), for estimating WC. Model 6 (AIC=6,619; R²=0,616) of the ANN was indicated by the AIC to estimate the PMP.

Keywords: Water limits in the soil; Multiple linear regression; Pedotransfer functions.

1. INTRODUÇÃO

Segundo Brasil (2011) a Região Centro Goiano compreende 31 municípios e foi dividida tendo como critério o eixo da BR 153. Sano et al. (2008a) demonstraram que os solos do estado são caracterizados em sua maioria em Latossolos (52%) e, também, por Argissolos e Nitossolos (15%). Os Latossolos apresentam aptidão para implantação de sistemas agrícolas, porém, possuem déficit em nutrientes químicos. Os Argissolos e Nitossolos se apresentam com uma maior fertilidade química. Segundo Pereira Júnior (2017), o Centro Goiano é uma região com relevante potencial hídrico, no entanto, apresenta uma crescente demanda de irrigação por pivôs centrais pela produção agrícola da região.

Segundo Faggion et al. (2009), o uso eficiente da água com conhecimento adequado e a utilização de alternativas que otimizem o seu uso podem contribuir para aumentar a sua disponibilidade, reduzindo problemas de déficit provocados pelo aumento da demanda social em relação à oferta ambiental.

Pensando-se em manejo da água de irrigação como uso eficiente da água, Resende et al. (2003) propõe o método do “quando” e “quanto” irrigar para monitorar o balanço hídrico no solo e efetuar a irrigação no tempo certo. Para o método, são necessários os pontos de umidade na capacidade de campo (CC) e no ponto de murcha permanente (PMP) característicos do solo, obtidos por meio da curva de retenção de água no solo. Resende et al. (2003) definem: a) a umidade na capacidade de campo (limite superior de água no solo) é a água retida em uma determinada camada de solo após cessar uma irrigação ou chuva e, após o excesso de água saturada no solo ter sido drenada por percolação, devido a força de gravidade; e b) a umidade no ponto de murcha permanente (limite inferior de água no solo) é a umidade retida no solo, após uma secagem devido à extração de água pelas plantas até que a umidade do solo atinja um ponto que as plantas murcham e não mais se recuperam. A água total disponível (AD) é a água retida entre as faixas de umidade do solo na CC e no PMP. Esse método de manejo fundamenta-se em utilizar uma fração da AD, levando-se em consideração a espécie explorada e, também, seu estágio fenológico.

O método laboratorial denominado Mesa de Tensão (TEIXEIRA e BHERING, 2017) pode ser empregado para calcular as umidades na capacidade de campo e no ponto de murcha permanente. No método da Mesa de Tensão (DONAGEMMA et al., 2011) as amostras de solo indeformadas são saturadas com água por capilaridade e colocadas sobre a mesa, na qual são

condicionadas a drenagem, com tensões que variam negativas, com o intuito de que a amostra perca água gradativamente até atingir o ponto em que cesse a drenagem.

O método da mesa de tensão possui como vantagem o uso de amostras indeformadas de solo que são condicionadas a ensaios laboratoriais o que pressuporia uma maior fidelidade nos resultados. Em contrapartida, este método possui limitações. Vaz et al. (1997) demonstraram que um dos grandes problemas é a dificuldade no controle do ponto de equilíbrio entre pressão aplicada e a água retida no solo. Estes, por sua vez, não permitem uma distribuição detalhada e contínua do diâmetro das partículas de solo por serem ainda determinados por peneiramento (porcentagem de areia). Naime et al. (2001) corroboram afirmando que, o método da mesa de tensão sofre desvantagem no quesito espaço físico nos laboratórios, dependência de um operador para manusear o equipamento e o prazo de resposta para a determinação da curva de retenção, que pode durar meses. Outro fator é o custo financeiro que depende do número de amostras coletadas para análise.

Uma alternativa para estimar as umidades do solo foi proposta por Bouma (1989), que denominou de funções de pedotransferência (FPTs). Essas funções, segundo o mesmo autor, são compostas de variáveis independentes ou preditoras, fáceis se serem obtidas, que são capazes de prever outras variáveis denominadas dependentes, que por sua vez são mais difíceis de serem obtidas. McBratney et al. (2002) demonstram que, as FPTs são usadas para estimar propriedades do solo (Ex.: Umidades do solo) por meio de outras propriedades características deste (Ex.: frações granulométricas, densidade, porosidade, etc). Desde então, muitos métodos de modelagem para as FPTs têm sido testados para que se obtenha um melhor ajuste na curva de retenção.

Segundo Costa (2012), a regressão linear múltipla é o método mais comumente usado para estimativas pontuais das funções de pedotransferência. Tabachnick e Fidell (1996) definem que a regressão linear múltipla (RLM) é um conjunto de técnicas estatísticas que possibilita a avaliação do reconhecimento de uma variável dependente com diversas variáveis independentes. Embora esse método seja o mais usado para estimativas das FPTs, possui como desvantagem a complexidade na formulação das funções, que a depender do número de variáveis independentes ou preditoras fica mais difícil para o pesquisador interpretar os resultados dos modelos gerados.

Alguns autores recentes propõe o emprego de Redes Neurais Artificiais para solução de problemas em diversas áreas da agricultura (ALVES et al., 2018; BITTAR et al., 2018, SOARES, 2013). Costa (2012) testou o uso de Rede Neural Artificial (RNA) como uma nova

abordagem para modelagem de FPTs na obtenção da curva característica de água no solo em solos de Santa Catarina, demonstrando a eficácia desse método.

Para Ferro e Sturabo (2013) as RNAs são caracterizadas por uma estrutura com neurônio artificial (elemento de processamento) na qual os modelos possuem capacidade de aprendizado e adaptação, similar aos neurônios biológicos naturais. O aprendizado da RNA ocorre com o ajuste dos parâmetros internos, a partir de um conjunto de exemplos. As redes com várias camadas de neurônios (Multilayer Perceptron - MLPs) são as mais empregadas e citadas na literatura, devido a sua grande capacidade de aprendizado e adaptabilidade aos diferentes tipos de problemas. Embora as RNAs sejam uma alternativa para a modelagem das FPTs em relação à complexidade do método de RLM, pode-se citar como desvantagem, o número elevado de amostras usadas no treinamento das redes.

Assim, este trabalho teve como objetivo geral avaliar o uso de Redes Neurais Artificiais e Regressões Lineares Múltiplas na modelagem de funções de pedotransferência para a predição das umidades na capacidade de campo e no ponto de murcha permanente em solos do Cerrado do Centro Goiano (Eixo BR-153).

2. REVISÃO DE LITERATURA

2.1 Região Centro Goiano (Eixo BR-153)

A Região Centro Goiano foi definida tendo como critério o eixo da BR 153 (Figura 1). Compreende 31 municípios (Tabela 1) ocupando um território de 18.493,049 km², o que corresponde a 5,44% do total do território de Goiás. O processo de industrialização na Região Centro Goiano tem ocorrido de forma intensa em alguns municípios, mas se restringe basicamente à Anápolis, com destaque para o polo farmacêutico; Goianésia, com duas usinas de processamento de cana-de-açúcar e uma indústria de atômados; Jaraguá, com polo de confecções; Rubiataba, com usina de cana-de-açúcar e fábrica de móveis. A região integra o Eixo Goiânia/Anápolis/Brasília, o terceiro maior mercado consumidor do país, perdendo apenas para São Paulo e Rio de Janeiro. A Região Centro Goiano possui 8 usinas Termelétricas de Energia em operação e 1 Hidrelétrica totalizando 112,91 MW de potência, dos quais cinco usinas operam com combustível de biomassa gerada por bagaço de cana (BRASIL, 2011).

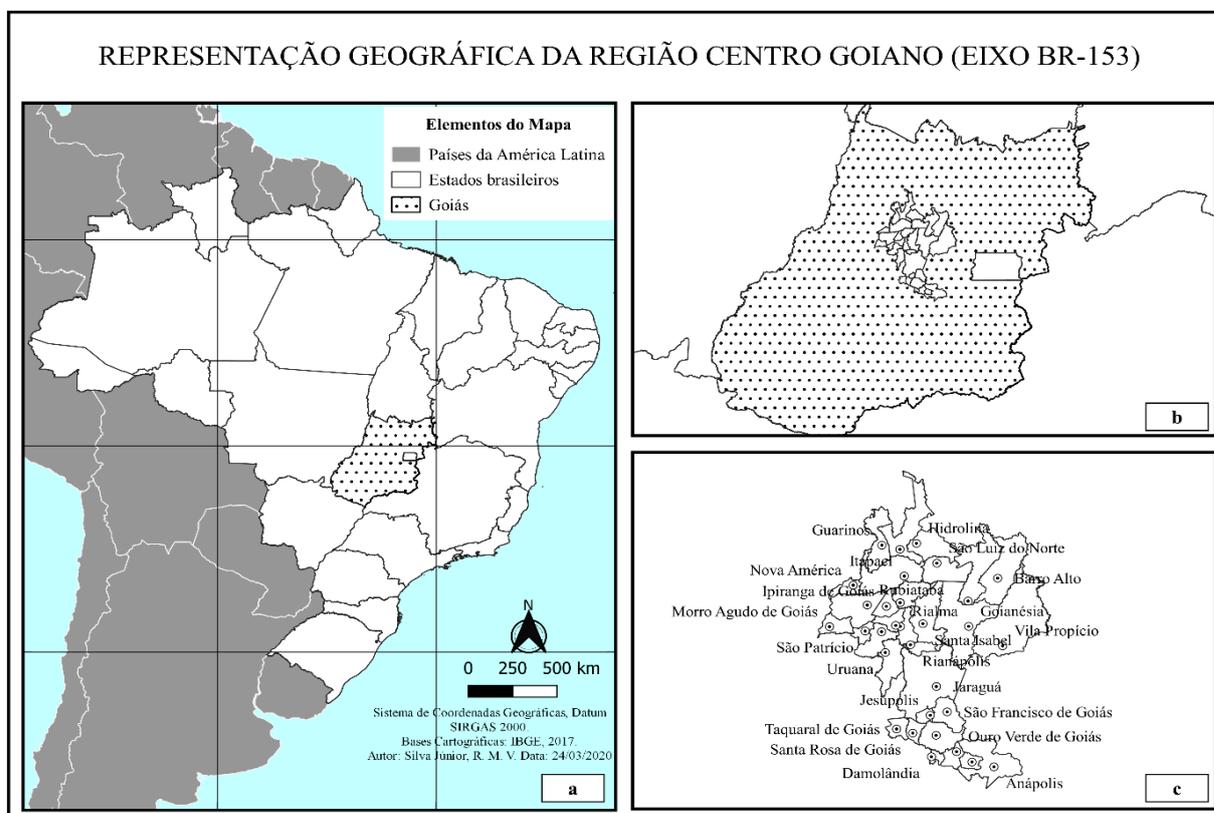


FIGURA 1 – a) Países da América Latina – Brasil; b) Estado de Goiás; c) Região Centro Goiano (Eixo BR-153).

Fonte: Próprio autor.

TABELA 1 – Lista de municípios da Região Centro Goiano (Eixo BR-153).

Número	Município
1	Anápolis
2	Barro Alto
3	Campo Limpo de Goiás
4	Carmo do Rio Verde
5	Ceres
6	Damolândia
7	Goianésia
8	Guarinos
9	Hidrolina
10	Ipiranga de Goiás
11	Itapaci
12	Jaraguá
13	Jesúpolis
14	Morro Agudo de Goiás
15	Nova América
16	Nova Glória
17	Ouro Verde de Goiás
18	Petrolina de Goiás
19	Pilar de Goiás
20	Rialma
21	Rianápolis
22	Rubiataba
23	Santa Isabel
24	Santa Rita do Novo Destino
25	Santa Rosa de Goiás
26	São Francisco de Goiás
27	São Luiz do Norte
28	São Patrício
29	Taquaral de Goiás
30	Uruana
31	Vila Propício

Fonte: Próprio Autor.

Segundo Instituto Mauro Borges (2018), a estimativa da área colhida em cana-de-açúcar na região centro goiano foi de 125.133 hectares, o que totalizou uma produção de 8.402.496 toneladas de cana. Outro produto que possui larga produção na região é o tomate, com uma área colhida de 111 hectares, totalizando 10.097 toneladas produzidas. A região também se destaca pela produção de soja (127.071 toneladas produzidas), milho (88.064 toneladas produzidas), banana (98.539 toneladas produzidas), abacaxi (30.865 mil frutos) e leite (379.454 mil litros produzidos), com destaque para as regiões de Jaraguá e Rubiataba, para o último. As informações catalogadas fornecidas pelo IBGE (2006), sobre o uso dos solos dessa região sob as perspectivas de área de estabelecimentos agropecuários por utilização de terras em lavoura permanente, temporária, pastagens naturais e plantadas, matas e florestas naturais e plantadas,

demonstram um total de 1.420.006 hectares em uso, dos quais destacam-se Goianésia, Jaraguá e Vila Propício. Segundo Brasil (2011), o uso dos solos da região também se destaca pela pecuária, operação e instalação de indústrias do setor primário de produção.

Essa região é formada predominantemente pelo Bioma Cerrado, que segundo Carvalho et al. (2008) ocupa cerca de 25% do território nacional. Ferreira et al. (2005) apontam o estado goiano como o único Estado da Federação totalmente inserido na área do bioma. O Estado possui uma taxa de conversão de 64% da cobertura nativa em área de expansão agropecuária. Carvalho et al. (2008) demonstraram o aumento do uso de terras agrícolas no Bioma Cerrado para o Estado de Goiás, com uma crescente demanda na Região Centro Goiano, sendo apontado quase que em totalidade por áreas de pastagens (45%) e agricultura (18,1%) (Figura 2). O autor ainda aponta 85% dos 246 municípios do Estado com área convertida superior à área de remanescentes, sendo os municípios do Centro Goiano os que apresentam maiores índices de conversão. Sano et al. (2008b) corroboram com essas informações demonstrando, também, uma taxa de conversão antrópica na ordem de 40% sobre a área original do bioma.

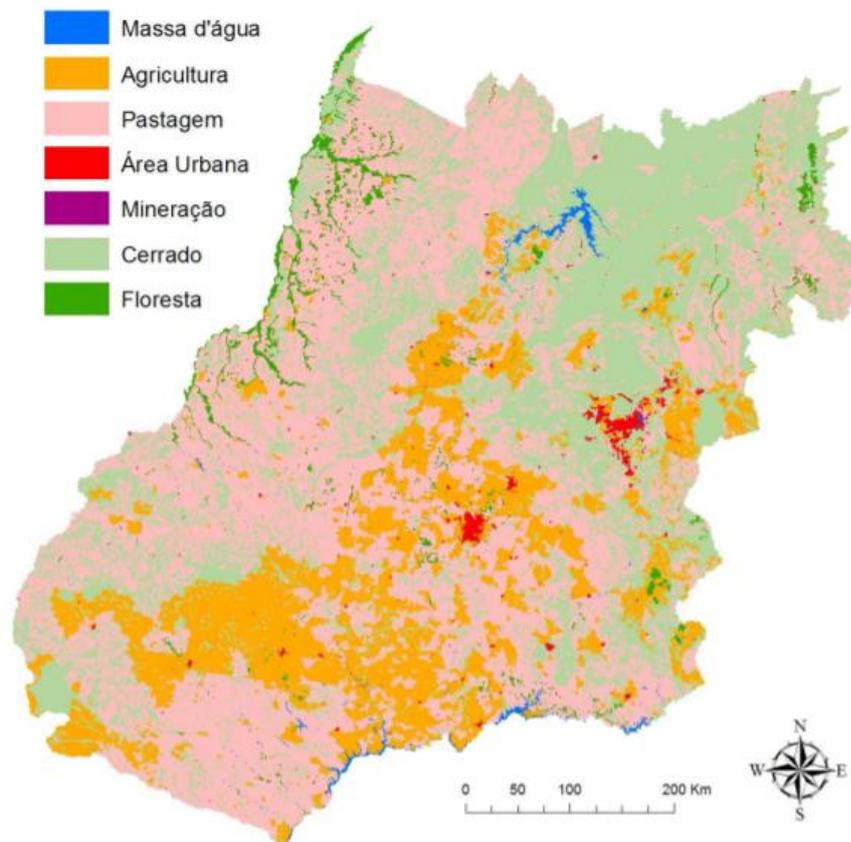


FIGURA 2 – Distribuição quantitativa (%) das classes de cobertura do solo em Goiás.
Fonte: Carvalho et al. (2008).

2.2 Definição, classes e tipos de solos da Região Centro Goiano (Eixo BR-153)

O solo é um corpo natural composto de sólidos (minerais e matéria orgânica), líquidos e gases que ocorrem na superfície da terra, ocupa espaço e é caracterizado por um ou ambos dos seguintes componentes: horizontes, ou camadas, que são distinguíveis do material inicial como resultado de adições, perdas, transferências e transformações de energia e matéria; ou capacidade de apoiar plantas enraizadas em um ambiente natural (SOIL SURVEY STAFF, 1999). Em seu significado tradicional, o solo é o meio natural para o crescimento de plantas terrestres, com ou sem distinção dos horizontes do solo. As pessoas consideram o solo importante porque suporta plantas que fornecem alimentos, fibras, drogas e outras necessidades humanas, além de filtrar a água e reciclar resíduos (SOIL SURVEY STAFF, 2014).

Segundo Santos et al. (2018), os solos são a base para a produção de alimentos e de muitos serviços essenciais dos ecossistemas. Tem sido demonstrado que a gestão sustentável dos solos contribui para o aumento da produção e valor nutritivo dos alimentos, bem como para a adaptação às alterações climáticas e sua mitigação. O Sistema Brasileiro de Classificação de Solos (SiBCS) é o sistema taxonômico oficial de classificação de solos do Brasil. Existem 6 níveis categóricos para classificação dos solos segundo o SiBCS, sendo: 1° - Ordens; 2° - Subordens; 3° - Grandes grupos; 4° - Subgrupos; 5° - Famílias; e 6° - Séries. No primeiro nível categórico (Ordens), existem 13 classes de solos, sendo formados pela associação de um elemento formativo com a terminação “-ssoos” (Tabela 2).

TABELA 2 – Elementos formativos e significados dos nomes das classes.

Classes	Elemento formativos	Termos de conotação e de memorização
ARGISSOLO	ARGI	Do latim <i>argilla</i> , “argila”; conotativo de solos com processo de acumulação de argila
CAMBISSOLO	CAMBI	Do latim <i>cambiare</i> , “trocar”, “mudar”; conotativo de solos em formação (transformação). Horizonte B incipiente
CHERNOSSOLO	CHERNO	Do russo <i>cherniy</i> , “preto”; conotativo de solos ricos em matéria orgânica, com coloração escura
ESPODOSSOLO	ESPODO	Do grego <i>spodos</i> , “cinza vegetal”; conotativo de solos com horizonte de acumulação iluvial de matéria orgânica associada à presença de alumínio. Horizonte B espódico
GLEISSOLO	GLEI	Do russo <i>gley</i> , “massa do solo pastosa”; conotativo de excesso de água. Horizonte glei
LATOSSOLO	LATO	Do latim <i>lat</i> , “tijolo”; conotativo de solos muito intemperizados. Horizonte B latossólico
LUVISSOLO	LUVI	Do latim <i>luere</i> , “lavar”; conotativo de translocação de argila. Horizonte B textural com alta saturação por bases e Ta
NEOSSOLO	NEO	Do grego <i>neo</i> , “novo”; conotativo de solos com pouco desenvolvimento pedogenético
NITOSSOLO	NITO	Do latim <i>itidus</i> , “brilhante”; conotativo de superfícies brilhantes nas unidades estruturais. Horizonte B nítico
ORGANOSSOLO	ORGANO	Do latim <i>organicus</i> , “pertinente ou próprio dos compostos de carbono”; conotativo de solos com maior expressão da constituição orgânica. Horizonte H ou O
PLANOSSOLO	PLANO	Do latim <i>planus</i> , “plano”; conotativo de solos desenvolvidos em planícies ou depressões com encharcamento estacional. Horizonte B plânico
PLINTOSSOLO	PLINTO	Do grego <i>plinthos</i> , “ladrilho”; conotativo de materiais argilosos coloridos que endurecem quando expostos ao ar. Horizonte plíntico
VERTISSOLO	VERTI	Do latim <i>vertere</i> , “virar”, “inverter”; conotativo de movimento de material de solo na superfície e que atinge a subsuperfície (expansão/contração). Horizonte vértico

Fonte: Santos et al. (2018).

Segundo Santos et al. (2005), a textura do solo refere-se à proporção relativa das frações granulométricas – areia (a mais grosseira), silte e argila (a mais fina) – que compõem a massa do solo. A textura é uma das propriedades do solo que é utilizada na sua classificação. O triângulo textural (Figura 3) é uma ferramenta que permite classificar o solo, segundo o Soil Survey Manual (SOIL SURVEY STAFF, 1993), em diferentes classes texturais.

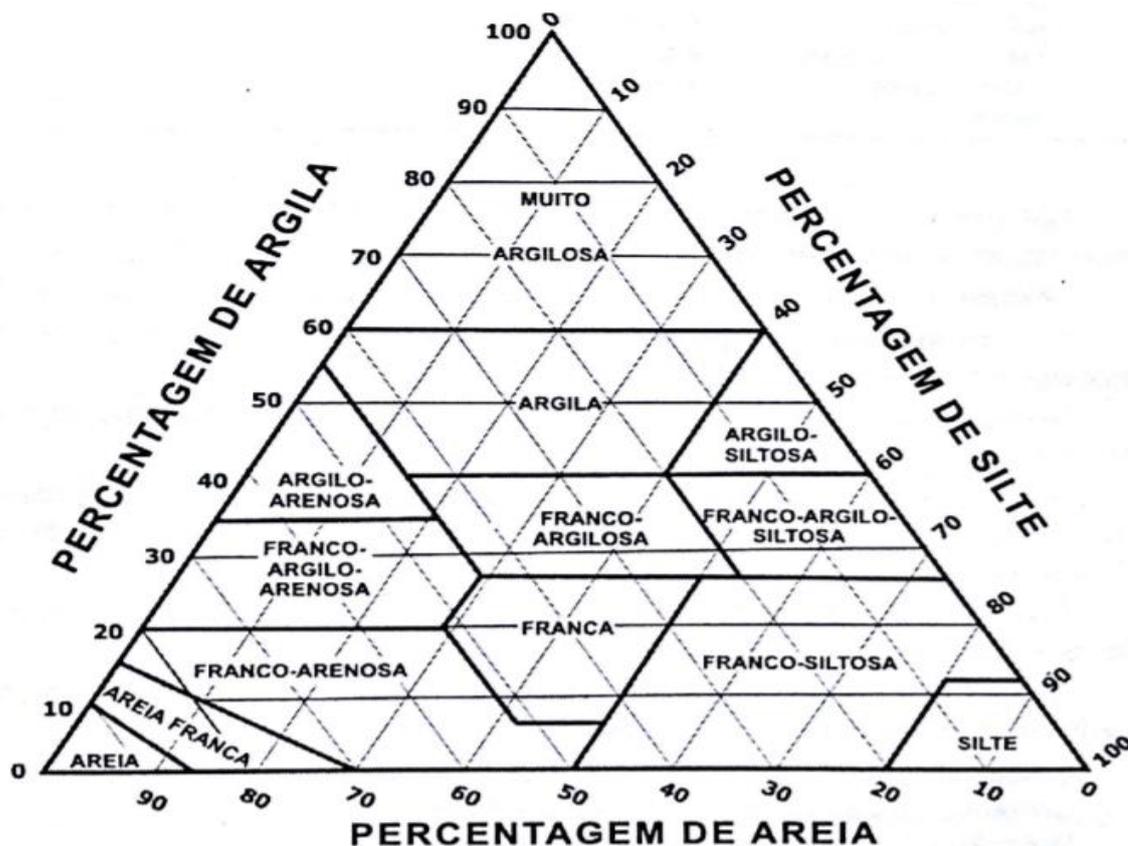


FIGURA 3 – Triângulo textural, utilizado para a determinação das classes texturais do solo.
Fonte: Santos et al. (2005).

Nos trabalhos de levantamentos de solos produzidos no Brasil, utiliza-se a função de uma ou mais das 13 classes texturais em 5 grupamentos (Tabela 3):

TABELA 3 – Representação dos 5 grupamentos de classes de solos:

Grupamentos	Definição
Textura arenosa	Compreende as classes texturais areia e areia franca
Textura argilosa	Compreende classes texturais ou parte delas, tendo na composição granulométrica de 35% a 60% de argila
Textura muito argilosa	Compreende a classe textural argilosa com mais de 60% de argila
Textura média	Compreende classes texturais ou parte delas que apresentam na composição granulométrica menos de 35% de argila e mais de 15% de areia, excluídas as classes areia e areia franca
Textura siltosa	Compreende parte de classes texturais que tenham silte maior que 50%, areia menor que 15% e argila menor que 35%

Fonte: Santos et al. (2005).

O Estado de Goiás é formado por 52% de Latossolos Vermelhos e Vermelhos Amarelos, seguidos de 15% de Argissolos Amarelos e Nitossolos e 12% de Cambissolos Háplicos, o que representam 79% das classes de solos do Estado, segundo dados do IBGE/CNPS (2001). Outros autores indicam valores de classes de solo mais expressivas no Estado sendo os Latossolos

(45,7%); Neossolos Quartzarênicos (15,2%); Argissolos (15,1%); Plintossolos (9,0%) (SANTOS e CÂMARA, 2002; REATTO e MARTINS, 2005).

Observa-se no mapa pedológico, gerado a partir das bases cartográficas SIEG (2005), para a Região Centro Goiano (Eixo BR-153) (Figura 4), a predominância de oito classes de solos (Argissolos, Cambissolos, Chernossolos, Gleissolos, Latossolos, Neossolos, Planossolos e Plintossolos), sendo predominantemente formados por Argissolos, Cambissolos e Latossolos (Vermelho e Vermelho-amarelo). Correia et al. (2004) classificaram os Latossolos da região como intemperizados, ácidos, de baixa fertilidade natural e com concentrações elevadas de alumínio.

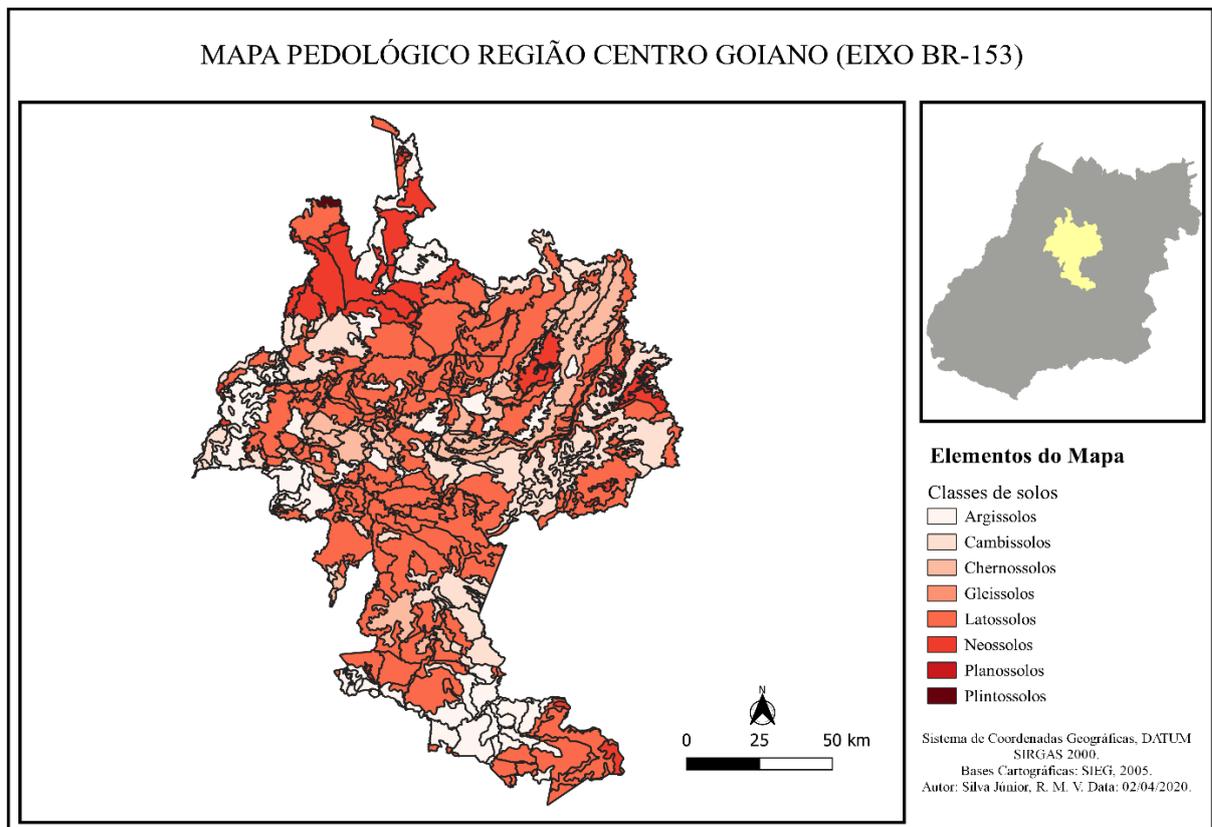


FIGURA 4 – Mapa pedológico da Região Centro Goiano (Eixo BR-153).

Fonte: Próprio Autor.

Segundo Lopes (1984), os solos do Cerrado apresentam grandes limitações ao cultivo, devido à sua baixa fertilidade natural. Os solos da região apresentam elevado potencial para a agricultura mecanizada intensiva, uma vez corrigidas as suas deficiências químicas, mostrando, sob vegetação natural, propriedades físicas favoráveis (CERRI et al., 1991). Para Oliveira et al. (2003), os solos de cerrado, no passado caracterizados como inférteis e improdutivos, passaram

a ser observados a partir da mecanização da agricultura, da irrigação e da utilização de corretivos químicos, como solos com potencial agrícola.

Castro et al (2011) analisaram propriedades físico-hídricas (textura, densidade específica do solo e de partículas, a porosidade e a curva de retenção de água no solo) de solos agricultáveis do Estado de Goiás, tais como o argissolo vermelho eutrófico (PVe), latossolo vermelho acriférrico (LVwf), nitossolo vermelho eutroférico (NVef) e neossolo quartzarênico (RQ), onde puderam observar que os PVe, RQ e LVwf apresentaram maiores valores na curva de retenção de água no solo e o RQ apresentou maior propensão à erodibilidade sendo, mais vulnerável à erosão hídrica. No entanto, os autores propõem que se forem aplicadas técnicas de uso e manejo do solo como aplicação de cobertura morta vegetal, terraceamento, cultivo em nível, dentre outras, pode-se conseguir a redução da perda de solos por erosão hídrica.

2.3 Umidades na capacidade de campo (CC) e no ponto de murcha permanente (PMP)

O conteúdo de água no solo é a quantidade de água armazenada até uma dada profundidade do solo, geralmente, a profundidade efetiva do sistema radicular. Pode ser obtido pela relação entre o volume de água e o volume de solo (umidade volumétrica) ou pela relação entre a massa de água e a massa de solo (umidade gravimétrica) (BUSKE, 2013).

Segundo Reichardt (1988), o solo se comporta como um reservatório de água para as plantas (Figura 5). Apesar deste ser aberto para a atmosfera e para os horizontes mais profundos do perfil, ele retém água por meio de sua interação com a matriz. O termo capacidade de campo foi introduzido por Veihmeyer e Hendricson (193, 1949) com o propósito de quantificar o limite superior de água no solo e com a tentativa de oferecer maior aplicabilidade ao conceito desenvolvido por Briggs e McLane (1910) de “equivalente de umidade”. Para Meyer e Gee (1999), a capacidade de campo representa o conteúdo de água retida no solo após o excesso de água ter sido drenado e o movimento da água tornar-se desprezível. Segundo Reichardt (1988) a capacidade de campo é um processo dinâmico e não uma característica da matriz solo, logo depende de características específicas para situações distintas. Resende et al. (2003) inferem que após uma irrigação ou chuva, uma determinada camada do solo fica saturada de água e, após algum tempo, o excesso de água é drenada, devido à força da gravidade. O conteúdo de água nesse ponto é denominado de capacidade de campo (CC) que constitui o limite superior da água total disponível (AD).

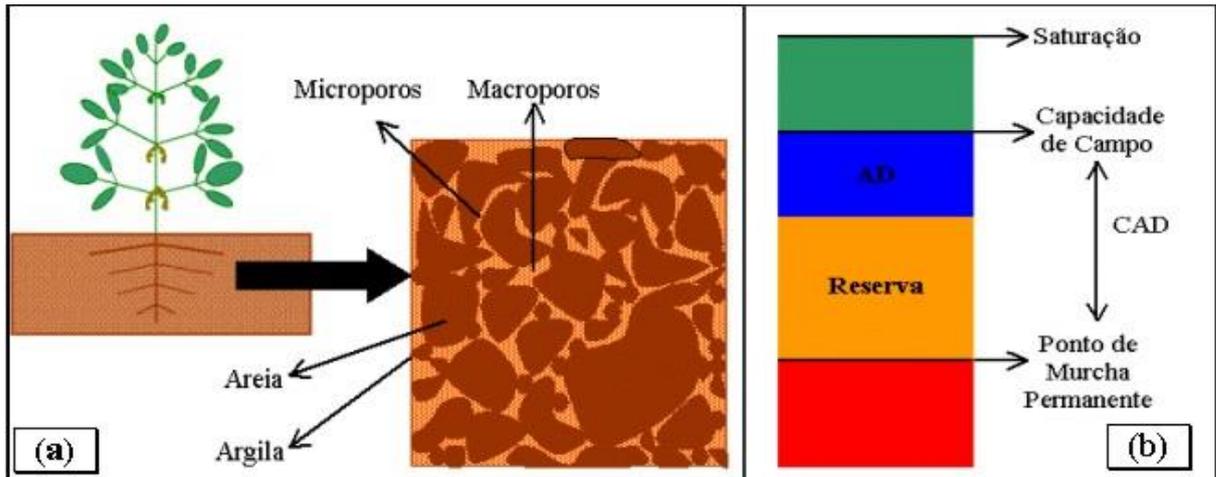


FIGURA 5 – Representação da distribuição de água no solo. a) distribuição de areia, argila, macro e microporos no solo. b) representação do solo como um reservatório de água e seus respectivos limites de distribuição hídrica.

Fonte: Vanzela e Andrade (2020).

Para Bernardo et al. (2007), a tensão considerada equivalente à capacidade de campo é de 33 kPa (0,033 MPa) para solos de textura fina e 10 kPa (0,010 MPa) para solos de textura grossa. Reichardt (1988) demonstrou que a tensão matricial não chegou aos valores de 33 kPa propostos para capacidade de campo. Outros autores, tais como Ferreira e Marcos (1983), Andrade et al. (1991) e Mello et al. (2002), afirmaram por meio de seus trabalhos que, para solos tropicais, a capacidade de campo correspondia a tensões na faixa de 6 a 10 kPa. A adoção de certa tensão representativa da capacidade de campo é de interesse geral, dado à praticidade de se caracterizar rapidamente a sua umidade correspondente, por meio de curvas características de retenção de água (ANDRADE e STONE, 2011).

O Ponto de Murcha Permanente (PMP) (Figura 5b) é definido funcionalmente, como o ponto (teor de umidade do solo) no qual as plantas murcham e não mais recuperam a turgidez, mesmo que sejam colocadas em câmara escura e úmida (NORTON e SILVERTOOTH, 1998; BEZERRA et al., 1999; CASTILLA PRADO e MONTALVO LOPES, 2000) ou que ocorra chuva ou irrigação (BEZERRA et al., 1999). Normalmente, o Ponto de Murcha Permanente é considerado como sendo uma característica estática do solo, ao contrário da capacidade de campo (REICHARDT, 1988).

Segundo os trabalhos de Briggs e Shantz (1911) e Furr e Reeve (1945), utilizando o girassol como planta indicadora para a determinação do fenômeno da murcha permanente, observou-se que o ponto em que a planta não mais retornava ao seu estado de turgescência, independentemente da quantidade de água que era repostada, ocorre quando a tensão de água no solo é de, aproximadamente, 1.500 kPa, considerado como "conceito das 15 atmosferas". Czyz

e Dexter (2012) apontam que os estudos anteriores de Briggs e Shantz (1911) e Veihmeyer e Hendrickson (1928) serviram de forte evidência para considerar que o PMP é na verdade determinado por características do solo, logo, o PMP é uma propriedade física do solo.

Segundo Resende et al. (2003) a secagem do solo ocorre principalmente devido à extração de água pelas plantas, até que a umidade do solo atinja um ponto em que se constitui o limite inferior (PMP) da água disponível (AD). A água retida nos microporos do solo abaixo do PMP é considerada como água não disponível. Portanto, AD é aquela retida no solo entre a CC e o PMP.

Apesar desses conceitos, vários pesquisadores têm observado que a umidade no PMP pode variar para diferentes espécies de plantas, estágio de desenvolvimento, condições do ambiente e tipo de solo (SLATYER, 1957; SYKES, 1969). Esses resultados contrariam o conceito de que a murcha permanente é independente da espécie e não varia com as características do solo (PROCÓPIO, et al 2004).

2.4 Fatores que influenciam as umidades na CC e no PMP

Para Ávila et al. (2011), os diversos processos estáticos e dinâmicos no solo, junto as interferências das mudanças sazonais no regime de chuvas, influenciam diretamente na alta variabilidade no espaço e no tempo da umidade do solo. Logo, devido a essa heterogeneidade e à diversidade das condições ambientais envolvidas, é relativamente complexo descrever os processos ou fatores dominantes que podem influenciar na variabilidade no espaço e no tempo da umidade do solo.

Dentre os fatores que afetam a retenção da água em um solo, os principais são: a textura, a densidade, a porosidade, o teor de matéria orgânica e a mineralogia da fração argila (KIEHL, 1979; BRADY, 1989). Gómez-Plaza et al. (2000) corroboram afirmando que os fatores que se destacam para o conteúdo de água no solo são: a heterogeneidade nas características do solo, tais como textura, conteúdo de matéria orgânica, estrutura e macroporosidade, que afetam a transmissividade do fluido e as propriedades de retenção da água no solo. Segundo Cassel e Nielsen (1986), a capacidade de retenção de água pelo solo está diretamente relacionada à sua matriz e à distribuição espacial dos poros.

As características físicas do solo, como a textura e a estrutura, afetam diretamente a capacidade de absorção de água pela planta, pois estão ligadas à capacidade do solo de armazenar água e transportá-la para a superfície das raízes. O conhecimento do armazenamento

de água disponível é uma informação básica para projetos de irrigação, considerando-se o limite superior (capacidade de campo) e o inferior (ponto de murcha permanente), que definem a capacidade de água disponível (CAD) (COELHO FILHO et al., 2011).

A textura tem grande influência no comportamento físico-hídrico e químico do solo, e por isso, sua avaliação é de grande importância para o uso e manejo dos solos utilizados para a agricultura. É expressa pela proporção dos componentes granulométricos da fase mineral do solo, areia, silte e argila (SANTOS et al., 2018). Segundo Costa (1979), a influência da textura do solo é muito grande na retenção de água. Todavia, Carvalho et al. (1999) afirmam que solos da mesma classe de textura podem ter pontos na curva de retenção de água no solo diferentes, não só devido às diferenças de granulometria nas mesmas classes de textura, mas também, como resultado de diferenças de teor em matéria orgânica, tipo de argila e das diferenças de microestrutura a elas relacionadas.

Segundo Brady (1989), os solos de textura mais fina possuem uma maior retenção de água no solo, ao longo de toda a faixa de energia, pelo fato de possuírem maior porcentagem de material coloidal, maior espaço poroso e superfície adsortiva muito maior que os solos de textura mais grossa. Sanchez (1981) corrobora com seu trabalho mostrando a importância da textura na retenção de água, ao comparar curvas de retenção de umidade nas diferentes classes texturais. A Figura 6 representa a curva de retenção ou curva característica de água no solo, para solos com teores de argila, silte e areia. Isso demonstra os diferentes volumes de água no solo (%), submetidos a tensões nas faixas de ponto de murcha permanente e capacidade de campo. Solos arenosos tendem a ter menor capacidade de água disponível por unidade de profundidade, com um limite mínimo de cerca de 0,5 mm de água/cm de profundidade, enquanto solos argilosos podem chegar num limite extremo e apresentarem 2,0 mm de água/cm de profundidade (COELHO FILHO, et al., 2011).

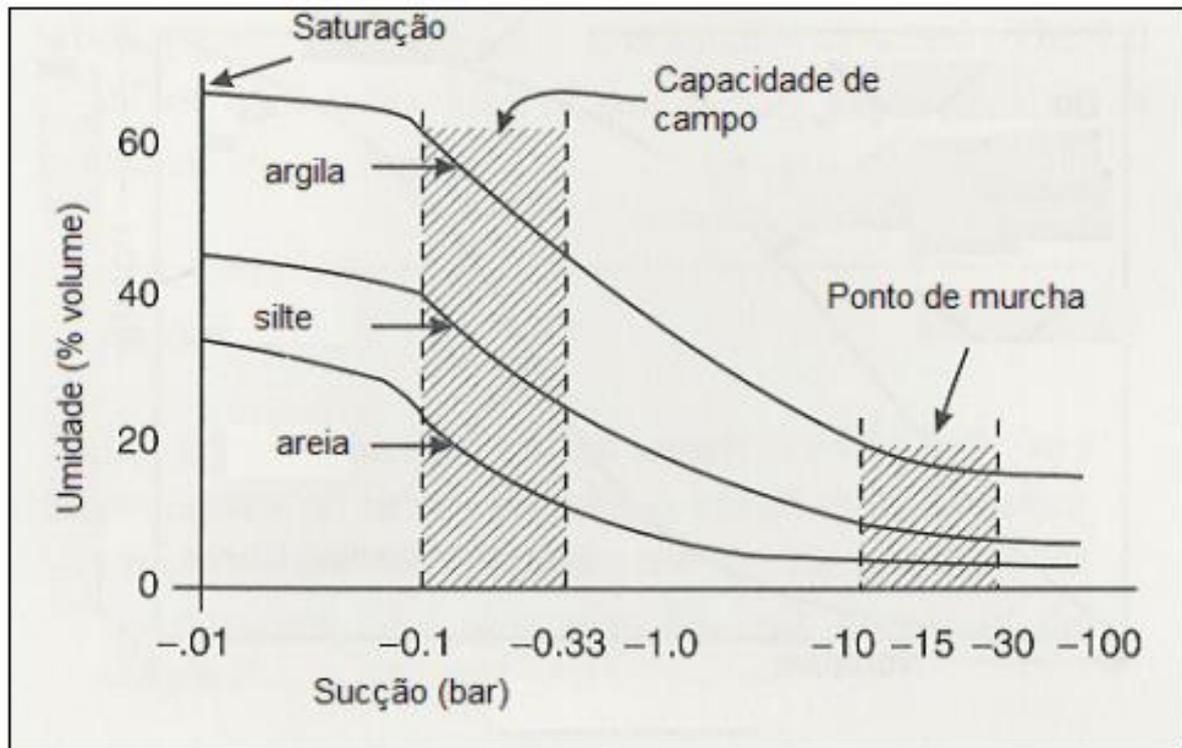


FIGURA 6 – Representação da curva característica de água no solo para solos com teores de argila, silte e areia.

Fonte: Ward e Trimble (2004).

Segundo a Embrapa (2017), a densidade do solo é o atributo físico do solo que indica a relação existente entre seu volume e sua massa. É um importante atributo físico, por fornecer indicações a respeito do estado de sua conservação, sobretudo em sua influência em propriedades como infiltração e retenção de água no solo, desenvolvimento de raízes, trocas gasosas e suscetibilidade do solo aos processos erosivos, e também sendo largamente utilizada na avaliação da compactação e/ou adensamento dos solos (GUARIZ et al., 2009). A densidade do solo varia de 1,1 a 1,6 g cm⁻³, dependendo da textura, da estrutura e dos teores de matéria orgânica do solo. Solos com elevados teores de matéria orgânica têm menores valores de densidade e solos argilosos apresentam menores valores de densidade do que os solos arenosos. Solos com densidade acima de 1,7 g cm⁻³ tendem a dificultar a penetração de raízes (LACERDA, 2007).

Para Hillel et al. (1972), a retenção de água no solo, para condições de teores elevados de umidade do solo, depende diretamente do arranjo e dimensões dos poros. As propriedades do solo que interferem diretamente na retenção são: a densidade e a porosidade, que são influenciadas pela estrutura do solo. Em contrapartida, para teores baixos de umidade do solo, a retenção praticamente independe da estrutura do solo, sendo este influenciado, pela textura e superfície específica.

Segundo Marques (2000), os poros do solo são determinados pelo arranjo das partículas sólidas, sendo representados por cavidades de diferentes formas e tamanhos, e ocupadas por ar e solução (água + nutrientes) (Figura 7). O solo não saturado, também chamado de solo agrícola, é aquele cujo espaço poroso é parcialmente cheio de água e parcialmente cheio de ar. Essa saída de água do complexo espaço poroso do solo faz com que ocorra a formação de interfaces ar-água, resultantes dos processos de retenção de água pela matriz do solo. Os dois processos que explicam basicamente a retenção da água pelos solos são: a retenção que ocorre nos microporos dos agregados (ex.: fenômeno da capilaridade) e a retenção que ocorre nas superfícies dos sólidos do solo, como filmes presos a ela, pelo chamado processo de adsorção (LIBARDI, 2005).

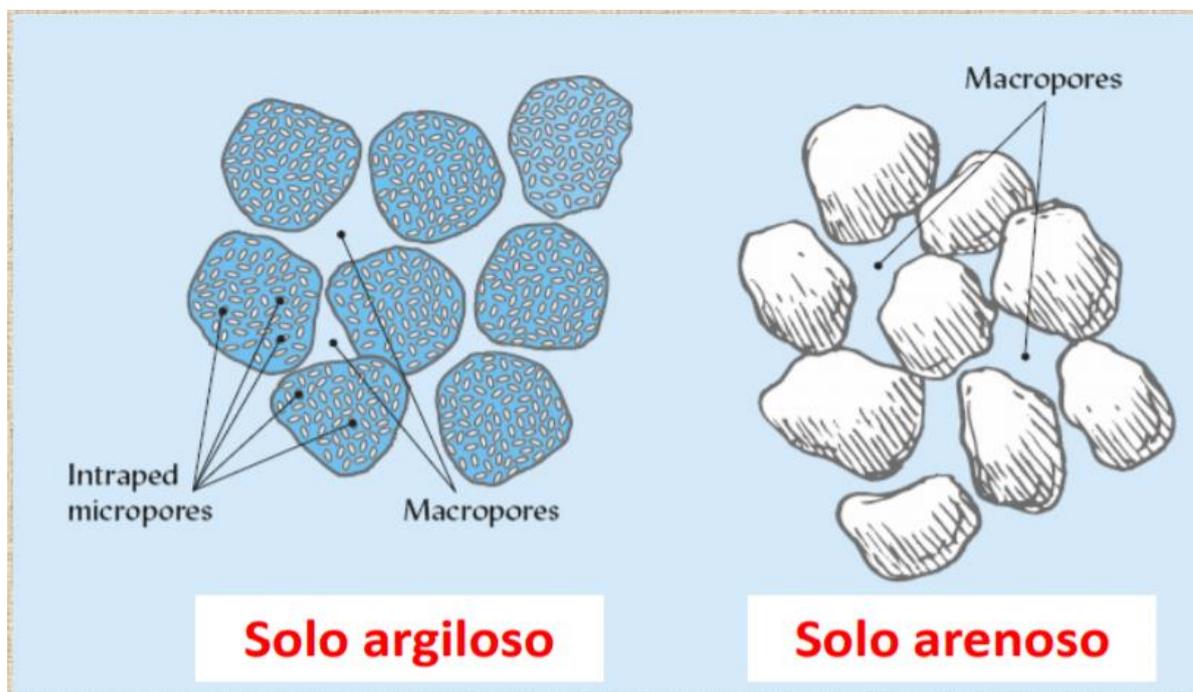


FIGURA 7 – Distribuição dos poros em solos argilosos e arenosos.

Fonte: Google imagens (2020).

O preparo de solo convencional de forma intensiva nos cultivos agrícolas, tem causado um aumento da densidade do solo que, por sua vez, desencadeia uma redução da porosidade total, na maioria das vezes pela diminuição da macroporosidade e aumento da microporosidade, o que reduz o volume dos índices gasosos e aumenta o índice de retenção hídrica (BERTOL e SANTOS, 1995; STONE e SILVEIRA, 2001; CRUZ et al., 2003; TORMENA et al., 2004; SECCO et al., 2005).

Segundo Brady e Weil (2013), a matéria orgânica (MO) do solo é constituída de uma variedade de substâncias orgânicas, incluindo organismos vivos, restos de organismos que em

algum momento ocuparam o solo e compostos orgânicos produzidos pelo metabolismo atual e passado ocorrido no solo. Kiehl (1985) demonstra que a densidade do solo, estrutura, aeração, drenagem, retenção de água e consistência do solo são diretamente influenciadas pela matéria orgânica. Bertoni e Lombardi Neto (2005) afirmam que o aumento da matéria orgânica, em solos arenosos, promove a aglutinação das partículas que firmam a estrutura e diminuem o tamanho dos poros, o que por sua vez, aumenta a capacidade de retenção de água. Logo, Bennett (1995) demonstra que a aplicação de matéria orgânica no solo, além de aumentar a fertilidade e diminuir a erodibilidade do solo, previne diretamente a perda de água no solo.

Grohmann e Medina (1962), verificaram que a retenção de água, em diferentes profundidades, mostrou-se dependente do teor de matéria orgânica, quando esta variou de 8 a 68 g kg⁻¹, onde a retenção de água reduzia com o aumento da profundidade.

Rawls et al. (2003) demonstraram que o acréscimo do teor de carbono aumenta a retenção de água, em qualquer classe textural, principalmente em solos que já possuem elevado teor de carbono orgânico naturalmente. Existem trabalhos que incluem a matéria orgânica no solo nos modelos de estimativa de CC e PMP, bem como em outros trabalhos a MO é específico à estimativa de uma das duas umidades (CC ou PMP) ou até mesmo excluem a MO dos modelos matemáticos de estimativa de CC e PMP.

2.5 Importância das umidades na CC e no PMP

A umidade no solo constitui-se em uma das variáveis mais importantes para estudos de condutividade hidráulica e infiltração, bem como a compreensão de uma série de processos hidrológicos e climáticos em diferentes escalas espaciais e temporais (ROSSATO et al., 2002; BROCCA et al., 2009; HEATHMAN et al., 2009).

A água é extremamente importante na produção vegetal e o seu manejo racional é decisivo para o desenvolvimento das plantas, evitando a falta ou excesso. Desta maneira, o conhecimento da distribuição do teor de água (umidade) no solo torna-se cada vez mais necessário, uma vez que está intimamente ligado às propriedades do sistema solo-água-planta, onde o domínio desse conhecimento é, certamente, um dos fatores indispensáveis para uma agricultura sustentável e sem prejuízos ao meio ambiente (SOUZA e MATSURA., 2002).

Nenhum dos processos físicos na atmosfera e no ambiente pode ocorrer sem água. A umidade do solo depende da quantidade de precipitação, da intensidade do consumo de água pelas plantas e da temperatura do ar, entre outros fatores. Amplos níveis de umidade são de alta

importância para o rendimento, portanto as plantas não crescerão e se desenvolverão com umidade inadequada do solo (EOS, 2020). Sun et al. (2009), corroboram afirmando que a umidade do solo interfere diretamente no crescimento das culturas e sua distribuição sofre forte influência do manejo da água em sistemas de cultivos agrícolas irrigados.

Para Dourado Neto et al. (1990), o conhecimento da curva de retenção de água no solo, que é a relação funcional entre umidade do solo e seu potencial matricial na zona radicular das culturas, é fundamental na irrigação, porque visa um aproveitamento mais racional da água. A aplicabilidade dessa curva é ampla tanto nos meios científicos como no cotidiano dos produtores, sendo possível estimar outros atributos do solo como a porosidade drenável, capacidade de campo, ponto de murcha permanente, água disponível, condutividade hidráulica não saturada, além do balanço hídrico, determinando-se a variabilidade do armazenamento de água no solo, sendo ainda um indicador físico bastante valioso da qualidade do solo (SÁ et al., 2010).

Resende et al. (2003) propõe o método de manejo da água de irrigação por turnos de rega fixo e variável. Para esse método são imprescindíveis alguns fatores para os cálculos da lâmina de irrigação, tais como, informações de umidades do solo nas condições de capacidade de campo (CC) e de ponto de murcha permanente (PMP), para a obtenção da água disponível (AD) e subsequente realização do balanço hídrico no solo.

Segundo Medina e Oliveira Júnior (1987), o conhecimento da capacidade de campo de um solo é de fundamental importância para as pesquisas de irrigação, erosão, hidrologia e drenagem. Silva Júnior, et al. (2017) citam o manejo da irrigação por pivô central para a cultura da soja no município de Sítio do Mato – BA, tendo como base as umidades na CC e no PMP para formulação das lâminas de irrigação. Pan et al. (2008) afirmam que o conteúdo de água do solo limita o número e o tamanho das espécies de plantas perenes em áreas áridas. Buske (2013) diz que é bastante usual o manejo de sistemas de irrigação com o uso dessas umidades do solo, acionando-se os sistemas antes que o solo alcance o limite inferior de água no solo (PMP) e desligando-se no momento em que se atinge a umidade do limite superior de água no solo (CC), reduzindo custos de irrigação e perdas de água bem como proporcionando o aumento da produtividade.

Para o manejo adequado da água de irrigação é necessário o controle diário da umidade do solo e/ou da evapotranspiração, durante todo o ciclo de desenvolvimento da cultura. Para tanto, é indispensável o conhecimento de parâmetros relacionados às plantas, ao solo e ao clima, para determinar o momento oportuno de irrigar e a quantidade de água a ser aplicada. O manejo

racional da água de irrigação visa minimizar o consumo de energia, maximizar a eficiência do uso da água e manter favoráveis as condições de umidade do solo e de fitossanidade das plantas. Pode ser baseado em critérios relacionados ao “status” da água no solo e nas plantas, na taxa de evapotranspiração da cultura ou na combinação de dois ou mais deles. A lâmina de água total disponível é calculada seguindo a Equação 1 (MAROUELLI et al., 1996):

$$LTD = \left(\frac{CC - PMP}{10} \right) \cdot Da \cdot Z \quad \text{Eq. (1)}$$

Em que:

LTD = lâmina de água total disponível, em mm;

CC = capacidade de campo, em % de peso seco;

PMP = ponto de murcha permanente, em % de peso seco;

Da = densidade aparente do solo, em g cm⁻³

Z = profundidade efetiva do sistema radicular das plantas, em cm.

Segundo Schreiner et al. (2010), classes diferentes de solo, sob atividades agropecuárias, sem manejo adequado da água no solo podem sofrer alterações nas propriedades físicas, tais como aumento da densidade no solo, redução da porosidade total, especialmente em função da diminuição dos macroporos e aumento na resistência à penetração.

Segundo Tsegaye et al. (2004), a umidade do solo é uma variável imprescindível no estudo e modelagem de variados processos agrônômicos, hidrológicos e ambientais. Gonçalves et al. (2011) afirmam que a maioria desses processos se relacionam com as variabilidades temporal e espacial da umidade do solo, de modo que a quantificação dessas variabilidades requerem técnicas que permitam medidas rápidas, exatas, passíveis de automação e de repetição no mesmo local, com o mínimo de perturbação do solo. Para Kim et al. (2008), essas variabilidades das umidades do solo podem ser minimizadas com o aumento da eficiência da irrigação, o que reduz impacto ambientais e melhora os rendimentos produtivos.

Outra importância das umidades do solo é estudada como a sua influência nas características de estresses mecânicos sofridos pelo solo. Segundo Dias Junior (2000) a aplicação de cargas em solos agrícolas é o que resulta no estresse mecânico do solo. A capacidade do solo de resistir a esses estresses contribui para a qualidade da porosidade e da subsequente relação líquido-gasoso nesses poros. O limite em que o solo resiste a isto é denominado de ponto de pré-consolidação (HORN e LEBERT, 1994; DIAS JUNIOR, 2000;

RICHARDS et al., 2000; TRAUTNER et al., 2003). Alguns trabalhos têm sido realizados com o propósito de correlacionar às umidades do solo, com o ponto de pré-consolidação, na forma de evitar situações que esse ponto seja ultrapassado. A situação de estresse no solo é agravada quando não existe um controle de umidade, principalmente para casos elevados de umidade ou quando o estresse ultrapassa os níveis anteriormente suportados (KONDO e DIAS JÚNIOR, 1999; DIAS JUNIOR, 2000; SILVA et al., 2002). Antunes Júnior (2016), utilizou umidades na capacidade de campo e no ponto de murcha permanente por meio da curva de retenção de água no solo para avaliar compactação de um Latossolo Vermelho, em Anápolis - GO. Mantovani (1987) observou a relação entre o teor de umidade e a densidade global do solo, submetidas a energias de compactação, que é representada pelo número de passadas do rodado do trator no solo. Essa curva aponta o teor de umidade ótimo, que favorece a obtenção de valor máximo de densidade, ou seja, de compactação ficando este teor próximo de umidade correspondente à capacidade de campo.

2.6 Determinação das umidades do solo

A determinação da umidade do solo é fundamental no manejo da água em culturas irrigadas (EMBRAPA, 2013). Ao longo do tempo foram desenvolvidas diversas metodologias e equipamentos para a determinação da umidade do solo, que define o teor de água existente no solo. Entre eles, existe grande variação de precisão, de custo, praticidade e tempo em função das condições do solo (KLEIN, 2008; BRAGA et al., 2018). Existem métodos diretos e indiretos de determinação da umidade do solo, que podem ser obtidos em laboratório ou *in situ* (BUSKE, 2013). Segundo Vione (2007), os métodos diretos consistem na medida direta da umidade contida em uma amostra de solo a partir da sua desagregação, sendo que o método indireto envolve a medição de alguma propriedade física ou físico-química do solo que possa correlacionar com o conteúdo de água do mesmo.

Dentre os métodos diretos pode-se ressaltar o método gravimétrico, por ser bastante usual e normalmente utilizado como padrão para calibrações de métodos indiretos na medição da umidade de um determinado solo (FERREIRA et al., 1998). Para Vielmo (2008), dos métodos gravimétricos destacam-se o método padrão de estufa, o método das pesagens e o método dupea. Dos métodos indiretos, pode-se citar: método Speedy, sonda de nêutrons, método do TDR, métodos tensiométricos, método de capacitância elétrica, método da resistência elétrica, método blocos de gesso, método de colman e método químico.

O método padrão da estufa, também conhecido como o método clássico de obtenção da umidade do solo, embora seja o mais utilizado, por ser altamente preciso e seguro, requer equipamentos que nem sempre estão prontamente disponíveis, além de ser um método demorado e destrutivo é também pouco prático, por impossibilitar a obtenção de resultados instantâneos (CAMARGO e COSTA, 1960; SILVA, 2013). Consiste na secagem da amostra de solo em estufa a 105-110°C, em que por diferença de massa entre o solo úmido e o solo seco, obtêm-se os valores de umidade do solo (GHELFI FILHO, 1988; SILVA, 2013). Apesar de, no geral, os métodos gravimétricos serem de relativa simplicidade são, em sua maioria, destrutivos, necessitando de grande número de amostras, são insensíveis às heterogeneidades internas, além de pressuporem a validade da hipótese de isotropia espacial (BIASSUSI et al., 1999).

Para os métodos indiretos, pode-se citar o método de Speedy, normalizado pelo Departamento Nacional de Estradas e Rodagem (DNER-ME, 1994). O aparelho de Speedy é constituído por um reservatório metálico fechado que se comunica com um manômetro destinado a medir a pressão interna. Dentro desses reservatórios são colocados, em contato, uma certa quantidade de solo úmido e uma determinada porção de carbureto de cálcio (CaC_2). De acordo com a variação da pressão interna obtém-se a quantidade de água existente no solo (CAPUTO, 1988). Vielmo (2008), aponta sua facilidade de manuseio e rápida obtenção da umidade, com custo operacional baixo, porém como desvantagem, a de ser um método destrutivo.

O princípio de funcionamento da sonda de nêutrons é bastante simples, estando fundamentado na perda de energia dos nêutrons rápidos (moderação de nêutrons) por meio de choques com os núcleos leves no sistema solo-água-ar (FALLEIROS, 1994). Ferreira et al., (1998) destacam o método da sonda de nêutrons por permitir a aferição da umidade do solo com o mínimo de alteração no perfil, a qualquer momento e de forma extremamente rápida e prática, porém, com a limitação do operador estar exposto à radiação do aparelho e o custo do equipamento ser elevado.

Manieri et al. (2007) citam o método do TDR, ou reflectometria no domínio do tempo, que é determinado pelo de tempo propagação de ondas eletromagnéticas em uma sonda metálica inserida no solo. Possui as vantagens de ter respostas com alta exatidão, não utiliza radiação ionizante, sofre pequena influência da salinidade do solo, da densidade, textura e temperatura, tendo a possibilidade de automação. Coelho et al. (2016) apontam desvantagens no método do TDR como custos elevados e limitação na quantidade de dados observados.

O tensiômetro é um aparelho desenvolvido por W. Gardner em 1922 (CAMARGO et al., 1982; BLACK, 1968) que é composto por uma cápsula cerâmica porosa ligada a um manômetro por um tubo num sistema, cheio de água, hermeticamente fechado (CAMARGO et al., 1982). O método do tensiômetro consiste em medir a tensão com que a água está retida pelas partículas do solo, também conhecido por potencial matricial. Possui como vantagens o conhecimento em tempo real da tensão de água no solo e, indiretamente, do teor de água no solo; é de fácil utilização, desde que convenientemente instalado, sendo de custo relativamente baixo, com facilidade de acesso no mercado (AZEVEDO et al., 1999). Otto e Alcaide (2001) apontam como desvantagem do tensiômetro a limitação de medidas de potencial matricial entre 0 e -100 kPa.

2.6.1 Determinação das umidades na capacidade de campo e no ponto de murcha permanente

É fato que a determinação da umidade do solo é importante no monitoramento hídrico de áreas agrícolas, bem como em estudos que enfoquem a relação solo-água-plantas (FERREIRA et al., 1998). Entretanto, os métodos citados no item 2.6 para obtenção dessa umidade necessitam de informações de limites de água no solo para tomadas de decisões. O estudo da curva característica ou curva de retenção de água no solo, assim como dos pontos gerados pela curva é o que determina as umidades fundamentais para os estudos de solo. Sem essas informações somente com as umidades obtidas pelos métodos citados faltariam parâmetros avaliativos capazes de inferir na tomada de decisão a respeito de ações como: quanto e quando irrigar (RESENDE et al., 2003), umidade ótima de compactação (MANTOVANI, 1987), ponto de pré-consolidação (KONDO e DIAS JÚNIOR, 1999), entre outros.

A curva de retenção de água, também conhecida como curva característica de umidade, é um dos parâmetros básicos requeridos no estudo dos processos de transferência da água no solo (FREITAS JÚNIOR e SILVA, 1984). Para Vieira e Castro (1987) a retenção de água na matriz do solo ocorre por duas forças principais: forças capilares e forças de adsorção, sendo denominadas de forças mátricas. A curva de retenção é expressa pela relação entre o potencial matricial e o teor de umidade do solo. Os primeiros trabalhos com a tentativa de correlacionar a umidade do solo e seu potencial matricial tiveram início com Briggs e McLane (1910), Veihmeyer et al. (1924) e Thomas e Harris (1925). Segundo Teixeira e Bhering (2017), a CC e o PMP são obtidos mediante estudos dos potenciais de água no solo, que podem ser aplicados por sucção (tensão) ou pressão, caracterizados na curva de retenção de água no solo.

Usualmente a umidade das amostras de solo é determinada após equilíbrio nos potenciais de 0 kPa; 1 kPa; 6 kPa; 10 kPa; 33 kPa; 100 kPa; 500 kPa; 1.000 kPa e 1.500 kPa. Childs (1940) aponta que a curva de retenção é uma das propriedades físico-hídricas mais difíceis de se caracterizar, devido o tempo que consomem nas análises, bem como a intrínseca movimentação da água da amostra devido à histerese, que Bonder (2008) define como sendo a diferença entre as curvas de secagem e de umedecimento do solo, geradas pela trajetória de variações do teor de umidade.

Os ensaios de determinação das umidades na CC e no PMP podem ser feitos em campo ou em laboratório. A determinação em campo (*in situ*) da CC pode ser feita pelo Método do Perfil Instantâneo – MPI ou pelo Método Padrão (HILLEL et al., 1972; EMBRAPA, 1979; COSTA et al., 1989; FABIAN e OTTONI FILHO, 1997, 2000; BERNARDO et al., 2008). Em condições de laboratório, pode-se obter as umidades na CC por meio do Método do Tubo, do Funil de Büchner, da Mesa de Tensão, da Câmara de Pressão de Richards e pelo Método da Centrífuga (RICHARDS e FIREMAN, 1943; WATSON, 1966; FERNANDES et al., 1978; COSTA, et al. 1997; TEIXEIRA e BHERING, 2017). Bernardo (1982), afirma que a determinação do PMP em condições de campo é muito difícil pelo fato da umidade do solo variar com a profundidade e sempre ter movimento de água de pontos distintos para a zona do sistema radicular da planta que indica o PMP. Por isso, são indicados para determinação do PMP os métodos classificados em direto (Método Direto ou Fisiológico) e indireto (Panela de Pressão/Membrana de Richards e Método da Centrífuga) (KIEHL, 1979; REICHARDT, 1987; TEIXEIRA e BHERING, 2017).

Costa et al. (1997) citam o Método do Perfil Instantâneo como um dos métodos de obtenção da CC *in situ*, embora para diversos autores, esse método seja mais utilizado para determinação da condutividade hidráulica no solo (WATSON, 1966; HILLEL et al. 1972). Segundo Paige e Hillel (1993), o Método de Perfil Instantâneo baseia-se na análise dos componentes da equação de Richards em perfis potenciais e fluxos provisórios durante a drenagem vertical que ocorre após a saturação do solo. O método apresenta como vantagem principal a possibilidade de se medir diretamente no campo as propriedades hidráulicas (CC), sem a necessidade de aguardar o estabelecimento de um equilíbrio dinâmico (HURTADO et al., 2005).

O Método Padrão (EMBRAPA, 1979; BERNARDO et al., 2008) para determinação da CC *in situ* é feito em uma bacia de dois metros de diâmetro, onde é aplicada uma lâmina de água com o intuito de saturar o perfil de solo em estudo (umedecido até uma profundidade de

1,5 m). O conteúdo de água aplicado no solo, é obtido pela subtração da porosidade e da umidade inicial. São aferidas periodicamente as umidades do solo até o ponto de equilíbrio, que dura aproximadamente 90 horas, para assim gerar um gráfico do teor de água em função do tempo, e por meio da regressão potencial estimar a CC (OLIVEIRA et al., 2005; BRITO et al., 2011; SOUZA et al., 2013). Diversos autores indicam esse método como o de maior eficácia na determinação da CC (FABIAN e OTTONI FILHO, 2000; BERNARDO et al., 2008; ARAÚJO et al., 2009; SAMPAIO et al., 2010; SOUZA et al., 2013).

Pelo Método do Tubo (COSTA et al., 1997) determina-se a CC a partir de um tubo PVC, coberto na parte inferior por uma tela de nylon, adicionando-se solo seco e peneirado e levemente compactado de forma a simular os valores de densidade global determinado em campo. Pode-se simular a determinação em condições de um vaso (REICHARDT, 1985) ou em condições de campo. O processo segue saturando-se o tubo e colocando-o para drenar sobre um outro cilindro contendo o mesmo solo seco. Cobre-se a base do conjunto dos cilindros com uma folha de alumínio para evitar a evaporação e assim é feita a drenagem do excesso de água. Afere-se a umidade periodicamente até o ponto de equilíbrio e assim é obtida a CC (FERNANDES et al., 1978; COSTA et al., 1997).

O funil de Büchner é um equipamento de sucção que foi introduzido por Bouyoucos (1929) e adaptado por Haines (1930). Possui uma placa cerâmica que serve de meio poroso que aplica a sucção da água no solo (Smith e Mullins, 2000). Vielmo (2008) cita que quando se usa o funil de Büchner, é necessário colocar papel de filtro sobre os orifícios de modo a tapá-los completamente, onde o papel deve ser molhado com solvente para melhorar a aderência. O funil de Büchner ou funil de Haines, como é atualmente conhecido, tem como principal limitação o uso de apenas uma amostra de solo por vez, necessitando de vários funis para agilizar a determinação da curva de retenção (LIMA e SILVA, 2008; SALES et al., 2013). Vários funis Büchner são frequentemente usados para determinar a curva mais rapidamente, o que aumenta o custo do processo (PETERS et al., 2014).

A mesa de tensão (Figura 8) foi inicialmente proposta por Leamer e Shaw (1941) e difundida no Brasil por Oliveira (1968). O princípio de funcionamento das mesas de tensão se baseia na remoção de água até uma determinada tensão controlada por meio da aplicação de uma diferença de potencial gerada por uma coluna de água pendente ou bomba de vácuo. Para as mesas de tensão de areia-caolin ou para potenciais maiores que 10 kPa, normalmente é utilizada uma bomba de vácuo para se obter o potencial desejado (TEIXEIRA e BHERING, 2017). Oliveira (1968) descreve e cita a utilização da mesa de tensão para baixas tensões de

água no solo. Oliveira (1983) e Lima e Silva (2008) demonstram em seus trabalhos o uso e a calibração de uma mesa de tensão para tensões na CC. Sales et al. (2013) apontam como principal vantagem da mesa de tensão a possibilidade do número de amostras, podendo chegar a 50 em um único ensaio.



FIGURA 8 – Conjunto para determinação da curva de retenção de água no solo – Mesa de Tensão + extrator de membrana.

Autor: SoloTest (2020).

Entre as metodologias para determinação da curva de retenção de água, uma das mais utilizadas é o tradicional princípio da placa de pressão ou câmara de Richards (Figura 9). A câmara de Richards é um equipamento que consiste numa câmara de pressão hermeticamente fechada (RICHARDS e FIREMAN, 1943; DAVALO, 2013). As amostras de solos são dispostas em um meio poroso (placa de cerâmica) e dessaturadas até o equilíbrio com um potencial aplicado por pressurização. Para manter a pressurização, as amostras são mantidas em câmaras herméticas, sobre placas porosas de cerâmica, previamente saturada com água desaerada, providas de um sistema de drenagem, sendo a pressurização fornecida por um sistema com compressores, reguladores de pressão e manômetros. O potencial (pressão)

desejado é ajustado e, conseqüentemente, a água retida com forças menores que o potencial aplicado move-se em direção e através da placa cerâmica, passando para o sistema de drenagem. O equilíbrio é determinado quando a drenagem do efluxo cessa e o conteúdo de água é estimado gravimetricamente por pesagem (TEIXEIRA e BHERING, 2017). A câmara de Richards, embora não tenha restrições sobre aplicações de altas pressões (funcionando de 3 até 150 mca), é pouco precisa quando se pretende usá-la com baixas pressões, devido ao manômetro não favorecer a aplicação de tais pressões. Além disso, oferece dificuldades para o estabelecimento do ponto de equilíbrio entre a pressão aplicada e a água drenada, exigindo longo tempo para os ensaios (até dois meses), além do alto custo do equipamento (ALMEIDA, 2008; TAVARES et al., 2008 citados por SALES et al., 2013).

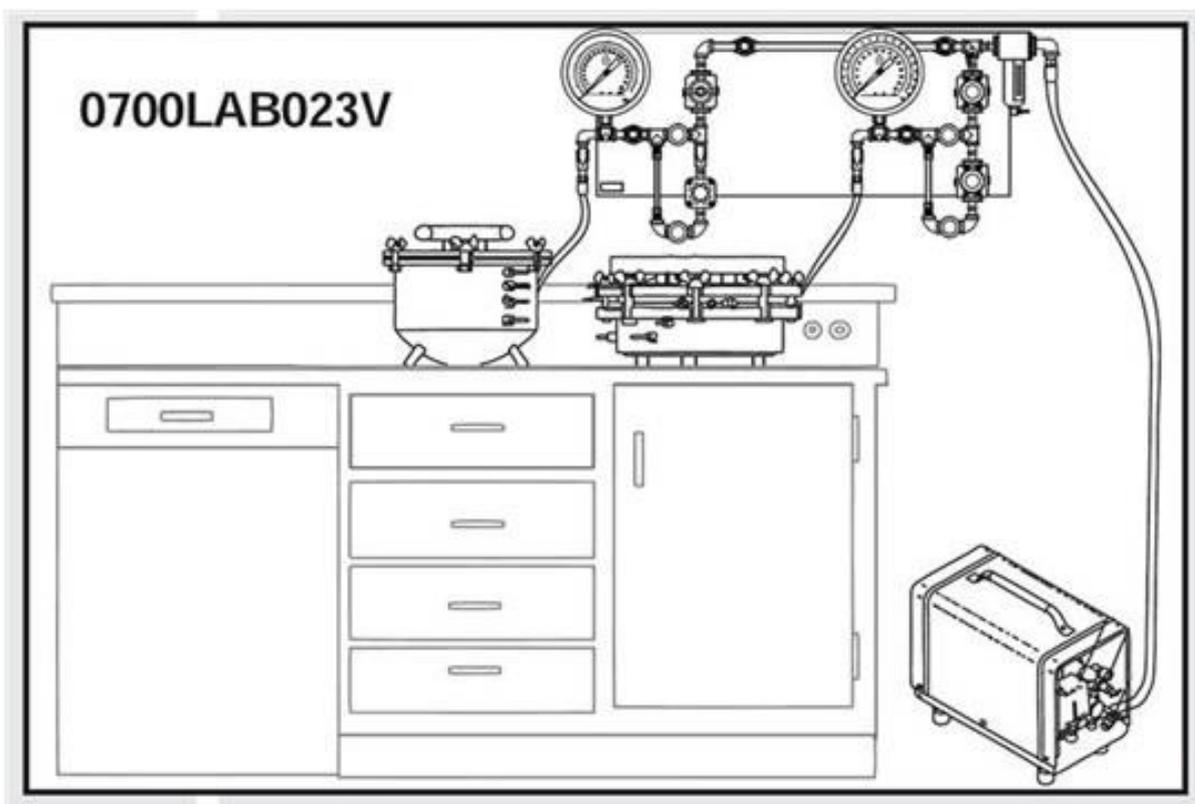


FIGURA 9 – Conjunto para determinação da curva de retenção de água no solo – Painela ou Câmara de Richard.

Autor: SondaTerra (2020).

Os primeiros trabalhos correlacionando o método da centrífuga com a umidade do solo em determinados potenciais foram apresentados por Briggs e McLane (1910) e Veihmeyer et al. (1924). Posteriormente, Thomas e Harris (1925) abordaram sobre o tempo de centrifugação na determinação do equivalente de umidade. A partir do trabalho proposto por Russel e Richards (1938) que foi possível complementar a teoria da determinação da curva de retenção

de água no solo por meio de centrífugas. A centrifugação de uma amostra de solo previamente saturada gera um potencial crescente ao longo de seu comprimento (altura da amostra ao longo do anel volumétrico). Com base nesse princípio, é possível calcular a velocidade angular de uma centrífuga (W) em rotações por minuto para uma dada tensão que se queira aplicar à amostra (h), expressa em kPa (TEIXEIRA e BHERING, 2017). Com o advento das câmaras de pressão de Richards (RICHARDS e FIREMAN, 1943) e suas facilidades, as centrífugas foram relegadas a um segundo plano, em virtude, provavelmente, das dificuldades operacionais inerentes ao controle preciso da velocidade angular (FREITAS JÚNIOR e SILVA, 1984).

Oliveira e Martins (1966) indicavam a determinação da umidade no ponto de murcha permanente por meio do método fisiológico, utilizando-se uma planta indicadora. Este era um processo bastante demorado e trabalhoso por isso, muitos investigadores pesquisaram métodos que o substituísse com certa precisão, maiores facilidades e rapidez. O método foi primeiramente empregado por Briggs e Shantz (1911) que propuseram a umidade do PMP equivalente à água retida no solo na tensão de 1.500 kPa, porém outros autores apontaram oscilações nas tensões do PMP comparando-se ao método da câmara de pressão de Richards (KLUTE, 1986; KLEIN et al., 2006; ALVES et al., 2010). Coelho et al. (2014) compararam os PMP gerados pelos métodos fisiológico e câmara de pressão de Richards, encontrando diferenças significativas entre as duas metodologias, para o feijão caupi. Os trabalhos envolvendo o método fisiológico para a determinação do PMP nos solos do Brasil são escassos devido a sua difícil e demorada metodologia, podendo-se citar trabalhos como Oliveira e Martins, (1966); Cirino e Guerra, (1994); Souza et al. (2002); Klein et al. (2006); Coelho et al. (2014).

Segundo Klute (1986) os métodos utilizados na determinação da curva de retenção de água no solo demandam muito tempo, são dispendiosos e caros. Devido às eminentes dificuldades na determinação dos parâmetros relacionados às propriedades hídricas dos solos, tanto no campo quanto em laboratório, verifica-se um crescente interesse pelo estabelecimento de métodos indiretos de estimativas da CC e PMP que utilizam outras propriedades edáficas mais facilmente obtidas e de menor custo, incluindo, até mesmo, características morfológicas, conhecidas como funções de pedotransferência (TOMASELLA et al., 2000; BAKER, 2008; PAZ et al., 2009; NASCIMENTO et al., 2010 citados por NUNES, et al. 2015).

2.7 Funções de Pedotransferência (FPT)

Diversos autores ao longo do tempo buscaram correlacionar atributos ou propriedades do solo de difícil obtenção com outras de fácil obtenção por meio de equações genéricas, conhecidas por funções de pedotransferência (GUPTA e LARSON, 1979; RAWLS et al., 1982; WOSTEN e GENUCHTEN, 1988; VEREECKEN et al., 1989; BUSSCHER, 1990; WILLIAMS et al., 1992; RAJKAI et al., 1996; VAN DEN BERG et al., 1997; TORMENA e SILVA, 2002; ALMEIDA et al., 2008; SILVA et al., 2008).

A expressão Função de Pedotransferência - FPT (Pedotransfer Function - PTF, em inglês) foi criada por Bouma (1989), com o significado de “transformando dados que possuímos em dados que necessitamos”. Funções de Pedotransferência permitem que informações básicas de solo, disponíveis em relatórios de levantamentos de solos ou em Sistemas de Informação Geográfica (SIGs), sejam transformadas em outras, de obtenção mais laboriosa e que possuem um maior custo na obtenção. Funções de Pedotransferência são funções preditivas de certas propriedades dos solos a partir de outras facilmente medidas e rotineiramente obtidas a custos mais baixos. As Funções de Pedotransferência atendem às demandas por dados frequentemente requeridos a partir de dados normalmente disponíveis em levantamentos de solos e bases de dados (MINASNY et al., 2003).

Para Hillel (1998), as FPTs podem ajudar a desenvolver valores de potencial matricial e podem prever a expressão da curva de retenção de água no solo. Williams et al. (1983) deram os primeiros passos de forma mais abrangente, na formulação das FPTs, gerando um modelo que classificava a retenção de água com base em classe textural. Posteriormente, Williams et al. (1992) utilizando parâmetros de textura e estrutura do solo, estimaram os parâmetros do modelo de Campbell (1974) para a curva de retenção de água. Diversos autores buscaram reproduzir esses parâmetros do modelo de Campbell ao longo do tempo, como, Cresswell e Paydar (1996), Paydar e Cresswell (1996) e Smettem et al. (1999). Pode-se citar também autores que desenvolveram FPTs para estimativas da CC e PMP, a exemplo de Littleboy (1997) com as estimativas da CC e do PMP, medidas em campo, por meio do teor de Argila, teor de Areia, Fração Grosseira e Densidade do solo. Bristow et al. (1999) com a predição da CC e PMP por meio da granulometria. Minasny et al., (1999) com a predição dos teores de água para as tensões de 10, 33 e 1500 kPa, tendo como atributos preditores a granulometria e a densidade do solo. Minasny e McBratney (2001), com uso das FPTs para estimar os parâmetros da equação de Van Genuchten (1980) utilizando-se da granulometria e

da densidade do solo. Posteriormente, Minasny e McBratney (2002) utilizaram Redes Neurais Artificiais (RNAs) para o desenvolvimento das FPTs na predição dos parâmetros da equação van Genuchten (1980) para retenção de água no solo. Bayat e Zadeh (2018) fizeram a estimativa da curva de retenção usando modelos de curva de resistência à penetração.

Arruda et al. (1987) contribuíram, no Brasil, com a primeira tentativa de estimar água disponível (AD), usando textura do solo, por meio de equações de regressão. Para a curva de retenção de água no solo, desenvolvidas por funções de pedotransferência, utilizando-se das equações de Brooks-Corey ou van Genuchten (1980), os pioneiros no país, foram: Berg et al. (1997), Tomasella e Hodnett (1998) e Tomasella et al. (2000). Em seguida, Giarola et al. (2002), estimaram as umidades na CC, PMP e AD, por meio de regressões múltiplas, em função dos parâmetros: teores de argila, silte e óxidos de Fe e de Al. Netto (2007) desenvolveu FPTs para estimar a retenção de água no solo de uma microbacia hidrográfica por meio de análises em Redes Neurais Artificiais. Silva et al. (2008), contribuíram com as FPTs para as curvas de retenção de água e de resistência do solo à penetração. Michelon (2010) estudou pedofunções para retenção de água de solos do Rio Grande do Sul irrigados por aspersão. Costa (2012) determinou em seu trabalho a retenção e disponibilidade de água em solos de Santa Catarina, por funções de pedotransferência. Soares (2013) fez uso de diferentes metodologias na geração de funções de pedotransferência para retenção de água em solos do Rio Grande do Sul.

Até então, poucos trabalhos foram realizados no Estado de Goiás envolvendo funções de pedotransferência para estimativa de curva de retenção de água no solo ou das umidades na CC e PMP. Pode-se citar Menegaz et al. (2015), que gerou funções de pedotransferência para estimar a retenção e disponibilidade de água para solos do Centro-Sul do Brasil. França (2011) desenvolveu funções de pedotransferência para estimativa de estoques de carbono em solo de áreas de campo limpo úmido do Distrito Federal.

Minasny et al. (2003) definiram dois princípios básicos de FPTs para evitar o mau uso do conceito de pedotransferência. O primeiro princípio caracteriza a eficiência, que se define em não prognosticar algo que é mais fácil e mais barato medir ou determinar. O segundo princípio é a incerteza, que determina não usar FPTs, a menos que se possa avaliar a incerteza associada e, para um determinado problema, se um conjunto de FPTs alternativas está disponível, usar aquela com menor variância. Minasny et al. (2003) também classificam as FPTs baseadas em: variáveis preditoras e preditas; e abordagem. Os autores propuseram um esquema prático para gerar as funções de pedotransferência (Figura 10).

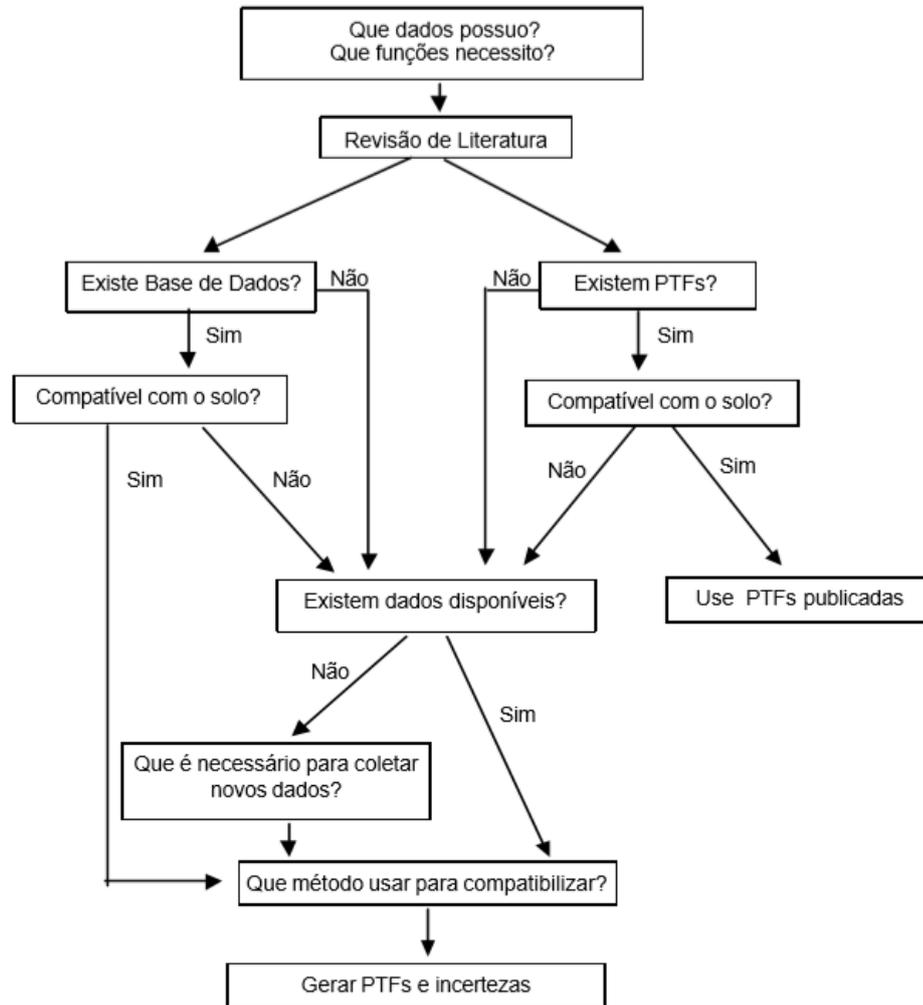


FIGURA 10 – Sequência para determinar as funções de pedotransferência.
Autor: Minasny et al. (2003).

2.8 Regressão linear múltipla (RLM)

Segundo Marôco (2003), o termo ‘regressão’ foi proposto pela primeira vez por Sir Francis Galton em 1885. O termo “Análise de Regressão” define um conjunto vasto de técnicas estatísticas usadas para modelar relações entre variáveis e prever o valor de uma ou mais variáveis dependentes (ou de resposta) a partir de um conjunto de variáveis independentes (ou predictoras).

A palavra linear literalmente significa “relativo a uma linha”, mas em termos estatísticos, a linha referida é uma linha reta. Um modelo linear é, portanto, um modelo baseado sobre uma linha reta; isso significa que geralmente estamos tentando resumir nossos dados observados em termos de uma linha reta (FIELD, 2009).

A correlação linear é uma correlação entre duas variáveis, cujo gráfico aproxima-se de uma linha. O gráfico cartesiano que representa essa linha é denominado diagrama de dispersão. Para poder avaliar melhor a correlação entre as variáveis, é interessante obter a equação da reta; essa reta é chamada de reta de regressão e a equação que a representa é a equação de regressão. O diagrama de dispersão é construído de acordo com os dados amostrais de n observações e a equação de regressão é dada pela Expressão 2 (CORREA, 2003):

$$Y = aX + b \rightarrow Y' = aX + b \quad \text{Eq. (2)}$$

Em que:

X = Variável independente;

$Y \rightarrow Y'$ = Variável dependente;

“Esse tipo de notação, de Y para Y' , caracteriza que não se trata de uma relação funcional para a determinação da reta, e sim de uma relação estatística, em que a distribuição está baseada em estimativas de dados colhidos por amostragem.” (CORREA, 2003)

A regressão linear múltipla foi abordada inicialmente por Stenberg et al. (1960). Bottenberg e Ward (1963) aprofundaram o tema com o livro ‘Regressão Linear Múltipla Aplicada’ (Applied multiple linear regression). Regazzi e Leite (1992) relataram que a RLM é uma ferramenta de estimativa amplamente empregada, que necessita de estudos prévios das variáveis dependentes com as independentes, para uma boa capacidade de predição do modelo estatístico empregado. A relação direta entre esses dois fatores é o que dita a capacidade do modelo estimar ou fazer inferências estatísticas precisas. Tabachnick e Fidell (1996) classificaram a regressão múltipla como um conjunto de técnicas estatísticas que permitem avaliar a relação entre variáveis dependentes e independentes. Action (2020) diz que a regressão múltipla é uma coleção de técnicas estatísticas para construir modelos que descrevem de maneira razoável relações entre várias variáveis explicativas (independentes) de um determinado processo. A diferença entre a regressão linear simples e a múltipla é que na múltipla são tratadas duas ou mais variáveis explicativas (independentes).

Um dos problemas mais importantes na área de pesquisa dos modelos lineares é a seleção de variáveis explicativas (independentes). Os modelos de seleção mais comuns, encontrados na maioria dos livros de regressão, são o *forward*, o *backward* e o *stepwise*, métodos com base em testes de hipótese. O método de seleção do tipo *forward* (seleção à frente)

é um dos mais simples, no qual a entrada das variáveis independentes no sistema, ocorre de acordo com o grau de correlação, em módulo, entre as variáveis dependentes e independentes, escolhendo-se a variável de maior correlação. Efetua-se então uma regressão linear entre as variáveis dependentes e independentes, caso o valor da estatística t dessa variável testada indique sua não rejeição, a variável será permanente no modelo. O procedimento continua para as outras variáveis até todas as variáveis estarem inclusas no modelo, ou até uma variável ser rejeitada no teste de significância, o que determina o encerramento do procedimento (MARQUES, 2018). O método de seleção *backward* (seleção para trás) inicia-se pelo ajuste de todas as variáveis independentes candidatas a ficar no modelo. Compara-se o desvio do modelo contendo todas as variáveis com os desvios dos modelos que resultam da exclusão individual de cada variável. Se o nível descritivo do teste da razão de verossimilhança for significativo a variável fica no modelo e o procedimento se encerra, senão, ela sai do modelo. O processo continua até observar uma variável com a menor significância testada e que esta, seja significativa, encerrando o procedimento (SILVA, 2006)

O procedimento *stepwise* (seleção passo a passo) tem tido maior aceitação nos estudos dentro da área da ciência do solo e vem sendo altamente empregado no estudo das relações entre parâmetros de solos tropicais (RIBON et al., 2014). A regressão *stepwise* geralmente é a estratégia escolhida para estudos exploratórios. Quando se está utilizando este tipo de regressão, o pesquisador, desprovido de uma teoria consistente sobre os fenômenos estudados, está interessado apenas em descrever relacionamentos pouco conhecidos entre variáveis e não em os explicar. Neste tipo de regressão, a seleção da sequência de entrada dos preditores na equação é feita, estatisticamente, sem um modelo teórico consistente a ser seguido (ABBAD e TORREZ, 2002). O procedimento começa com o passo à frente, mas depois que a segunda variável entra no modelo, o teste da razão de verossimilhança é realizado para verificar se a primeira variável permanece no modelo. Caso permaneça, uma terceira variável é selecionada da mesma forma que no procedimento passo à frente. Se uma terceira variável entra no modelo, testa-se para verificar se as duas primeiras continuam no modelo. Pode acontecer que uma delas ou as duas sejam eliminadas. Tenta-se então a inclusão de uma nova variável. Caso entre, tenta-se a eliminação das que já estão no modelo. O procedimento termina quando não se consegue nem adicionar, nem eliminar variáveis (SILVA, 2006).

Diversos autores, em um panorama global, apresentaram o uso da regressão linear múltipla como ferramenta de estimativa, podendo-se citar os trabalhos de Koklay e Clark (1999), Souza et al., (2007), Nathans et al., (2012), dos quais Merdun et al. (2006) utilizaram

as RLMs para prever a retenção de água no solo e a condutividade hidráulica, Ghanbarian-Alavijeh e Millán (2010) desenvolveram funções de pedotransferência por meio de RLMs para estimar a curva de retenção de água no solo, Liao et al. (2011) avaliaram as características de retenção de água no solo e sua variabilidade espacial usando as FPTs formuladas por RLMs e Nguyen et al. (2017) fizeram a comparação da regressão estatística e técnicas de mineração de dados na estimativa de água em solos tropicais.

Diversos trabalhos foram realizados no Brasil utilizando-se RLMs, dos quais é possível citar, Maia et al. (2001) com a classificação da composição iônica da água de irrigação usando regressão linear múltipla. Brito e Sampaio (2001) com o título do trabalho: “efeito de fontes de proteína nas características da carcaça e avaliação do rendimento de carne aproveitável estimada por meio de equações de regressão linear múltipla em touros $\frac{3}{4}$ Canchim $\frac{1}{4}$ Nelore”. Baptistella et al. (2006), utilizando a RLM na determinação dos valores venais de imóveis urbanos. Valentini et al. (2008) com a estimativa do fluxo de CO₂ do solo, por meio de regressão múltipla, para floresta de transição no Noroeste de Mato Grosso. Pode-se apontar também os trabalhos que correlacionaram o uso de regressões lineares múltiplas na predição das umidades do solo e da curva de retenção de água no solo, tais como: Giarola et al. (2002); Silva et al. (2008); Michelon (2010); Costa (2012); Soares (2013); Menegaz et al. (2015), entre outros.

2.9 Redes neurais artificiais (RNAs)

Redes neurais são sistemas de computação com nós interconectados que funcionam como os neurônios do cérebro humano. Usando algoritmos, elas podem reconhecer padrões escondidos e correlações em dados brutos, agrupá-los e classificá-los e, com o tempo, aprender e melhorar continuamente (SAS, 2020). Haykin (2001) propõe que as RNAs se inspiram no cérebro humano pelo fato do aprendizado da rede ocorrer por meio do ambiente e pelos pesos atribuídos aos neurônios servirem como forma de armazenar o conhecimento adquirido.

Uma Rede Neural Artificial consiste em uma estrutura conexionista, na qual o processamento é distribuído por um grande número de pequenas unidades densamente interligadas. Este paradigma procura entender e emular as propriedades decorrentes do alto grau de paralelismo e conectividade dos sistemas biológicos. Muitas aplicações são constantemente encontradas para as Redes Neurais Artificiais, ao mesmo tempo que os seus fundamentos teóricos vão se tornando cada vez mais sólidos devido ao trabalho incessante de um número cada vez maior de pesquisadores. As áreas de aplicação são as mais diversas, com grandes e

pequenas aplicações em campos diversos, como engenharia, economia, agronomia, medicina etc., resolvendo problemas que envolvam extração de características, classificação, categorização/clusterização; estimativa e previsão; otimização; aproximação de funções; dentre outras (FURTADO, 2019).

2.9.1 Breve histórico

A sequência de acontecimentos históricos relacionados às RNAs teve início em 1943, com a apresentação do neurônio artificial por McCulloch e Pitts (1943). Hebb (1949) foi quem postulou a primeira regra de aprendizado. Rosenblatt (1958) desenvolveu o modelo *Perceptron*, que foi o primeiro modelo com aprendizado supervisionado, sendo a forma mais simples de RNA usada para classificar padrões de forma linear, por conter um único neurônio e pesos ajustáveis. Posteriormente, Widrow e Hoff (1960) formularam o modelo *adaline*, que era semelhante ao *Perceptron*. O modelo *Perceptron* possuía limitações que, por conseguinte, levou os autores Minsky e Papert (1969) a criticarem, de forma negativa, contra a possibilidade de evolução e resolução de problemas complexos utilizando-se esse modelo. Em 1975 foi apresentado um novo modelo de *perceptron* com múltiplas camadas e auto-organização, com o trabalho de Fukushima (1975). Porém, somente com a publicação de Rumelhart et al. (1986), que propuseram o algoritmo de retropropagação de erros (error backpropagation), que foi apresentado uma solução universal para as limitações do modelo *perceptron*, que consistia no treinamento dos pesos da rede com múltiplas camadas.

2.9.2 Neurônio Biológico

A origem da teoria de Redes Neurais remonta aos modelos matemáticos e aos modelos de engenharia, de neurônios biológicos. A célula nervosa, ou neurônio, foi identificado anatomicamente e descrito com notável detalhe, pelo neurologista espanhol Ramón y Cajal no século 19 (KOVÁCS, 2006). Os neurônios (Figura 11) são células excitáveis, capazes de produzir e propagar sinais elétricos. Como estas características permitem processar e transmitir informações, estas células tornaram-se os blocos fundamentais presentes nos sistemas nervosos dos mais diferentes animais. São os neurônios que ativam desde a codificação de estímulos sensoriais até a contração de músculos, passando por todas as etapas intermediárias de

processamento das informações sensoriais, memória, tomada de decisões, etc (CARELLI, 2008).

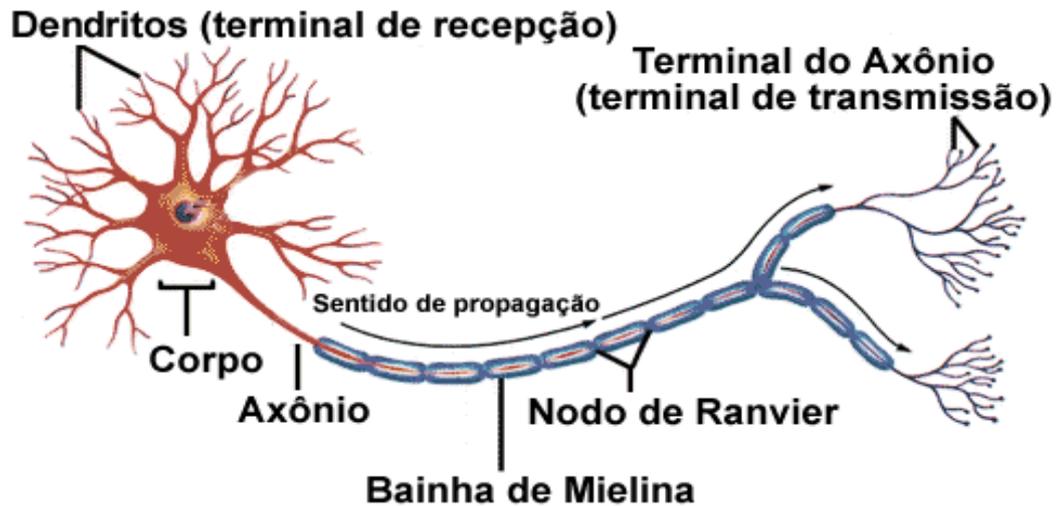


FIGURA 11 – Representação de um neurônio biológico.
Fonte: Canedo (2016).

Um neurônio é composto por um corpo celular, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos (terminais receptivos) formam uma malha de filamentos finíssimos ao redor do neurônio. Ao passo que o axônio (linhas de transmissão) consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito do próximo neurônio é conhecido como sinapse, que tem como papel fundamental a memorização da informação (MATSUNAGA, 2012).

2.9.3 Neurônio artificial

Uma rede neural é composta por um elevado número de elementos processadores, os neurônios, amplamente interligados por meio de conexões com um determinado valor que estabelece o grau de conectividade entre estes, denominado peso da conexão ou sinapse (FURTADO, 2019). Haykin (2001) afirma que para se conseguir um bom desempenho das RNAs, é preciso empregar uma interligação de células computacionais simples, que são denominadas de neurônios ou unidades de processamento. Vega (1999) representou um modelo de neurônio artificial em quatro partes (Figura 12): i) um conjunto de sinais de entrada (I_j), que representam os estímulos recebidos pelos dendritos no modelo de neurônio biológico e que, por sua vez, multiplicam-se ao peso sináptico ou peso (w_{ij}), que segundo Haykin (2001), servem

para armazenar o conhecimento adquirido; ii) um somador (Σ), que é encarregado de efetuar a soma dos sinais de entrada ponderados pelos respectivos pesos; e uma função de ativação (μ_i) que serve para limitar a amplitude do sinal de saída a um determinado intervalo finito, normalmente representado de $[0,1]$ e $[-1,1]$ (VEGA, 1999). Furtado (2019) apresenta 3 funções de ativação mais comuns, denominados Threshold, Linear e Sigmóide, sendo que entre elas a função mais frequentemente usada é a função Sigmoidal.

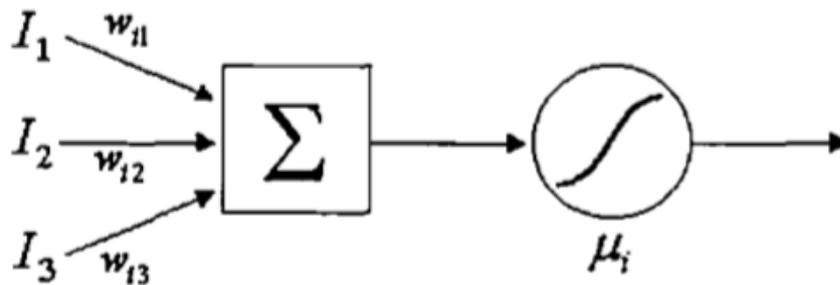


FIGURA 12 – Modelo de um neurônio artificial.

Fonte: Vega (1999).

Alguns neurônios recebem excitações do exterior e são chamados neurônios de entrada e correspondem aos neurônios dos órgãos dos sentidos. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior e são chamados neurônios de saída e correspondem aos motoneurônios que são os neurônios biológicos que excitam os músculos. Os neurônios que não são nem entrada nem saída são conhecidos como neurônios internos. Estes neurônios internos à rede têm grande importância e são conhecidos na literatura saxônica como “hidden” fazendo com que alguns traduzam como “escondidos” (BARRETO, 2002).

2.9.4 Arquitetura da rede ou Topologia

A primeira questão a ser resolvida depois de modelar os neurônios, também chamado de unidade de processamento, é definir como eles serão conectados entre si. A forma como a rede é conectada é chamada de topologia ou arquitetura (VEGA, 1999). Segundo Miranda et al. (2009), encontrar a melhor arquitetura para uma rede é um dos maiores problemas da área de redes neurais, porque demanda tempo de execução além de ser um procedimento experimental. Em geral, podemos identificar três classes de arquiteturas de rede

fundamentalmente diferentes: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes (FLECK et al., 2016). Furtado (2019) nomeia essas arquiteturas em: Rede Neural Feedforward de 1 camada, Rede Neural Feedforward Multicamadas e Redes Recorrentes ou Realimentadas.

Na RNA Feedforward (Figura 13) os neurônios são organizados em forma de camadas, os nós da camada de entrada se comunicam diretamente com a camada de saída (nós computacionais). A arquitetura do tipo feedforward em camadas apresenta uma organização similar à do córtex humano, onde os neurônios se dispõem em camadas paralelas e consecutivas, e os axônios se estendem sempre no mesmo sentido, isto é, a informação propaga-se da entrada para a saída, não existindo portanto ligações entre os neurônios de uma mesma camada ou com camadas anteriores (FURTADO, 2019).

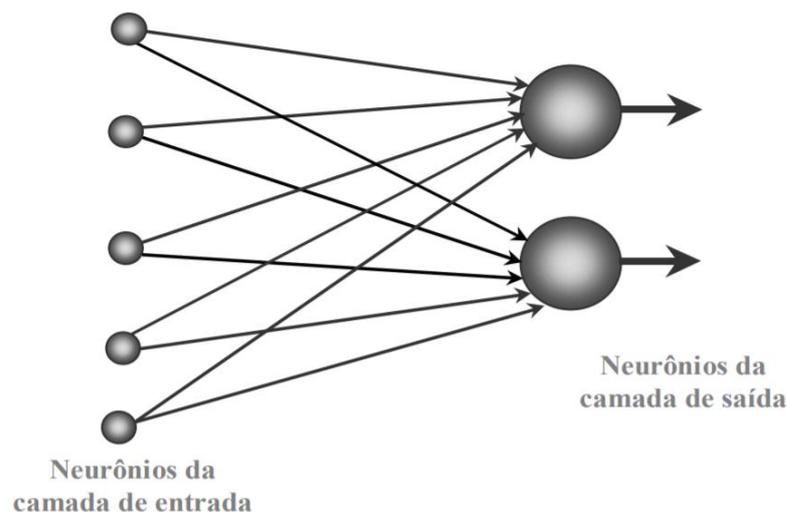


FIGURA 13 – Representação de uma Rede Feedforward de 1 camada.
Fonte: Furtado (2019).

As redes com arquitetura Feedforward de camadas múltiplas ou multicamadas, são constituídas por uma ou mais camadas escondidas de neurônios (Figura 14). São empregadas em problemas de aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos. Tipos: Perceptron Multicamadas, Redes de Base Radial (PALMIERE, 2020).

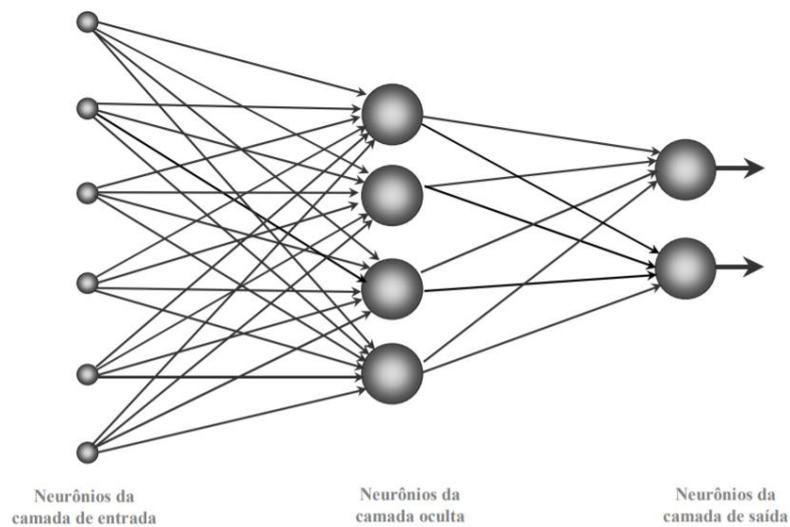


FIGURA 14 – Representação de uma Rede Feedforward Multicamadas.
Fonte: Furtado (2019).

Segundo Gers (2015), as redes neurais com topologia do tipo recorrente (Figura 15) podem reter informações ao longo do tempo e reutilizar essas informações em situações diferentes, ou seja, o aprendizado da rede é contínuo. Yi e TAN(2013) afirmam que essas redes programam as informações de forma direta e indireta, possibilitando que um neurônio de qualquer camada se conecte a qualquer outro neurônio, incluindo ele próprio, o que gera uma RNA com uma melhor capacidade de aproximação das respostas só que com a desvantagem de ser mais complexa e exigir um poder computacional muito maior que as outras arquiteturas de RNAs.

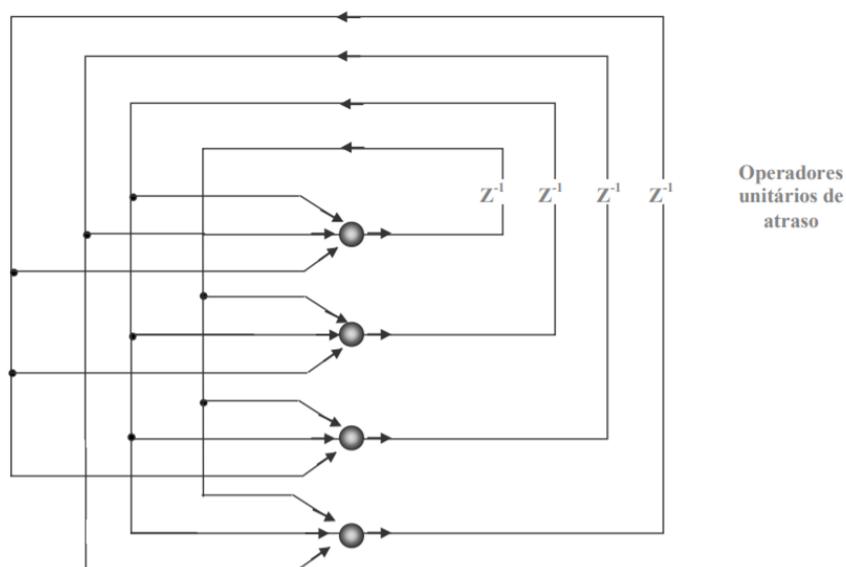


FIGURA 15 – Representação de uma Rede Recorrente.
Fonte: Furtado (2019).

2.9.5 Treinamento e aprendizado em RNAs

Para uma Rede Neural Artificial, o conceito de treinamento diferencia-se do conceito de aprendizado. O aprendizado está associado a uma tarefa que a rede está executando em função do treinamento, da sua arquitetura e da sua topologia. Já o treinamento é o processo de ensinar a RNA (FURTADO, 2019). Para que haja treinamento das RNAs, é necessário alimentá-la com um banco de dados (informações ou estímulos). Os dados para treinamento das RNAs do tipo MLPs são geralmente particionados em três sub amostras, classificadas em: treinamento, que é utilizada para efetivamente treinar a rede, isto é, para ajustar as ponderações das conexões entre os neurônios de cada camada; validação, que é utilizada para verificar a consistência do aprendizado da rede e para a seleção das variáveis a serem utilizadas; e teste, que é usada para controle da estimativa dos erros produzidos pela rede (BENITE, 2003).

Para Basheer e Hajmeer (2000), a aprendizagem é um processo de adaptação da RNA ao receber estímulos externos e com isso modificar a forma de representação interna do seu sistema com base nesse estímulo. Hykin (2001) confirma essa ideia, afirmando que a aprendizagem ocorre com um processo de estimulação dos neurônios artificiais por meio dos estímulos externos (ambiente), o que gera alterações nos parâmetros livres da RNA e a RNA “responde”, a partir disto, de uma nova maneira ao ambiente.

A arquitetura da rede define, dentre outros parâmetros, a que tipo de treinamento a rede será submetida, capacitando-a a resolver o problema. Os algoritmos podem ser divididos em três classes: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (FURTADO, 2019).

Em um aprendizado supervisionado, um supervisor externo fornece à RNA a saída desejada em relação a um padrão de entrada. Com isso, é possível comparar a saída da RNA com a saída desejada, obtendo-se o erro referente à resposta atual. A partir disso, os pesos sinápticos são ajustados de forma a minimizar o erro. A minimização do erro é incremental, pois a cada resposta gerada pela rede, são efetuados pequenos ajustes nos pesos das conexões (BISHOP citado por FLECK et al., 2016).

No aprendizado não supervisionado a saída deve se auto organizar em relação às particularidades do conjunto de amostras e assim identificar subconjuntos similares. Seus pesos e limiares são ajustados pelo algoritmo de aprendizagem de modo a refletir estas particularidades (PALMIERE, 2020).

O aprendizado por Reforço pode ser considerado uma variante do aprendizado supervisionado, no qual não se dispõe de respostas corretas, mas pode-se saber se as respostas que a rede produziu são corretas ou não. Neste algoritmo, um “crítico” irá observar o funcionamento do sistema. Caso as respostas a determinados impulsos sejam satisfatórias, deve-se reforçar as conexões que levam a estas respostas e, caso contrário, estas conexões devem ter um menor peso. É um método baseado em tentativa e erro, pois os ajustes dos pesos a serem tomados irão depender unicamente das respostas produzidas pelo sistema durante o treinamento. O que o diferencia do treinamento supervisionado é que o supervisor sabe exatamente como ajustar os pesos no caso de erro (FURTADO, 2019).

2.9.6 Backpropagation

Um algoritmo de aprendizado é um conjunto de regras bem definidas para a solução de um problema de aprendizado. Não há somente um, mas vários algoritmos de aprendizado que podem ser utilizados para treinar RNAs (VEGA, 1999). O algoritmo de aprendizado aplicado no decorrer do processo de treinamento de redes Multilayer perceptron (MLP - abordado no item 2.9.7), é denominado backpropagation ou algoritmo de retropropagação do erro (SILVA et al., 2016).

A aprendizagem por retropropagação do erro consiste em duas etapas: uma para frente, a propagação e uma para trás, a retropropagação. No passo para frente, um padrão de entrada (vetor de entrada) é aplicado aos nodos e seu efeito se propaga por meio da rede, camada por camada. Finalmente um conjunto de saídas é produzido com a resposta real da rede. Durante o passo de propagação, os pesos da rede são todos fixos. Durante o passo para trás, os pesos são todos ajustados de acordo com uma regra de correção de erros. Especificamente, a resposta real da rede é comparada com uma resposta conhecida (alvo) para produzir um sinal de erro. Esse sinal de erro é então propagado para trás por meio da rede. Os pesos são ajustados de forma que a resposta real da rede se aproxime da resposta desejada (FERREIRA, 2004).

2.9.7 Redes Multilayer Perceptron (MLP) ou Perceptron de Múltiplas Camadas

As MLPs foram desenvolvidas na década de 80 por Rumelhart, Hinton e Willians. Possuem uma camada de entrada com n atributos, uma ou mais camadas ocultas com um ou mais neurônios em cada uma delas e, por fim, uma camada de saída com um ou mais neurônios,

conforme o problema a ser modelado. A arquitetura pode ser do tipo FeedForward ou Recorrente. O aprendizado é do tipo supervisionado, com algoritmo de treinamento BackPropagation (Gradiente Descendente). A função de ativação pode ser do tipo Sigmoidal, Tangente Hiperbólica, entre outras. Pode resolver problemas não linearmente separáveis, de classificação e regressão (GATTO, 2018).

As redes Multilayer perceptron (MLP) (Figura 16), são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva camada neural de saída. Conseqüentemente, as redes MLPs possuem no mínimo duas camadas de neurônios, os quais estarão distribuídos entre as camadas intermediárias e a camada de saída (SILVA et al., 2016).

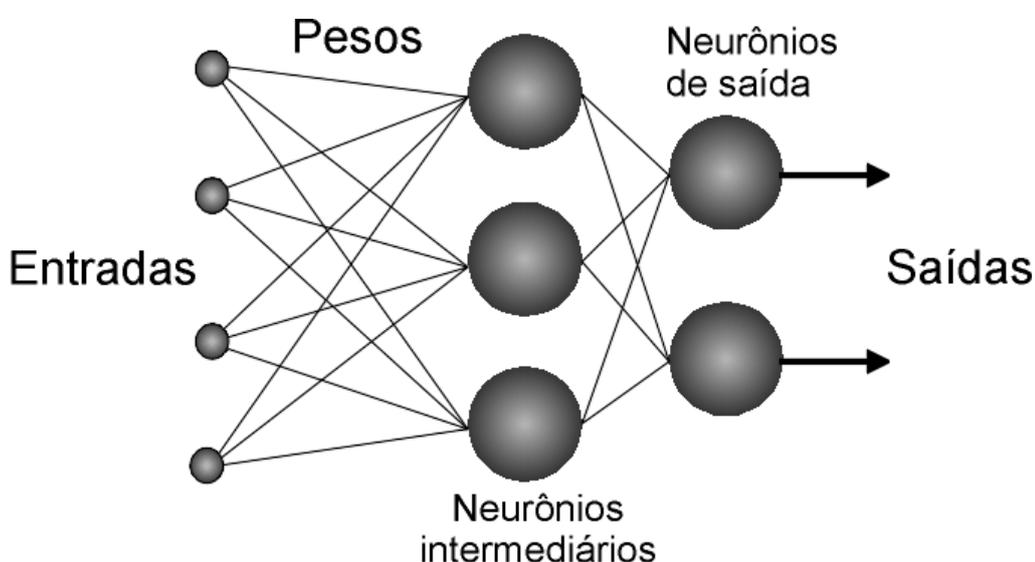


FIGURA 16 – Representação de uma Rede Neural Artificial de 2 camadas com 4 neurônios de entrada e dois neurônios de saída.

Fonte: Tafner (1998).

2.9.8 Trabalhos empregando RNAs nas áreas agrícolas

Desde a sua expansão, as RNAs apresentaram um campo aberto e de possível potencial na área agrícola. Diversos trabalhos foram desenvolvidos empregando-se as RNAs. Dentre as vantagens encontradas pelos pesquisadores, pode-se apontar a facilidade de aplicação das RNAs na resolução dos problemas de predição comparando-se às metodologias estatísticas.

Dentre os trabalhos mais recentes realizados com RNAs no Brasil, para resolver problemáticas no âmbito agrícola, pode-se citar: Netto (2007) que estimou a retenção de água no solo por meio de RNAs na região central do Estado de São Paulo, no Planalto de São Carlos; Gorgens et al. (2009), com a estimação do volume de árvores utilizando RNAs; Silva et al.

(2009) com a proposta do ajuste do modelo de Schumacher e Hall e aplicação de RNAs para estimar volume de árvores de eucalipto; Costa (2012), que usou RNAs para estimar a retenção e disponibilidade de água em 44 perfis de solos de Santa Catarina, avaliando e gerando funções de pedotransferência; Soares (2013) que estimou a curva de retenção de água no solo por meio de RNAs em solos do Rio Grande do Sul; Binoti et al. (2014) com a configuração de RNAs para estimação do volume de árvores; Mendes (2014), com a predição da retenção de água em solos de Santa Catarina por meio de RNAs; Oliveira (2014), que fez a estimativa do teor de água no solo em Bacia hidrográfica com RNAs utilizando fatores físicos e climáticos; Bittar (2016) com o título do trabalho: “Redes Neurais Artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do Cerrado”; Alves (2016), com a estimativa da produtividade da soja com Redes Neurais Artificiais, entre outros.

3. MATERIAL E MÉTODOS

3.1 Localização e caracterização da área experimental

A área de estudo está localizada no Estado de Goiás, na Região Centro Goiano (Figura 17), que foi definida tendo como critério o eixo da BR 153. A região possui um clima predominante tropical semiúmido, com duas estações bem definidas, uma chuvosa que acontece entre outubro e abril e uma seca, que compreende os meses de maio a setembro. A temperatura média anual pode variar entre 18 e 23°C. Na estação seca, as temperaturas podem chegar próximo aos 4°C. O índice pluviométrico anual varia de 1.200 a 2.500 mm. Para o desenvolvimento deste trabalho, foram realizadas coletas em 10 municípios da Região Centro Goiano (Eixo BR-153) (Figura 17), dos quais estão presentes na Tabela 4. As áreas onde foram coletadas as amostras de solo estavam sendo utilizadas como: áreas de cultivo de banana, melancia, abacaxi, feijão, laranja, pimenta, horticultura, plantio de cana-de-açúcar, áreas de pastagem, áreas com plantio direto e com e sem preparo de solo.

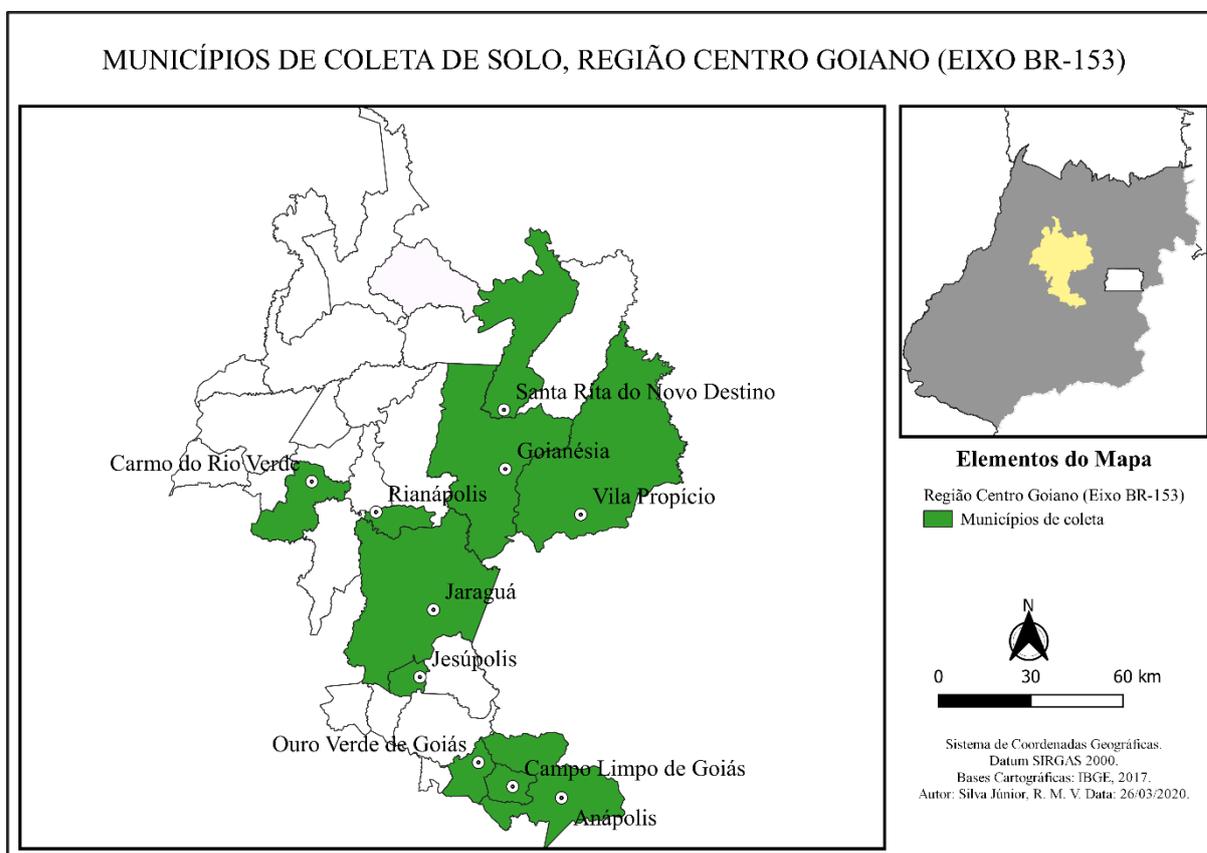


FIGURA 17 – Municípios de coleta de solo, Região Centro Goiano (Eixo BR-153).

Fonte: Próprio autor.

TABELA 4 – Municípios e localização das áreas de coletas de solo na Região Centro Goiano.

Número	Município	Localização	Altitude
1	Anápolis	16° 19' 37" S, 48° 57' 10" W	1.167 m
2	Campo Limpo	16° 17' 49" S, 49° 05' 16" W	840 m
3	Carmo do Rio Verde	15° 21' 14" S, 49° 42' 28" W	615 m
4	Goianésia	15° 19' 01" S, 49° 07' 01" W	640 m
5	Jaraguá	15° 45' 25" S, 49° 20' 02" W	610 m
6	Jesúpolis	15° 57' 03" S, 49° 22' 26" W	707 m
7	Ouro Verde	16° 13' 12" S, 49° 11' 34" W	1.040 m
8	Rianópolis	15° 26' 49" S, 49° 30' 36" W	589 m
9	Santa Rita do Novo Destino	15° 08' 06" S, 49° 07' 12" W	760 m
10	Vila Propício	15° 27' 25" S, 48° 53' 20" W	722 m

Fonte: Próprio Autor.

As classes de solo dos municípios onde foram realizadas as coletas estão destacadas na Figura 18, sendo predominantemente compostos por Argissolos, Cambissolos e Latossolos.

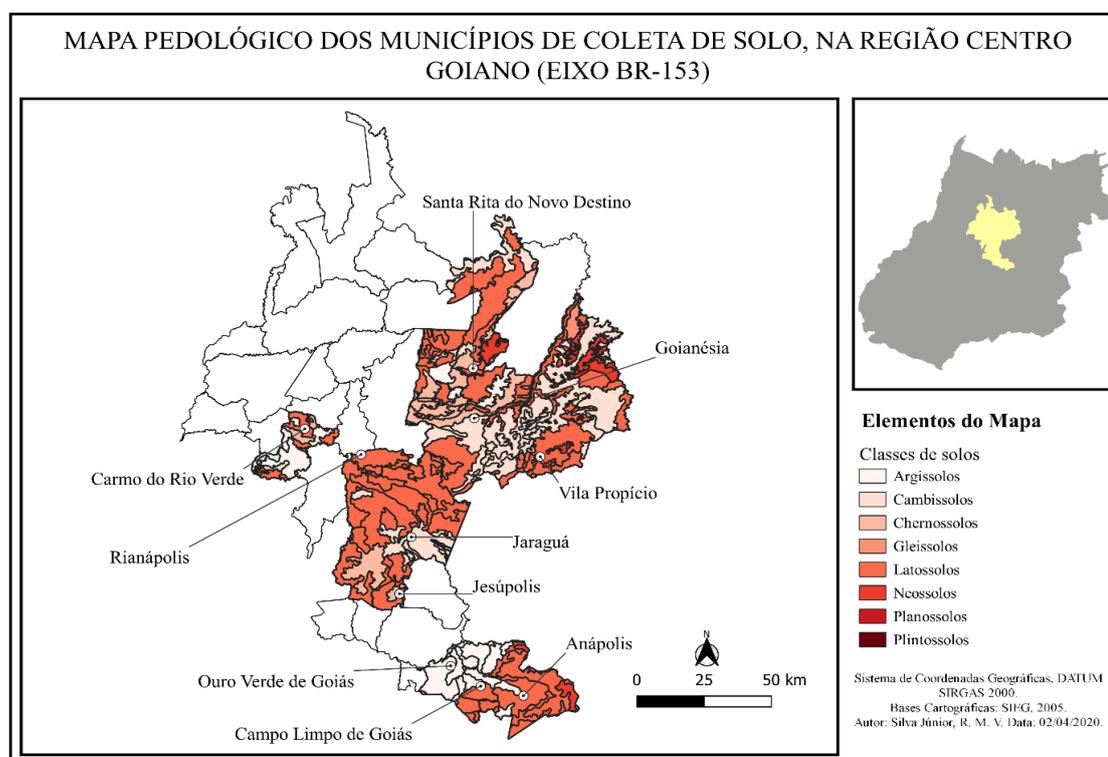


FIGURA 18 – Mapa pedológico dos municípios onde foram realizadas as coletas de solo, na Região Centro Goiano (Eixo BR-153).

Fonte: Próprio Autor.

3.2 Coleta das amostras de solo

O período do ano em que foram realizadas as coletas das amostras de solo compreendeu a estação seca, entre os meses de junho e agosto de 2019. As coletas foram realizadas em pontos aleatórios nos municípios definidos no item 3.1. A aleatoriedade nas coletas foi feita como estratégia para obter melhor representatividade dos atributos dos solos dos municípios em estudo. Essa maior variabilidade das amostras coletadas serviu para a formulação das FPTs por RLMs e RNAs.

Os pontos de coleta foram georreferenciados utilizando-se um aparelho de Sistema de Posicionamento Global (GPS), da marca Garmin modelo Legend RoHs cuja precisão é de ± 3 m. O aparelho possui um datum ajustado ao sistema SIRGAS 2000.

As amostras indeformadas foram coletadas com o auxílio de um trado tipo Uhland (Figura 19a), que apresenta um anel com altura de 50 mm e diâmetro interno de 50 mm, cujo volume interno aproximado é de 100 cm³. O solo coletado foi mantido nos anéis volumétricos (Figura 19b), tendo suas extremidades cobertas com tampões de plástico, onde foram devidamente identificados e armazenados em um estojo (Figura 19c), próprio para o transporte do material, com o intuito de garantir a integridade estrutural e hídrica das amostras.



FIGURA 19 – a) Coleta de solo das amostras indeformada; b) anel volumétrico com amostra de solo; c) estojo transportador onde as amostras ficaram armazenadas.

Fonte: Próprio autor.

As amostras deformadas foram coletadas com o auxílio de um trado Holandês, devidamente identificadas e embaladas em sacos plásticos para preservar e evitar contaminações (Figura 20).



FIGURA 20 – Amostra deformada de solo identificada e armazenada em saco plástico.
Fonte: Próprio autor.

Em cada um dos 10 municípios foram definidos 12 pontos de coletas de solo. Em cada ponto de coleta foram retiradas amostras de solo em duas profundidades distintas (0,0 – 0,20 m; 0,20 – 0,40 m). Desta forma, foram reunidas 24 amostras deformadas e 24 amostras indeformadas, divididas nas duas profundidades, totalizando 48 amostras de solo em cada município. Logo, o total de amostras de solo, referentes aos 10 municípios de coleta e para as duas profundidades descritas foram de: 240 amostras deformadas e 240 amostras indeformadas. Para a realização das coletas e identificação dos perfis dos solos, nas profundidades de 0,20 – 0,40 m, foram abertas trincheiras nos solos.

Após a coleta do solo, as amostras deformadas e indeformadas foram levadas para a análise física no Laboratório de Mecânica dos Solos da Universidade Estadual de Goiás, Campus Central – Sede: Anápolis – CET. Parte das amostras deformadas seguiram para o Laboratório de Engenharia Agrícola da mesma instituição para determinação da Matéria Orgânica.

As amostras indeformadas foram utilizadas para a determinação das umidades na capacidade de campo, densidade do solo, porosidade total, microporosidade e macroporosidade. As amostras deformadas foram utilizadas para a determinação das umidades no ponto de murcha permanente, matéria orgânica, granulometria e densidade de partículas.

3.3 Análises laboratoriais

3.3.1 Umidades na capacidade de campo (CC) e no ponto de murcha permanente (PMP)

A CC foi obtida utilizando-se as 240 amostras indeformadas e o PMP foi obtido utilizando-se as 240 amostras deformadas, ambas coletadas em campo para as duas profundidades descritas (0,0 – 0,20 m; 0,20 – 0,40 m).

Para a determinação das umidades na capacidade de campo e no ponto de murcha permanente foi utilizada a metodologia proposta por Teixeira e Bhering (2017). Os equipamentos utilizados para a obtenção da CC foram as mesas de areia sintética (Figura 21a) (Sandbox for pF -determination), que aplicaram tensões de sucção às amostras indeformadas retidas nos anéis volumétricos de volumes conhecidos, na faixa de 10 a 33 kPa. Para o PMP utilizou-se um extrator de membrana (Figura 21b) (Pressure Membrane Apparatus) que aplica pressões de 1.500 kPa sob as amostras deformadas de solo. Os equipamentos utilizados foram da Marca Eijkelkamp.



FIGURA 21 – a) extrator de membrana – Eijkelkamp (Pressure Membrane Apparatus); b) mesas de areia sintética – Eijkelkamp (Sandbox for pF -determination).

Fonte: Próprio autor.

3.3.2 Análise granulométrica

Foram utilizadas as amostras de solo deformadas (0,0 – 0,20 m; 0,20 – 0,40 m) para a determinação granulométrica (Areia, Silte e Argila) por meio do método da pipeta (Figura 22) (DONAGEMMA et al., 2017).



FIGURA 22 – Determinação granulométrica pelo método da pipeta.
Fonte: Próprio autor.

3.3.3 Densidade de partículas (D_p) e densidade do solo (D_s)

Para a determinação da densidade de partículas (D_p) foi utilizado o método do picnômetro, descrito pela ABNT NBR 6458 (2017) (Figura 23). A densidade do solo (D_s) foi determinada pela relação entre massa do solo seco em estufa e seu volume (100 cm^3) de acordo com Donagemma et al. (2011).



FIGURA 23 – Determinação da densidade de partículas e densidade do solo.
Fonte: Próprio autor.

3.3.4 Porosidade total (P_t), Macroporosidade (Macro) e Microporosidade (Micro)

A porosidade total foi obtida por meio do método padrão da estufa, com um cilindro volumétrico de dimensões conhecidas (amostra indeformada) e pesado em uma balança de

precisão de 0,1 g, como propõe Almeida et al. (2017). Os microporos (Micro) foram obtidos mediante o ponto da curva de retenção de água no solo, no potencial matricial equivalente a -6 kPa, e os macroporos (Macro) foram calculados por meio da diferença entre a porosidade total e os microporos (ALMEIDA et al., 2017).

3.3.5 Matéria orgânica (MO)

A matéria orgânica foi obtida pelo método via seca em mufla por incineração (Figura 24). Utilizou-se das amostras deformadas de solo, 5,00 g de terra fina seca ao ar (TFSA), maceradas e peneiradas a 80 mesh. O material peneirado ficou por 24 horas em estufa a 65°C onde em seguida foi esfriado em um dessecador e pesado. Após a pesagem, o solo foi colocado em uma mufla onde permaneceu por 6 horas a uma temperatura de 600°C. O material foi retirado da mufla, resfriado em dessecador e novamente pesado. Anotou-se os valores obtidos nas pesagens para os cálculos de matéria orgânica seguindo a metodologia proposta por Fontana (2017).



FIGURA 24 – a) Preparação da amostra de solo para análise de matéria orgânica (MO); b) resfriamento (em dessecador) da amostra após passar pelo ensaio de MO.

Fonte: Próprio autor.

3.4 Análise descritiva e exploratória

A estatística descritiva foi usada para avaliar e verificar a distribuição e dispersão das variáveis que compõem os atributos físicos e químico do solo. Foram calculadas as seguintes medidas descritivas: média, mediana, moda, variância, desvio padrão e coeficiente de variação, para cada uma das variáveis de estudo. Para verificar a normalidade dos dados, foi realizado o teste de Shapiro e Wilk (1965). Para verificação da ocorrência de outliers foi usado o critério

de Tukey (1977), por meio do gráfico boxplot. O Coeficiente de correlação de Pearson (r) (SCHULTZ e SCHULTZ, 1992) foi usado para verificar a correlação entre os atributos físicos, químico e as umidades do solo. As análises estatísticas foram realizadas por meio dos softwares Sisvar 5.6 (FERREIRA, 2014) e R (R CORE TEAM, 2015).

3.5 Funções de pedotransferência

As funções de pedotransferência foram formuladas a partir de dois métodos de modelagem: regressões lineares múltiplas e redes neurais artificiais. As variáveis de saída ou dependentes para formulação das FPTs são referentes aos dados obtidos em laboratório das CC e PMP, por meio dos métodos da mesa de tensão e membrana extratora, descritos no item 3.3.1. As variáveis de entrada ou independentes que serviram na modelagem das FPTs foram os valores obtidos por meio dos ensaios de laboratório dos atributos físicos (Areia, Silte, Argila, D_s , D_p , P_t , Macro, Micro) e químico (MO) das amostras coletadas, descritos nos itens 3.3.2 ao 3.3.5.

3.5.1 Regressão Linear Múltipla (RLM)

Um exemplo de equação de regressão linear múltipla pode ser representado conforme o modelo seguinte, adaptado de Gupta e Larson (1979), para o modelo adotado na estimativa da capacidade de campo:

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_3 \cdot X_3 + \beta_4 \cdot X_4 + \beta_5 \cdot X_5 + \beta_6 \cdot X_6 + \beta_7 \cdot X_7 + \beta_8 \cdot X_8 + \beta_9 \cdot X_9 + \beta_{10} \cdot X_{10} \quad \text{Eq. (3)}$$

Em que:

Y = conteúdo de água ($\text{m}^3 \text{ m}^{-3}$) para a sucção de 33 kPa (CC) ou de 1.500 kPa (PMP);

β_0 = intercepto;

$\beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7, \beta_8, \beta_9$ e β_{10} = coeficientes de regressão.

X_1 = Areia (g kg^{-1}); X_2 = Silte (g kg^{-1}); X_3 = Argila (g kg^{-1}); X_4 = Densidade do solo (g cm^{-3}); X_5 = Densidade de partículas (g cm^{-3}); X_6 = Matéria orgânica (g kg^{-1}); X_7 = Porosidade total ($\text{m}^3 \text{ m}^3$); X_8 = Microporosidade ($\text{m}^3 \text{ m}^3$); X_9 = Macroporosidade ($\text{m}^3 \text{ m}^3$); X_{10} = Profundidade (m).

3.5.1.1 Definição do modelo

Para definição do modelo matemático foram selecionadas variáveis dependentes e independentes. As variáveis dependentes que compuseram o sistema são as umidades na capacidade de campo e no ponto de murcha permanente. As variáveis independentes ou predictoras são: Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade. Foi utilizado um banco de dados geral referente as profundidades de 0,0 a 0,40 m, contendo todas as variáveis em questão (0,0 – 0,20 m e 0,20 – 0,40 m).

3.5.1.2 Verificação dos pressupostos básicos para a RLM

Após a seleção das variáveis que alimentaram o modelo matemático foram realizadas verificações dos pressupostos básicos estatísticos para RLM, sendo estes:

- I – Número mínimo de 20 repetições por variáveis independentes
- II – Ausência de multicolinearidade.
- III – Independência dos resíduos (DURBIN e WATSON, 1950).
- IV – Ausência de *Outliers* (Faixa do desvio padrão ± 3)
- V – Distribuição normal para os Resíduos (Gráficos Histograma e P-P Plot)
- VI – Homocedasticidade (Gráfico de dispersão)
- VII – Relação linear entre variáveis dependentes e independentes (Gráfico de dispersão)

3.5.1.3 Escolha do modelo matemático para resolução da RLM

O método *stepwise* foi usado como parâmetro de seleção das variáveis que compuseram os modelos matemáticos. O software utilizado foi o *IBM SPSS Statistics* (IBM CORPORATION, 2017).

3.5.1.4 Separação do conjunto de dados

Foi utilizado o banco de dados total com as amostras de 0,0 – 0,20 m e 0,20 – 0,40 m. O conjunto de dados foi dividido aleatoriamente em 60% para geração das FPTs e 40% para sua validação, como proposto por Soares (2013).

3.5.1.5 Critérios para seleção do modelo

Os critérios para escolha do melhor modelo foram: Teste F significativo a 5%, R^2 , R^2 ajustado, Coeficientes Padronizados (Beta) e Teste-t significativo a 5% para as estimativas dos parâmetros.

3.5.2 Rede Neural Artificial (RNA)

As RNAs foram formuladas e treinadas com o uso do software *GNU Octave* na versão 5.2.0.1. O treinamento seguiu a metodologia proposta por Braga et al. (2012), que utilizaram um algoritmo de retro propagação de erros (back-propagation), com uma rede de topologia *Multilayer Perceptron* (Perceptron de Múltiplas Camadas – MLP) e treinamento supervisionado.

3.5.2.1 Escolha das variáveis de entrada e saída

Para a escolha das variáveis de entrada (variáveis independentes) que possuem maior efeito na predição das variáveis de saída (variáveis dependentes), foram realizados treinamentos com RNAs distintas, tanto para as umidades na capacidade de campo quanto para as umidades no ponto de murcha permanente.

Os neurônios da camada de entrada foram referentes às variáveis de atributo físico-químico do solo (Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade). Os neurônios das camadas de saída foram referentes às variáveis dependentes (CC e PMP).

Um banco de dados geral (amostras de 0,0 – 0,20 m e 0,20 – 0,40 m) foi utilizado para os treinamentos das RNAs (CC e PMP).

3.5.2.2 Arquitetura da RNA

A arquitetura da RNA foi a de múltiplas camadas (MLP) com variações de neurônios nas camadas de entrada e intermediária. Na saída foi utilizado apenas um neurônio. Isso foi feito devido a independência das estimativas de CC e PMP.

Foram adotados oito modelos que combinaram as variáveis da camada de entrada, tanto para CC quanto para PMP, conforme Tabela 5:

TABELA 5 – Modelos gerados pela RNA para as variáveis CC e PMP.

Modelo	Entrada	Saída
1	Areia, Silte, Argila	CC
2	Areia, Silte, Argila, Ds, Dp e MO	CC
3	Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade	CC
4	Modelo escolhido na RLM	CC
5	Areia, Silte, Argila	PMP
6	Areia, Silte, Argila, Ds, Dp e MO	PMP
7	Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade	PMP
8	Modelo escolhido na RLM	PMP

Fonte: Próprio autor.

A camada oculta variou entre 1 a 20 neurônios. O número máximo de vezes que os dados de treinamento foram apresentados para cada ciclo (Número de ciclos) foi de 1.000. O número de treinamentos que foram realizados para cada neurônio da camada oculta foi de 1.000 treinamentos.

3.5.2.3 Normalização dos dados

Com o objetivo de manter todas as variáveis em uma mesma ordem de grandeza, nivelando as unidades de medida dos dados e permitindo que os mesmos possam ser inseridos no sistema para formulação das RNAs, foi feito um pré-processamento dos dados na qual as variáveis de entrada e saída foram normalizadas. A transformação foi realizada por meio da Equação 2 (SRINIVASAN et al., 1994):

$$y = \frac{(x - x_{\min})(d_2 - d_1)}{x_{\max} - x_{\min}} + d_1 \quad \text{Eq. (4)}$$

Em que:

y = resultado normalizado;

x = valor a ser normalizado;

x_{\min} = valor mínimo de x;

x_{\max} = valor máximo de x;

d_1 = limite inferior do resultado da normalização (-1);

d_2 = limite superior do resultado da normalização (1).

3.5.2.4 Separação do conjunto de dados para treinamento, validação e teste

A separação do conjunto de dados foi feita seguindo a metodologia proposta por Soares (2013). O banco de dados foi dividido aleatoriamente em cerca de 70% dos dados para treinamento, 15% para validação e 15% para teste.

3.5.2.5 Escolha da melhor RNA

Para a escolha da melhor RNA foram utilizados os critérios de menor erro relativo médio e menor variância comparando-se os valores obtidos das umidades nas capacidades de campo e no ponto de murcha permanente em laboratório com os estimados pelas RNAs. Caso existissem valores comparados similares, foram levados em consideração os critérios propostos por Camargo e Sentelhas (1997) de menor erro quadrático médio em relação aos dados de treino.

3.5.2.6 Desnormalização dos dados

Para que fosse possível a comparação entre os resultados das variáveis de saída (dependentes) geradas pelas RNAs, com as variáveis obtidas nos ensaios na mesa de tensão (CC e PMP), foi feita uma desnormalização dos dados (Equação 5).

$$x = \frac{(x_{\text{máx}} - x_{\text{mín}}) * (y - d_1)}{d_2 - d_1} + x_{\text{mín}} \quad \text{Eq. (5)}$$

Em que:

y = resultado desnormalizado;

x = valor normalizado;

$x_{\text{mín}}$ = valor mínimo de x;

$x_{\text{máx}}$ = valor máximo de x;

d_1 = limite inferior do resultado da normalização (-1);

d_2 = limite superior do resultado da normalização (1).

3.6 Indicadores estatísticos que foram usados para avaliação de desempenho e eficiência das FPTs

Foram utilizados como referência para avaliação de desempenho e eficiência das funções de pedotransferência modeladas por meio de RNAs e RLMs, os indicadores, conforme sugerido por Freitas (2017):

Coeficiente de correlação de Pearson (r) (SCHNEIDER, 1998) (Equação 6):

$$r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)^2][\sum_{i=1}^n (O_i - O)^2]}} \quad \text{Eq. (6)}$$

Em que:

r = Coeficiente de correlação de Pearson;

E_i = Valores estimados;

O_i = Valores observados;

E = Média dos valores estimados;

O = Média dos valores observados;

n = Quantidade de padrões de teste.

Coeficiente de determinação (R^2) (Equação 7):

$$\sqrt{R^2} = r \quad \text{Eq. (7)}$$

Em que:

R^2 = Coeficiente de determinação;

r = Coeficiente de correlação de Pearson.

Índice de concordância (c) (Equação 8) (WILLMONTT, 1981):

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2} \quad \text{Eq. (8)}$$

Em que:

c = Índice de concordância de Willmont;

E_i = Valores estimados;

O_i = Valores observados;

E = Média dos valores estimados;

O = Média dos valores observados;

n = Quantidade de padrões de teste.

Índice de desempenho (id) (Equação 9). Na Tabela 6 estão os critérios de avaliação de desempenho conforme Camargo e Sentelhas (1997).

$$id = r \cdot c \quad \text{Eq. (9)}$$

Em que:

id = Índice de desempenho;

r = Coeficiente de correlação de Pearson;

c = Índice de concordância de Willmont.

TABELA 6 – Classificação dos índices de desempenho de Camargo e Centelhas (1997) para escolha das funções de pedotransferência.

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

Fonte: Camargo e Sentelhas (1997).

Erro médio relativo (P%) (Equação 10):

$$P = \frac{100}{n} \sum \left| \frac{O_i - E_i}{O_i} \right| \quad \text{Eq. (10)}$$

Em que:

P = Erro médio relativo;

n = Número de elementos;
 O_i = Valores observados;
 E_i = Valores estimados.

Erro Quadrático Médio (EQM) (Equação 11):

$$EQM = \frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2 \quad \text{Eq. (11)}$$

Em que:

EQM = Erro quadrático médio;
 n = Número de elementos;
 O_i = Valores observados;
 E_i = Valores estimados.

3.7 Comparação dos resultados observados x estimados obtidos nos modelos de RLMs e RNAs

Para comparação entre os valores observados e estimados por meio das RNAs e RLMs foi escolhido o Teste-t a 5% de probabilidade.

3.8 Comparação entre os modelos de FPTs gerados por RLMs e RNAs

Os critérios de desempenho observados nos Itens 3.6 e 3.7 foram usados para comparação dos modelos. O índice AIC (Akaike Information Criterion) (AKAIKE, 1974) foi usado para avaliar a qualidade do ajuste dos dados, pelo fato de os modelos apresentarem diferentes números de parâmetros.

4. RESULTADOS E DISCUSSÃO

4.1 Análise descritiva e exploratória

A Figura 25 representa o triângulo textural com as respectivas classes de solo obtidas por meio dos resultados das médias das 240 análises granulométricas (Item 3.3.2). Observa-se na figura, a predominância das classes: Muito argilosa, Argilosa, Argilo-arenosa, Franco-argilosa e Franco-argilo-arenosa. Os solos foram classificados como: Latassolos, Argissolos e Cambissolos.

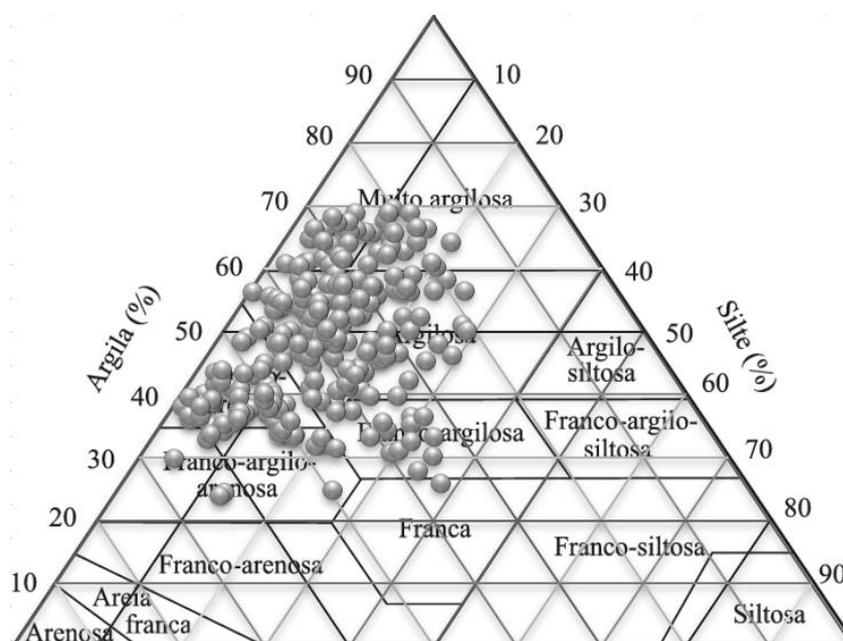


FIGURA 25 – Triângulo textural com os respectivos resultados das análises granulométricas dos diferentes solos avaliados.

Fonte: Próprio autor.

A análise descritiva e exploratória foi feita para todas as variáveis. Segundo a classificação de Warrick e Nielsen (1980), os coeficientes de variação (C.V.) oscilaram entre baixos, médios e altos (Tabelas 7 e 8). Os C.V. (%) de MO, Dp, Ds, Pt e Micro para a profundidade de 0,0 – 0,20 m apresentaram valores classificados como baixos (<12%). Para 0,0 – 0,40 m foram encontrados valores de C.V. (%) baixos para as mesmas variáveis, exceto para a MO, que apresentou C.V. médio (12% < C.V. < 60%). As variáveis Areia, Argila, CC e PMP para a profundidade de 0,0 – 0,20 m apresentaram valores médios (12% < C.V. < 60%), também observadas na profundidade de 0,20 – 0,40 m. As variáveis Silte e Macro, para as duas profundidades, apresentaram valores de C.V.% considerados altos (>60%). Valores similares

foram observados nos trabalhos de Soares (2013), Antunes Júnior (2016) e Mendes (2014). Nos APÊNDICES de 1 a 20 encontram-se as tabelas com as análises individuais para cada cidade.

TABELA 7 – Estatística Descritiva das variáveis dependentes e independentes utilizadas nas formulações das FPTs, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO	22,069	2,190	17,637	27,503	9,922	0,985	0,197
Dp	2,700	0,080	2,501	2,891	2,971	0,984	0,160
Ds	1,277	0,111	1,005	1,564	8,701	0,991	0,650
Areia	394,476	107,944	193,922	635,925	27,364	0,971	0,011
Silte	130,665	82,586	3,781	347,809	63,204	0,941	0,000
Argila	474,859	108,946	238,329	687,930	22,943	0,978	0,043
Pt	0,498	0,045	0,392	0,605	9,060	0,947	0,000
Macro	0,029	0,023	0,002	0,124	80,459	0,882	0,000
Micro	0,469	0,040	0,342	0,574	8,490	0,983	0,140
CC	323,501	46,335	177,149	450,180	14,323	0,983	0,134
PMP	114,614	30,823	47,796	166,544	26,893	0,949	0,000

Mín: valor mínimo; Máx: valor máximo; C.V.: coeficiente de variação; p-value e W: teste normalidade Shapiro Wilk a 5%; MO – Matéria Orgânica (g kg^{-1}); Dp – Densidade de Partículas (g cm^{-3}); Ds – Densidade do Solo (g cm^{-3}); Areia (g kg^{-1}); Silte (g kg^{-1}); Argila (g kg^{-1}); Pt – Porosidade Total ($\text{m}^3 \text{m}^{-3}$); Macro – Macroporosidade ($\text{m}^3 \text{m}^{-3}$); Micro - Microporosidade ($\text{m}^3 \text{m}^{-3}$); CC – Capacidade de Campo (g kg^{-1}); PMP – Ponto de Murcha Permanente (g kg^{-1}).

TABELA 8 – Estatística Descritiva das variáveis dependentes e independentes utilizadas nas formulações das FPTs, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO	20,345	2,653	14,359	26,716	13,039	0,982	0,103
Dp	2,719	0,078	2,550	2,898	2,873	0,986	0,261
Ds	1,375	0,120	1,067	1,751	8,755	0,991	0,663
Areia	376,016	113,506	158,396	660,284	30,187	0,977	0,041
Silte	127,286	67,266	11,278	379,412	52,846	0,945	0,000
Argila	496,698	109,571	259,041	694,959	22,060	0,966	0,004
Pt	0,460	0,049	0,324	0,574	10,622	0,994	0,883
Macro	0,022	0,016	0,002	0,110	75,061	0,839	0,000
Micro	0,438	0,049	0,283	0,572	11,106	0,993	0,826
CC	287,027	53,552	119,945	496,902	18,658	0,981	0,081
PMP	111,393	33,157	47,030	179,854	29,765	0,959	0,001

Mín: valor mínimo; Máx: valor máximo; C.V.: coeficiente de variação; p-value e W: teste normalidade Shapiro Wilk a 5%; MO – Matéria Orgânica (g kg^{-1}); Dp – Densidade de Partículas (g cm^{-3}); Ds – Densidade do Solo (g cm^{-3}); Areia (g kg^{-1}); Silte (g kg^{-1}); Argila (g kg^{-1}); Pt – Porosidade Total ($\text{m}^3 \text{m}^{-3}$); Macro – Macroporosidade ($\text{m}^3 \text{m}^{-3}$); Micro - Microporosidade ($\text{m}^3 \text{m}^{-3}$); CC – Capacidade de Campo (g kg^{-1}); PMP – Ponto de Murcha Permanente (g kg^{-1}).

Esses valores altos de C.V. (%), observados nas Tabelas 7 e 8, são compreensíveis já que se trata de análises de solos distintos, com diferentes propriedades estruturais e texturais.

Os teores de areia foram observados também por Antunes Júnior (2016), para a região de Anápolis em Latossolo Vermelho sob plantio direto. Segundo Sousa e Lobato (2020), os latossolos apresentam teores de silte inferiores a 20% (200 g kg^{-1}) e argila variando entre 15% e 80% (150 e 800 g kg^{-1}). Pedron et al. (2012) encontraram valores de areia que variaram entre 382 a 750 g kg^{-1} no horizonte A e 183 a 545 g kg^{-1} no horizonte B. Os valores de argila variaram de 87 a 250 g kg^{-1} para o horizonte A e 285 a 520 g kg^{-1} no horizonte B, em argissolos do Rio Grande do Sul.

Na camada de $0,0 - 0,20 \text{ m}$, a CC média foi de $323,501 \text{ g kg}^{-1}$, com limite inferior de $177,149 \text{ g kg}^{-1}$ e superior de $450,180 \text{ g kg}^{-1}$; enquanto que o PMP médio foi de $114,614 \text{ g kg}^{-1}$, com limite inferior de $47,796 \text{ g kg}^{-1}$ e superior de $166,544 \text{ g kg}^{-1}$. Para a camada de $0,20 - 0,40 \text{ m}$, a CC média foi de $287,027 \text{ g kg}^{-1}$, com limite inferior de $119,945 \text{ g kg}^{-1}$ e superior de $496,902 \text{ g kg}^{-1}$; enquanto que o PMP médio foi de $111,393 \text{ g kg}^{-1}$, com limite inferior de $47,03 \text{ g kg}^{-1}$ e superior de $179,854 \text{ g kg}^{-1}$. Segundo Ramos (2017), essa variação na CC e no PMP deve-se, provavelmente, às características estruturais, granulométricas e a heterogeneidade das amostras coletadas. Para Hillel et al. (1972), a retenção de água no solo, para condições de teores elevados de umidade do solo, depende diretamente do arranjo e dimensões dos poros. Em contrapartida, para teores baixos de umidade do solo, a retenção praticamente independe da estrutura do solo, sendo este influenciado, pela textura e superfície específica.

Com o teste de Shapiro-Wilk a 5% de probabilidade constatou-se para as variáveis estudadas, com exceção de MO, Dp, Ds, Micro e CC para ($0,0 - 0,20 \text{ m}$ e $0,20 - 0,40 \text{ m}$) e Pt ($0,20 - 0,40 \text{ m}$) que os dados não seguem distribuição normal. Utilizando o critério de Tukey (1977) e gráficos do tipo *Boxplot*, foram encontrados *outliers* e removidos para a formulação das FPTs por meio das RLMs, atendendo a um dos pressupostos básicos da regressão. As RNAs foram treinadas com a tabela contendo *outliers*, pelo fato desta não exigir pressupostos de remoção de dados discrepantes em relação à média. Essa metodologia foi adotada para verificação e observação do comportamento das redes mediante situações extremas, bem como para aumentar a capacidade de generalização da RNA.

4.2 Correlações entre as variáveis dependentes e independentes

Segundo Milone e Angelini (2003), o coeficiente de Pearson (r) demonstra a força e a direção da relação linear entre duas variáveis. Esses valores podem oscilar de -1 a 1, onde o 0 indica que não existe uma relação linear e 1 ou -1 indicam uma relação linear perfeita. Quando o resultado for negativo significa que as variáveis estudadas possuem relação inversa. Na Tabela 9 encontram-se as variáveis preditoras e as preditas e suas respectivas correlações analisadas pelo parâmetro da correlação de Pearson (r). Nesta tabela, optou-se por dividir os dados em: análise de 0,0 – 0,20 m; de 0,20 – 0,40 m e de 0,0 – 0,40 m de profundidade, para os parâmetros estudados.

TABELA 9 – Coeficiente de correlação de Pearson (r) entre as variáveis dependentes e independentes para as profundidades 0,0 – 0,20 m e 0,20 – 0,40 m.

Variáveis	0,0 - 0,20		0,20 - 0,40		0,0 – 0,40	
	CC	PMP	CC	PMP	CC	PMP
Profundidade	-	-	-	-	-0,362	-0,074
MO	0,448	0,287	0,255	0,329	0,401	0,316
Dp	0,218	-0,219	0,337	0,416	0,220	0,114
Ds	-0,593	-0,242	-0,738	-0,346	-0,731	-0,306
Argila	0,535	0,251	0,471	0,468	0,376	0,345
Silte	-0,164	-0,119	-0,119	-0,061	-0,056	-0,077
Areia	-0,417	-0,161	-0,399	-0,423	-0,343	-0,298
Pt	0,745	0,085	0,860	0,432	0,842	0,296
Micro	0,840	0,260	0,909	0,476	0,900	0,389
Macro	-0,069	-0,361	-0,087	-0,232	-0,052	-0,226

Profundidade – (0,0 – 0,20 m; 0,20 – 0,40 m e 0,0 – 0,40 m); – Matéria Orgânica (g kg^{-1}); Dp – Densidade de Partículas (g cm^{-3}); Ds – Densidade do Solo (g cm^{-3}); Areia (g kg^{-1}); Silte (g kg^{-1}); Argila (g kg^{-1}); Pt – Porosidade Total ($\text{m}^3 \text{m}^3$); Macro – Macroporosidade ($\text{m}^3 \text{m}^3$); Micro – Microporosidade ($\text{m}^3 \text{m}^3$); CC – Capacidade de Campo (g kg^{-1}); PMP – Ponto de Murcha Permanente (g kg^{-1}).

Conforme o que consta na Tabela 9, verificou-se uma correlação fraca negativa ($-0,5 < r \leq -0,1$) entre a variável Profundidade e CC (-0,362), ou seja, uma variável aumenta à medida que a outra diminui. Para o PMP a correlação com a variável Profundidade (-0,074) foi ínfima negativa ($-0,1 < r < 0$), indicando uma baixa correlação.

A variável MO reduziu sua correlação com a variável CC com o aumento da profundidade (de 0,448 para 0,255) e aumentou para a variável PMP com o aumento da profundidade (de 0,287 para 0,329). As duas variáveis apresentaram correlação fraca positiva ($0,1 \leq r < 0,5$).

A densidade de partículas apresentou aumento na correlação com a variável CC com o aumento da profundidade (de 0,218 para 0,337) e aumentou também para a variável PMP com o aumento da profundidade (de -0,219 para 0,416). As duas variáveis apresentaram correlação fraca positiva ($0,1 \leq r < 0,5$), com exceção da variável PMP na profundidade de 0,0 – 0,20 m que apresentou correlação fraca negativa ($0,1 \leq r < 0,5$). Esses valores foram também observados por Soares (2013) para solos do Rio Grande do Sul.

As variáveis Ds, Silte, Areia e Macro apresentaram correlação negativa, tanto para CC quanto para PMP. A variação foi de ínfima negativa a moderada negativa ($-0,1 \leq r < 0$ a $-0,8 \leq r < -0,5$). Esses resultados foram também observados por Costa (2012).

As variáveis Argila, Pt e Micro apresentaram correlação positiva para as variáveis CC e PMP. Isto resultou em correlações que variaram de fraca ($0,1 \leq r < 0,5$) a forte positiva ($0,8 \leq r < 1$). As variáveis Ds, Pt e Micro obtiveram as maiores correlações com a variável CC, apresentadas na coluna de 0,0 – 0,40 m. Para o PMP as maiores correlações foram observadas nas variáveis Micro, Argila e MO, também na coluna de 0,0 – 0,40 m. Esses resultados corroboram com estudos que mostram que a estrutura do solo está diretamente relacionada aos potenciais baixos de 33 kPa enquanto que, para potenciais elevados, a MO bem como a Argila, possuem maior influência. Segundo Pádua et al. (2015), solos argilosos possuem maior microporosidade e maior retenção de MO. Por esse fato, o PMP pode estar diretamente relacionada às variáveis Micro, Argila e MO observadas na correlação de Pearson. Resultados semelhantes foram encontrados nos trabalhos de Marcolin e Klein (2011) e Ramos (2017).

4.3 FPTs geradas por meio de regressões lineares múltiplas

4.3.1 Pressupostos básicos e seleção dos modelos

As RLMs foram geradas utilizando-se o Software *IBM SPSS Statistics* (IBM CORPORATION, 2017) com a função de regressão linear múltipla e o método *Stepwise* para inserção das variáveis e desenvolvimento dos modelos. Foram atendidos aos pressupostos básicos descritos no tópico 3.5.1.2 para as duas variáveis independentes analisadas (CC e PMP). Após a remoção de *Outliers*, obteve-se uma tabela com 221 dados dos quais foram divididos em 60% (133) para modelagem e 40% (88) para validação, conforme proposto no Item 3.5.1.4. Isto garantiu um número de repetições (n) de 133 para cada variável independente. As duas variáveis seguiram distribuição normal para os Resíduos, observados por meio de Gráficos

Histograma e P-P Plot Normal. A homocedasticidade e a relação linear entre variáveis dependentes e independentes foram observadas por meio do Gráfico de dispersão.

Para análise da variável dependente CC (33 kPa), observa-se na Tabela 10 o valor de Durbin-Watson (D) de 1,748. Considera-se aceitáveis valores maiores que $D_L = 1,686$ e $D_U = 1,747$, para um $n = 133$, com duas variáveis independentes (Micro e Ds) e um nível de significância de 5%. Esse resultado garante a independência dos resíduos – diferença entre os valores previstos e observados (DURBIN e WATSON, 1950). Na Tabela 10 nota-se o resumo dos modelos estatísticos gerados para a variável de capacidade de campo, com o intuito de compará-los com um modelo sem preditores. O r representa o coeficiente de Pearson com a correlação entre as variáveis dependentes e independentes no modelo gerado. O R^2 indica a porcentagem de variação na variável dependente que é explicada pela variável independente no modelo. A estatística da mudança resume o quanto cada modelo matemático construído melhorou, em termos de previsão, comparados ao modelo sem previsor. Ainda na estatística da mudança, o F da Mud. e p-Value representam a ANOVA gerada pelo sistema para teste das hipóteses geradas (Ex: H_0 : o ajuste do modelo 1 = ajuste do modelo sem previsor; H_1 : o ajuste do modelo 1 \neq o ajuste do modelo sem previsor). Os modelos apresentaram as seguintes variáveis preditoras: Microporosidade (Micro) e Densidade do Solo (Ds).

TABELA 10 – Resumo dos modelos estatísticos gerados para a variável dependente CC.

Modelo	r	R ²	R ² ajust.	Estatísticas da mudança			Durbin-Watson
				R ² da Mud.	F da Mud.	p-Value	
1	0,900 ^a	0,810	0,808	0,810	558,062	0,000	
2	0,910 ^b	0,828	0,825	0,018	13,429	0,000	1,748

Modelo = modelo estatístico; r = coeficiente de Pearson; R^2 = raiz quadrada do coeficiente de Pearson; R^2 ajust. = R^2 Ajustado; E.P da est. = Erro padrão da estimativa; R^2 da Mud. = R^2 da Mudança; F da Mud. = F (5%) da Mudança; a. Preditores: (Constante), Micro; b. Preditores: (Constante), Micro, Ds; c. Variável Dependente: CC

Os coeficientes de Pearson (r) para os dois modelos gerados na Tabela 10 apresentaram valores altos de correlação ($0,8 \leq r < 1$), demonstrando uma forte correlação entre os valores observados e preditos em cada modelo. O R^2 foi de 0,810 para o modelo 1 e 0,828 para o modelo 2. Com isso, nota-se um aumento no seu valor com o acréscimo de uma nova variável preditora. Esse fenômeno é previsto, já que é uma tendência do R^2 de aumentar com o acréscimo de novas variáveis preditoras ao modelo. Logo, o R^2 ajust. foi analisado como forma de verificação dessa tendência. O R^2 ajust. também aumentou, demonstrando a capacidade real preditiva de cada modelo. O R^2 da mudança informou o quanto cada modelo é melhor prevendo comparado ao

modelo anterior. Com a análise de F da Mud. e p-Value nota-se que os modelos 1 e 2 ($0,001 \leq p < 0,01$) apresentaram uma evidência altamente significativa do H_1 .

A Tabela 11 representa a ANOVA gerada para a variável dependente CC com o intuito de comparar os modelos observados na Tabela 10 com um modelo sem preditores. A ANOVA segue as mesmas hipóteses estatísticas da tabela anterior (Ex: H_0 : o ajuste do modelo 1 = ajuste do modelo sem previsor; H_1 : o ajuste do modelo 1 \neq o ajuste do modelo sem previsor). Logo, os valores do p-Value no Teste F foram todos significativos a 5% de probabilidade, indicando que o acréscimo de uma nova variável preditora melhorou na qualidade de predição do modelo ($p < 0,05$).

TABELA 11 – ANOVA da variável dependente CC.

	Modelo	SQ	QM	F	p-Value
1	Regressão	22.1551,216	22.1551,216	558,062	0,000 ^b
	Resíduo	52.007,132	397,001		
	Total	273.558,348			
2	Regressão	226.420,495	11.3210,247	312,219	0,000 ^c
	Resíduo	47.137,854	362,599		
	Total	273.558,348			

Modelo = modelo estatístico; SQ = Soma dos quadrados; QM = Quadrado médio; F = Teste F (5%); a. Variável Dependente: CC; b. Preditores: (Constante), Micro; c. Preditores: (Constante), Micro, Ds

A Tabela 12 representa a tabela de coeficientes que serviram na interpretação do peso de cada variável independente ao modelo e se elas foram realmente relevantes para o modelo. Os coeficientes não padronizados apresentados na tabela são os coeficientes com as unidades de medida observados para cada variável preditora e predita. Os coeficientes padronizados representam de forma adimensional essas mesmas variáveis do modelo, o que facilita a comparação entre os diferentes coeficientes. O Teste t a 5% de probabilidade foi feito para cada coeficiente padronizado Beta, cuja hipótese de nulidade (H_0) é que o coeficiente seja igual a 0 e o H_1 que o coeficiente seja diferente de 0. A Constante representa o ponto de intersecção da reta com o eixo Y. Para o Modelo 2, o valor de p-Value da Constante foi significativo a 5% e 1% de probabilidade (0,753), indicando não ser estatisticamente diferente de 0, logo a reta pode passar pela origem.

TABELA 12 – Tabela de coeficientes da variável CC para análise da RLM.

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	p-Value	Estatísticas de colinearidade	
	B	Erro	Beta			Tolerância	VIF
1	(Constante)	-155,461	19,540				
	Micro	1.014,386	42,940	0,900	23,623	0,000	1,000
2	(Constante)	15,859	50,343		0,315	0,753	
	Micro	863,780	58,079	0,766	14,873	0,000	0,499
	Ds	-77,042	21,024	-0,189	-3,665	0,000	0,499

t = Teste t (5%);

Ainda sobre a Tabela 12, os Coeficientes padronizados Beta indicaram o peso de cada variável na predição do modelo. Quanto maior o coeficiente melhor a capacidade de predição dessa variável em relação a outra variável, em valores absolutos. Logo, para o Modelo 2 a variável Micro apresentou valor de coeficiente padronizado Beta 0,766 e Ds -0,189. O Test t foi feito para verificar se a variável está sendo ou não significativa ao modelo. Com isto, para o modelo 2, as duas variáveis preditoras foram significativas ao modelo pelo Test t a 5% de probabilidade. A ausência de multicolinearidade foi analisada pelos valores de Tolerância e VIF. O pressuposto foi garantido para valores de Tolerância superiores a 0,1 e VIF inferiores a 10.

A partir das análises das Tabelas 10, 11 e 12 foi verificado se os modelos matemáticos gerados com a regressão linear múltipla, contendo as variáveis preditoras (Microporosidade e Densidade do Solo), foram capazes de prever a variável Capacidade de Campo. A análise resultou em dois modelos estatisticamente significativos gerados. O modelo 2 [F(2,130) = 312,2919; p < 0,05; R² = 0,828] com as variáveis Microporosidade e Densidade do Solo, foi o modelo que melhor explicou a variável predita Capacidade de Campo. Portanto, as variáveis Microporosidade ($\beta = 0,766$; t = 14,873; p < 0,05) e Densidade do Solo ($\beta = -0,189$; t = -3,665; p < 0,05) são preditoras da CC. Essas variáveis foram também observadas por Costa (2012), Soares (2013) e Mendes (2014) em seus modelos matemáticos de regressão linear múltipla.

A Equação 12 representa o modelo gerado pela RLM para a predição da variável CC:

$$CC = 15,859 + 863,780 * \text{Micro} - 77,042 * \text{Ds} \quad \text{Eq. (12)}$$

Em que:

CC = Capacidade de Campo (g kg^{-1});

$Micro$ = Microporosidade ($\text{m}^3 \text{m}^{-3}$);

Ds = Densidade do Solo (g cm^{-3});

Para análise da variável dependente PMP (1.500 kPa), observa-se na Tabela 13 o valor de Durbin-Watson (D) 0,644. Considera-se aceitáveis valores maiores que $D_L = 1,655$ e $D_U = 1,779$, para um $n = 133$, com quatro variáveis independentes (Micro, Pt, MO e Argila) e um nível de significância de 5%. Portanto, para essa variável não é garantido o pressuposto de independência dos resíduos (DURBIN e WATSON, 1950). Outro índice usado para verificação e complemento desse pressuposto foi o índice I de Moran (MORAN, 1950). Esse índice é a estatística mais famosa e largamente utilizada quando se deseja mensurar a auto correlação de uma determinada variável alocada em um espaço bidimensional (CARRIJO, 2015). Foram geradas duas classes de distância geográfica pela análise do índice I de Moran, a partir do software R (R CORE TEAM, 2015). A primeira classe (Classe1: $I=0,806$; $p\text{-Value}=0,001$) indica lugares geograficamente próximos; a segunda classe (Classe2: $I=-0,011$; $p\text{-Value}=0,002$) indica lugares mais distantes. Ambas as classes apresentaram valores significativos com forte correlação. O valor positivo da primeira classe indica que lugares geograficamente próximos tem resíduos similares, confirmando a falta de independência dos resíduos. Na Tabela 13 nota-se o resumo dos modelos estatísticos gerados para a variável de ponto de murcha permanente, com o intuito de compará-los a um modelo sem preditores.

TABELA 13 – Resumo dos modelos estatísticos gerados para a variável dependente PMP.

Modelo	r	R ²	R ² ajus.	Estatísticas da mudança			Durbin-Watson
				R ² da Mud.	F da Mud.	p-Value	
1	0,389 ^a	0,151	0,145	0,151	23,362	0,000	
2	0,443 ^b	0,196	0,184	0,045	7,213	0,008	
3	0,493 ^c	0,243	0,226	0,047	8,050	0,005	
4	0,525 ^d	0,276	0,253	0,033	5,761	0,018	0,644

Modelo = modelo estatístico; r = coeficiente de Pearson; R² = raiz quadrada do coeficiente de Pearson; R² ajus. = R² Ajustado; E.P da est. = Erro padrão da estimativa; R² da Mud. = R² da Mudança; F (5%) da Mud. = F da Mudança; Sig. Mud. F = Significância do F da mudança; a. Preditores: (Constante) e Micro; b. Preditores: (Constante), Micro e Pt; c. Preditores: (Constante), Micro, Pt e MO; d. Preditores: (Constante), Micro, Pt, MO e Argila; e. Variável Dependente (PMP)

Na Tabela 13, para os modelos 1, 2 e 3 gerados, o r oscilou entre $0,1 \leq r < 0,5$, demonstrando uma correlação fraca entre os valores preditos e os valores observados. No modelo 4, o r apresentou uma correlação moderada ($0,5 \leq r < 0,8$). O R^2 foi de 0,151 para o modelo 1 e 0,276 para o modelo 4, com quatro preditores. O R^2 ajustado indicou a real capacidade preditiva dos modelos. Logo, a melhor capacidade explicativa para a variável dependente pelas variáveis independentes foi obtida no modelo 4, com quatro variáveis predictoras (Micro, Argila, Pt e MO). Apesar disto, o modelo 4 demonstrou baixa capacidade preditiva, explicando a variável PMP em apenas 25,3%. Com a análise de F da Mud. e p-Value a 5% de probabilidade, nota-se que os modelos 1, 2, 3 e 4 apresentaram uma evidência altamente significativa do H_1 .

A Tabela 14 representa a ANOVA gerada para a variável dependente PMP com o intuito de comparar os modelos observados na Tabela 13 com um modelo sem preditores. A ANOVA segue as mesmas hipóteses estatísticas da tabela anterior (Ex: H_0 : o ajuste do modelo 1 = ajuste do modelo sem previsor; H_1 : o ajuste do modelo 1 \neq o ajuste do modelo sem previsor). Logo, os valores do p-Value no Teste F foram todos significativos a 5% de probabilidade, indicando que o acréscimo de uma nova variável preditora melhorou na qualidade de predição do modelo ($p < 0,05$).

TABELA 14 – ANOVA da variável dependente PMP.

Modelo		Soma dos Quadrados	Quadrado Médio	F	p-Value
1	Regressão	21.300,731	21.300,731	23,362	0,000 ^b
	Resíduo	119.441,431	911,767		
	Total	140.742,162			
2	Regressão	27.579,692	13.789,846	15,842	0,000 ^c
	Resíduo	113.162,470	870,481		
	Total	140.742,162			
3	Regressão	34.226,362	11.408,787	13,817	0,000 ^d
	Resíduo	106.515,800	825,704		
	Total	140.742,162			
4	Regressão	38.814,041	9.703,510	12,18	0,000 ^d
	Resíduo	101.928,121	796,313		
	Total	140.742,162			

Modelo = modelo estatístico; SQ = Soma dos quadrados; QM = Quadrado médio; F = Teste F (5%). a. Variável Dependente: PMP; b. Preditores: (Constante), Micro; c. Preditores: (Constante), Micro, Argila; d. Preditores: (Constante), Micro, Argila, Pt; e. Preditores: (Constante), Micro, Argila, Pt, MO.

Na Tabela 15 nota-se que o Teste t a 5% de probabilidade foi feito para cada coeficiente padronizado Beta, cuja hipótese de nulidade (H_0) é que o coeficiente seja igual a 0 e o H_1 que

o coeficiente seja diferente de 0. A Constante representa o ponto de intersecção da reta com o eixo Y. Para os Modelos 1, 2, 3 e 4, os valores de p-Value da Constante foram maiores que 0,05 indicando não serem estatisticamente diferentes de 0, logo a reta pode passar pela origem. Ainda sobre a Tabela 15, os Coeficientes padronizados Beta indicaram o peso de cada variável na predição do modelo. Quanto maior o coeficiente melhor a capacidade de predição dessa variável em relação a outra variável, em valores absolutos. Para o Modelo 4 as variáveis Micro, Pt, MO e Argila, apresentaram valores de coeficiente padronizado Beta de 0,892, -0,721, 0,234 e 0,198, respectivamente. O Test t foi realizado para verificar se a variável está sendo ou não significativa ao modelo. Com isto, para o modelo 4, as quatro variáveis preditoras foram significativas ao modelo pelo Test t a 5% de probabilidade. A ausência de multicolinearidade foi analisada pelos valores de Tolerância e VIF. O pressuposto foi garantido para valores de Tolerância superiores a 0,1 e VIF inferiores a 10.

TABELA 15 – Tabela de coeficientes da variável PMP para análise da RLM.

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	p-Value	Estatísticas de colinearidade		
	B	Erro	Beta			Tolerância	VIF	
1	(Constante)	-27,002	29,613		-0,979	0,329		
	Micro	314,531	65,074	0,389	4,833	0,000	1,000	1,000
2	(Constante)	-15,910	29,342		-0,542	0,589		
	Micro	795,504	190,036	0,984	4,186	0,000	0,112	8,933
	Pt	-487,541	181,529	-0,631	-2,686	0,008	0,112	8,933
3	(Constante)	-42,352	30,059		-1,409	0,161		
	Micro	814,701	185,208	1,008	4,399	0,000	0,112	8,945
	Pt	-589,491	180,413	-0,763	-3,267	0,001	0,108	9,302
	MO	3,140	1,107	0,244	2,837	0,005	0,796	1,256
4	(Constante)	-40,479	29,530		-1,371	0,173		
	Micro	557,286	185,999	0,892	3,878	0,000	0,107	9,354
	Pt	-557,015	177,689	-0,721	-3,135	0,002	0,107	9,356
	MO	3,011	1,088	0,234	2,767	0,006	0,794	1,259
	Argila	0,057	0,24	0,198	2,400	0,018	0,831	1,204

t = Teste t (5%).

A partir das análises das Tabelas 13, 14 e 15 foi verificado se os modelos matemáticos gerados com a regressão linear múltipla, contendo as variáveis preditoras (Microporosidade,

Porosidade Total, Matéria Orgânica e Argila), foram capazes de prever a variável Ponto de Murcha Permanente. A análise resultou em quatro modelos estatisticamente significativos gerados, porém o modelo 4 [$F(4,128) = 12,186$; $p < 0,05$; $R^2 = 0,276$] com as variáveis Microporosidade, Porosidade Total, Matéria Orgânica e Argila foi o modelo que melhor explicou a variável predita Ponto de Murcha Permanente dentre os modelos analisados. Apesar disso, pela baixa capacidade preditiva do modelo, com a análise do R^2 , esse modelo não é indicado para a predição da variável PMP. Logo, as variáveis Microporosidade ($\beta = 0,892$; $t = 3,878$; $p < 0,05$), Porosidade Total ($\beta = -0,721$; $t = -3,135$; $p < 0,05$), Matéria Orgânica ($\beta = 0,234$; $t = 2,767$; $p < 0,05$) e Argila ($\beta = 0,198$; $t = 2,400$; $p < 0,05$), nas condições observadas neste estudo, não foram capazes de predizer de maneira satisfatória o PMP. A Equação 13 representa o modelo gerado para a predição da variável PMP:

$$PMP = -40,479 + 721,286 * \text{Micro} - 557,015 * Pt + 3,011 * MO + 0,057 * \text{Argila} \quad \text{Eq. 13}$$

Em que:

PMP = Ponto de Murcha Permanente (g kg^{-1});

Micro = Microporosidade ($\text{m}^3 \text{ m}^{-3}$);

Argila = Argila (g kg^{-1});

Pt = Porosidade Total ($\text{m}^3 \text{ m}^{-3}$);

MO = Matéria Orgânica (g kg^{-1}).

4.3.2 Desempenho e validação dos modelos de RLM

O desempenho e eficiência dos modelos gerados pelas RLMs, tanto na parte de modelagem quanto na validação, foi feito adotando-se como critérios avaliativos: O Coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2) (SCHULTZ e SCHULTZ, 1992); Índice de concordância (c) (WILLMONTT, 1981); Índice de desempenho (id) (CAMARGO e SENTELHAS, 1997); Erro médio relativo (P%) e Erro Quadrático Médio (EQM).

Nota-se na Tabela 16 que o índice de desempenho (id) observado na fase de modelagem para o modelo 2 (CC) com duas variáveis preditoras (Micro e Ds) foi de 0,8653, obtivendo um desempenho classificado como Ótimo ($>0,85$). Na fase de validação, o id foi de 0,835 classificado como Muito bom ($0,76 \leq id \leq 0,85$). O R^2 (coeficiente de determinação) para a

etapa de modelagem foi de 0,828 e 0,787 na validação. Os valores de r na modelagem e validação apresentaram uma forte correlação do modelo entre os dados estimados e observados, pela tendência ser próxima a 1 (0,910 e 0,887, respectivamente). Já para o índice de concordância (WILLMONT, 1981), que fornece o grau de exatidão entre as variáveis envolvidas na análise, valores observados e valores estimados apresentaram índices de 0,951 e 0,941 para modelagem e validação (próximos de 1).

TABELA 16 – Resultados dos indicadores estatísticos da regressão linear múltipla selecionada para a capacidade de campo (33 kPa).

RLM	Modelo	Fase	EQM	P(%)	R ²	r	c	id	Desemp.
CC	2	Modelagem	0,031	49,944	0,828	0,910	0,951	0,865	Ótimo
		Validação	0,053	51,888	0,787	0,887	0,941	0,835	Muito bom

RLM: regressão linear múltipla; EQM: erro quadrático médio; P(%): erro médio relativo; R²: coeficiente de determinação; r: coeficiente de correlação de Pearson; c: índice de concordância; id: índice de desempenho.

Na Tabela 17, para a variável ponto de murcha permanente, observa-se que o índice de desempenho (id) na modelagem para o modelo 4 (PMP) com quatro variáveis preditoras (Micro, Pt, MO e Argila) foi de 0,337. Na fase de validação o id foi de 0,264, ambos classificados como Péssimo (<0,41). O R² para a etapa de modelagem foi de 0,276 e 0,164. Os valores de r na modelagem e validação apresentaram uma correlação moderada ($0,5 \leq r < 0,8$). Já para o índice de concordância (WILLMONT, 1981), os valores na fase de modelagem foram de 0,6422 e 0,5998 na validação.

TABELA 17 – Resultados dos indicadores estatísticos da regressão linear múltipla selecionada para o ponto de murcha permanente (1.500 kPa).

RLM	Modelo	Fase	EQM	P(%)	R ²	r	c	id	Desemp.
PMP	4	Modelagem	0,167	222,055	0,276	0,525	0,642	0,337	Péssimo
		Validação	0,226	236,499	0,164	0,441	0,599	0,264	Péssimo

RLM: regressão linear múltipla; EQM: erro quadrático médio; P(%): erro médio relativo; R²: coeficiente de determinação; r: coeficiente de correlação de Pearson; c: índice de concordância; id: índice de desempenho.

As Figuras 26 e 27 representam os dados observados e estimados pelos modelos escolhidos para as variáveis capacidade de campo e ponto de murcha permanente, respectivamente. Os dados observados e estimados da capacidade de campo, apresentaram uma forte tendência com um erro relativo baixo evidenciando a capacidade de predição do modelo 2 com duas variáveis preditoras (Micro e Ds), uma vez que os valores estimados praticamente acompanharam os valores observados para os 133 pontos amostrados. Para a variável PMP, o modelo 4 com quatro variáveis preditoras (Micro, Pt, MO e Argila), apresentou baixa

capacidade de predição comparando-se os valores estimados com os observados. Soares (2013) em seu trabalho com solos do Rio Grande do Sul conseguiu estimar as umidades do solo com parâmetros semelhantes no modelo de Regressão Linear Múltipla. Mendes (2014) também obteve resultados similares para a predição das umidades do solo em solos argilosos no Rio Grande do Sul, utilizando RLMs como uma das metodologias de estimativa.

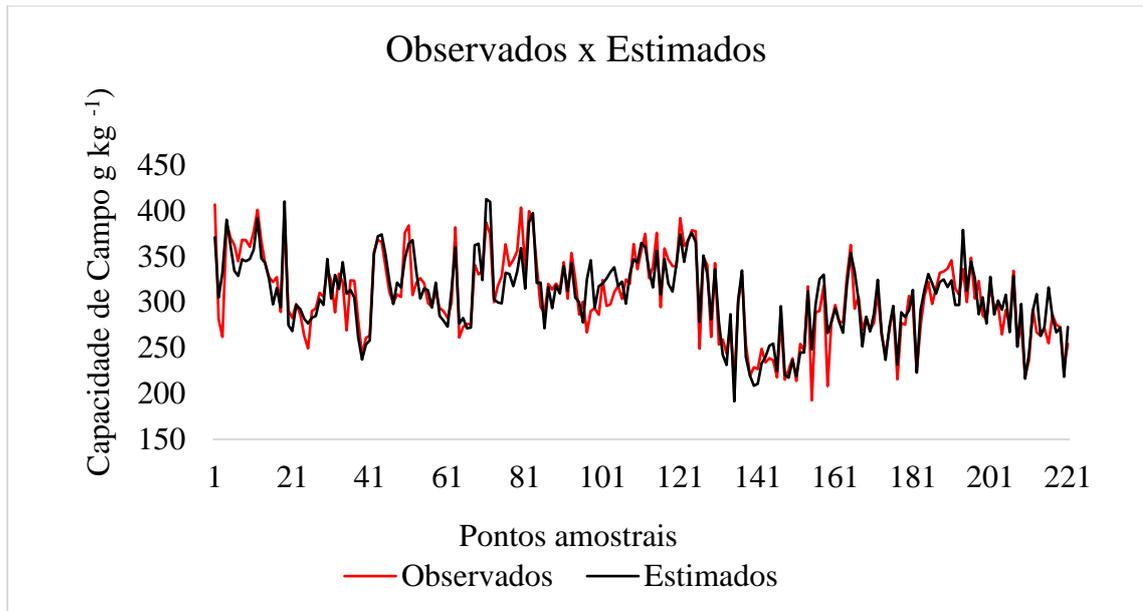


FIGURA 26 – Comparativo geral dos valores observados e estimados do modelo 2, com dois preditores para a variável CC (33 kPa).

Fonte: Próprio autor.

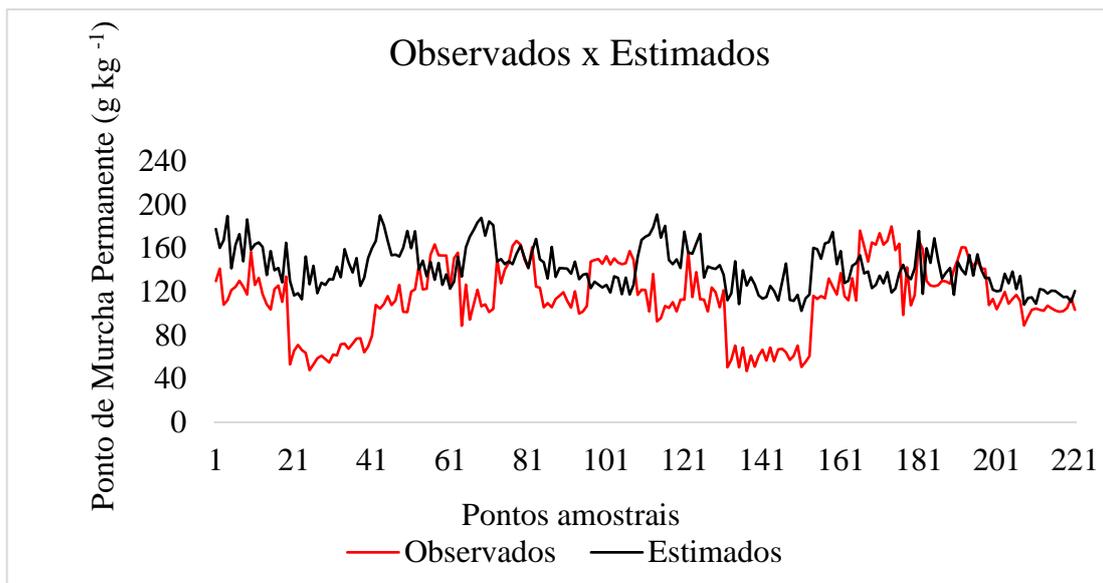


FIGURA 27 – Comparativo geral dos valores observados e estimados do modelo 4, com quatro preditores para a variável PMP (1.500 kPa).

Fonte: Próprio autor.

O Teste-t foi feito para verificar se houve diferença significativa entre as variáveis observadas e as variáveis estimadas pelos modelos de RLM tanto para CC quanto para PMP. Constatou-se a 95% de significância (n=221) que, para a variável CC, não houve diferença significativa entre os valores observados e os estimados ($t=-0,285$; $p\text{-Value}=0,775$), demonstrando a confiabilidade do modelo. Para o PMP, apesar do modelo não ser indicado para a estimativa da variável por ter apresentado índices de desempenho péssimos tanto na modelagem quanto na validação, bem como valores de R^2 também baixos, os valores estimados não diferiram significativamente pelo Teste-t a 95% de significância (n=221) dos valores observados ($t=0,197$; $p\text{-Value}=0,843$).

4.4 FPTs geradas por meio de redes neurais artificiais

4.4.1 Treinamento das RNAs

Devido ao grande número de redes treinadas, foi necessário a utilização do programa desenvolvido por Rocha (2019). Com isso foi possível variar a complexidade da arquitetura de cada rede (número de neurônios da camada oculta e de entrada). Braga et al. (2012) menciona problemas de dimensionamento e ajuste do número de neurônios em relação a complexidade do problema a ser resolvido. Logo, foi possível ajustar e evidenciar o índice de desempenho para cada número de neurônios nas camadas oculta e de entrada.

Foram testados oito modelos que variaram os neurônios da camada de entrada (Figura 28), tanto para CC quanto para PMP. Foi alterado também o número de neurônios da camada oculta, que variou de 1 a 20 neurônios. Sendo assim, foram realizados 1.000 treinamentos para cada número de neurônios da camada oculta. Isso totalizou 20.000 treinamentos para cada modelo de RNA, resultando ao final em 160.000 redes treinadas para CC e PMP. Foi utilizado o banco de dados completo (com *Outliers*) com as 240 amostras, conforme descrito no item 3.5.2.2.

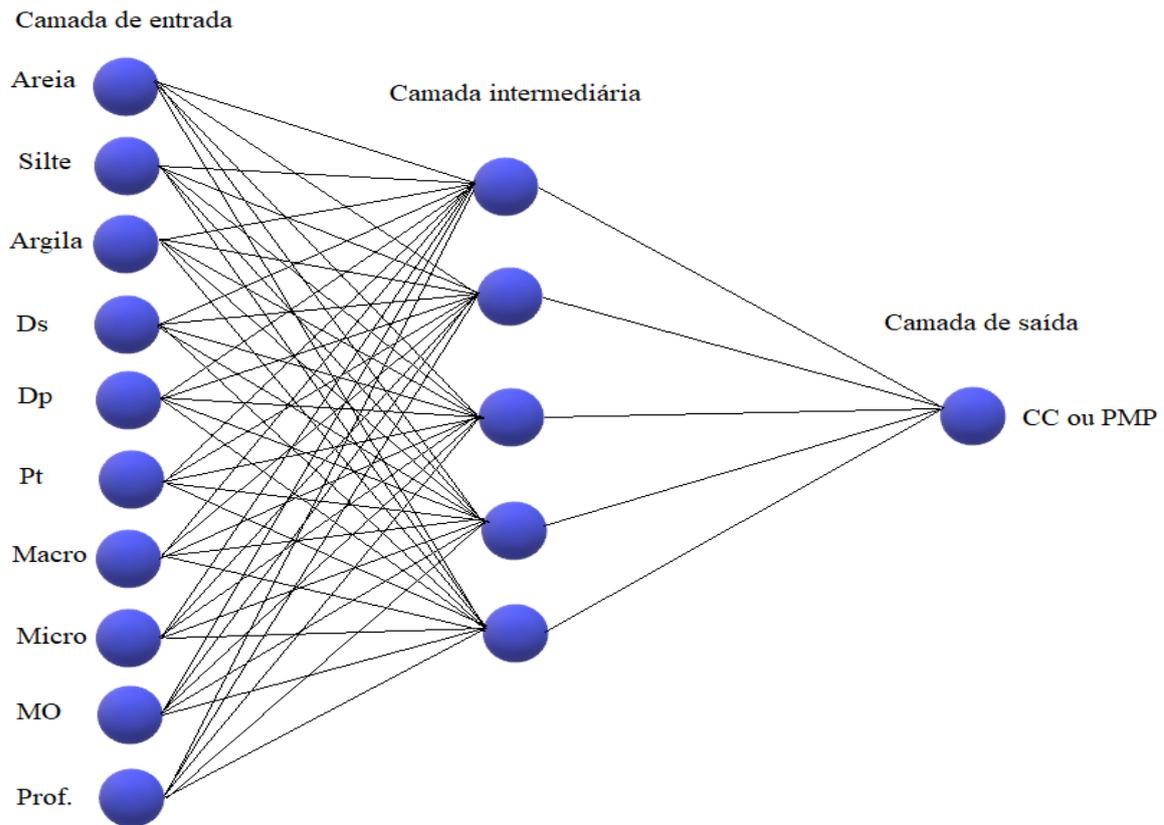


FIGURA 28 – Exemplo de arquitetura de rede com 10 neurônios na camada de entrada, 5 neurônios na camada oculta e 1 neurônio na camada de saída.

Fonte: Próprio autor.

Utilizando a função TREINAR, foram realizados os treinamentos para as 20.000 redes do tipo MLP de cada modelo proposto pelo número de neurônios da camada de entrada, que levou aproximadamente seis horas para cada modelo. Para começar o treinamento foi necessário preencher alguns parâmetros observados na Tabela 18.

TABELA 18 – Parâmetros utilizados para realizar o treinamento das redes MLP.

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

Fonte: Rocha (2019).

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

Após o treinamento foi realizada a quantificação dos resultados em relação ao desempenho das redes. A Tabela 19 representa a quantificação desses resultados para a variável CC, nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, observando-se os quatro modelos propostos. Para o treinamento da RNA (Modelo 1) nota-se que não houve nenhuma rede com desempenho Ótimo em nenhuma fase. Para esse modelo a maior parte dos resultados ficou com um desempenho Mal ou Péssimo. Isso demonstra que esse modelo com essas variáveis de entrada (Areia, Silte e Argila) não foram bons preditores para explicar a CC. Com o incremento de mais variáveis à camada de entrada com os Modelos 2 (Areia, Silte, Argila, Ds, Dp e MO) e 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Macro, Micro e Profundidade), observou-se que o desempenho em todas as fases melhorou. Isso é um ponto positivo para a RNA já que, comparada a RLM, foi capaz de melhorar seu desempenho com o incremento de mais variáveis preditoras. Para o Modelo 4, com duas variáveis na camada de entrada (Micro e Ds) conforme o modelo escolhido para a RLM, a rede apresentou mais de 19.000 resultados na fase de treinamento e 869 redes na fase de validação externa, ambas com desempenho Ótimo. Um fenômeno observado nos quatro modelos apresentados foi o fenômeno de *overfitting* onde as redes começaram a se especializar apenas no conjunto de treinamento. Com isso, nota-se uma redução do número de redes com o mesmo desempenho entre a fase de Treinamento e Validação Externa.

TABELA 19 – Quantificação das RNAs em relação ao desempenho nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, para os quatro modelos testados com a variável de saída Capacidade de Campo (CC – 33 kPa).

Modelo	Geral	Treinamento	Validação	Teste	Validação Externa	Desempenho
1	0	0	0	0	0	Ótimo
	0	5	0	0	0	Muito Bom
	0	70	0	0	0	Bom
	0	103	11	1	0	Mediano
	35	445	140	46	14	Sofrível
	523	1.494	1.070	343	525	Mal
	19.442	17.883	18.779	19.610	19.461	Péssimo
2	120	3.513	1.270	573	1	Ótimo
	12.225	11.422	6.600	4.823	14	Muito Bom
	7.194	4.664	6.716	6.682	4.995	Bom
	264	223	2.000	2.632	8.976	Mediano
	121	111	2.215	3.147	5.083	Sofrível
	37	31	812	1.399	647	Mal
	39	36	387	744	284	Péssimo
3	19.418	19.696	12.328	10.832	5.043	Ótimo
	517	251	6.902	6.254	11.756	Muito Bom
	36	26	676	2.174	2.623	Bom
	3	3	41	367	315	Mediano
	6	4	23	260	185	Sofrível
	3	2	12	57	38	Mal
	17	18	18	56	40	Péssimo
4	18.484	19.231	13.155	9.585	869	Ótimo
	1.177	585	5.958	7.513	14.384	Muito Bom
	188	36	664	1.681	3.158	Bom
	7	11	37	279	564	Mediano
	8	1	33	285	463	Sofrível
	0	1	10	162	195	Mal
	136	135	143	495	367	Péssimo

Fonte: Próprio autor.

Na Tabela 20 observa-se a quantificação dos desempenhos nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, para a variável PMP, conforme os quatro modelos propostos. Para o treinamento da RNA com Modelo 5, nota-se que não houve nenhuma rede com desempenho Ótimo em nenhuma fase. Em contrapartida, esse modelo apresentou redes com desempenhos Bom a Mediano para todas as fases. Comparado ao Modelo 1 de CC, nota-se que as variáveis de entrada Areia, Silte e Argila, se mostraram melhores preditores da variável PMP. Com o incremento de mais variáveis à camada de entrada com os Modelos 6

(Areia, Silte, Argila, Ds, Dp e MO) e 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Macro, Micro e Profundidade), observou-se que o desempenho em todas as fases melhorou. Isso também foi observado para os Modelos 2 e 3 de CC. Para o Modelo 8, com quatro variáveis na camada de entrada (Micro, Pt, MO e Argila), conforme o modelo escolhido para a RLM, a rede apresentou desempenho Bom em todas as fases, exceto na fase de validação externa, que começou apresentar desempenho de Sofrível a Péssimo. O fenômeno de *overfitting* também foi observado para as redes.

TABELA 20 – Quantificação das RNAs em relação ao desempenho nas fases: Geral, Treinamento, Validação, Teste e Validação Externa, para os quatro modelos testados com a variável de saída Ponto de Murcha Permanente (PMP – 1.500 kPa).

Modelo	Geral	Treinamento	Validação	Teste	Validação Externa	Desempenho
5	0	0	0	0	0	Ótimo
	0	57	17	3	0	Muito Bom
	13	534	621	213	2	Bom
	144	1.435	1.172	537	75	Mediano
	8.652	9.785	4.516	2.877	2.087	Sofrível
	7.689	4.917	5.431	4.920	7.285	Mal
	3.502	3.272	8.243	11.450	10.551	Péssimo
6	2	1.073	2	1	0	Ótimo
	469	2.994	209	38	18	Muito Bom
	4.905	6.148	1.987	709	591	Bom
	4.417	2.727	2.002	1.066	1.043	Mediano
	5.448	3.196	5.291	3.765	4.269	Sofrível
	2.116	1.698	4.852	5.022	5.294	Mal
	2.643	2.164	5.657	9.399	8.785	Péssimo
7	0	1.776	0	9	0	Ótimo
	440	3.843	15	130	9	Muito Bom
	4.525	4.896	419	831	244	Bom
	3.316	1.896	898	994	411	Mediano
	5.007	3.047	4.354	2.991	2.077	Sofrível
	3.479	2.341	6.020	4.135	3.906	Mal
	3.233	2.201	8.294	10.910	13.353	Péssimo
8	0	18	0	0	0	Ótimo
	0	67	3	0	0	Muito Bom
	7	271	89	21	0	Bom
	39	462	248	69	0	Mediano
	760	3.059	1.700	706	5	Sofrível
	6.738	7.647	4.231	2.516	50	Mal
	12.456	8.476	13.729	16.688	19.945	Péssimo

Fonte: Próprio autor.

4.4.2 Escolha das RNAs

Conforme proposição de Braga et al. (2012), para que as redes possam ter êxito com mais conjuntos de dados, torna-se imprescindível que estas consigam generalizar o problema. Visto isso, o primeiro critério de escolha foi o desempenho na fase de validação externa. Quanto melhor o desempenho observado nessa fase, maior será a capacidade de generalização da rede.

Logo, foram selecionadas as redes com os melhores desempenhos na fase de validação externa para cada modelo proposto. O segundo critério de escolha foi a observação dos melhores desempenhos das redes nas demais fases (Geral, Treinamento, Validação e Teste). O desempenho baseado na técnica de Camargo e Sentelhas, (1997), mostra em termos de exatidão (r) e precisão (c) a confiança apresentada pelo modelo. Com isso, a Tabela 21 apresenta o número de redes selecionadas nesse critério.

TABELA 21 – Número de redes selecionadas a partir do critério de desempenho de Camargo e Sentelhas (1997).

Modelo	Entrada	Saída	Quantidade
1	Areia, Silte, Argila	CC	1
2	Areia, Silte, Argila, Ds, Dp e MO	CC	3
3	Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade	CC	2.702
4	Micro e Ds	CC	150
5	Areia, Silte, Argila	PMP	1
6	Areia, Silte, Argila, Ds, Dp e MO	PMP	7
7	Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade	PMP	7
8	Micro, Pt, MO e Argila	PMP	3

Fonte: Próprio autor.

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

Segundo Braga et al. (2012) redes com menor número de neurônios na camada oculta têm maior capacidade de generalização. Isso se deve ao fato de que redes com grande número de neurônios na camada oculta podem resultar em *overfitting*. Quanto maior a estrutura, maior

o número de parâmetros livres ajustáveis e, conseqüentemente, maior a flexibilidade da rede, gerando redes que memorizam os dados de entrada superdimensionadas.

Dentre as redes pré-selecionadas, foram escolhidas apenas uma RNA para cada modelo, que obteve a melhor resposta dentre os parâmetros analisados. Na Tabela 22 encontram-se as redes escolhidas para cada modelo testado com o respectivo número de neurônios na camada oculta.

TABELA 22 – Resultados dos indicadores estatísticos das redes selecionadas para os modelos propostos.

Mod.	Neur.	Calib.	EQM	P(%)	R ²	r	c	id	Desemp.
1	19	Geral	0,061	246,937	0,319	0,565	0,743	0,420	Mal
		Trein.	0,037	243,967	0,561	0,749	0,843	0,632	Mediano
		Val. Int.	0,094	209,001	0,134	0,366	0,631	0,231	Péssimo
		Teste	0,142	298,974	0,032	-0,178	0,281	0,050	Péssimo
		Val. Ext.	0,047	178,615	0,438	0,662	0,802	0,531	Sofrível
2	6	Geral	0,022	136,920	0,734	0,857	0,922	0,790	Muito bom
		Trein.	0,016	148,021	0,805	0,897	0,943	0,846	Muito bom
		Val. Int.	0,035	95,347	0,632	0,795	0,884	0,703	Bom
		Teste	0,038	125,762	0,621	0,788	0,866	0,682	Bom
		Val. Ext.	0,018	125,195	0,750	0,866	0,919	0,796	Muito bom
3	6	Geral	0,006	111,814	0,925	0,962	0,981	0,943	Ótimo
		Trein.	0,004	128,827	0,951	0,975	0,987	0,962	Ótimo
		Val. Int.	0,012	96,652	0,885	0,941	0,970	0,913	Ótimo
		Teste	0,009	40,770	0,912	0,955	0,975	0,930	Ótimo
		Val. Ext.	0,011	79,957	0,832	0,912	0,946	0,862	Ótimo
4	5	Geral	0,012	169,717	0,856	0,925	0,959	0,888	Ótimo
		Trein.	0,011	214,033	0,852	0,923	0,959	0,885	Ótimo
		Val. Int.	0,010	61,969	0,882	0,939	0,966	0,907	Ótimo
		Teste	0,016	66,966	0,848	0,921	0,956	0,881	Ótimo
		Val. Ext.	0,010	75,853	0,837	0,915	0,952	0,871	Ótimo
5	13	Geral	0,122	424,295	0,477	0,691	0,802	0,554	Sofrível
		Trein.	0,114	312,392	0,489	0,699	0,809	0,566	Sofrível
		Val. Int.	0,139	341,248	0,486	0,697	0,788	0,550	Sofrível
		Teste	0,144	1.038,880	0,430	0,656	0,781	0,512	Sofrível
		Val. Ext.	0,094	152,229	0,579	0,761	0,844	0,642	Mediano
6	4	Geral	0,090	336,051	0,616	0,785	0,875	0,687	Bom
		Trein.	0,087	338,589	0,619	0,787	0,874	0,687	Bom
		Val. Int.	0,084	232,916	0,604	0,777	0,869	0,675	Bom
		Teste	0,108	427,128	0,613	0,783	0,879	0,688	Bom
		Val. Ext.	0,070	330,031	0,689	0,830	0,906	0,752	Bom

...Continua...

TABELA 22, Cont...

Mod.	Neur.	Calib.	EQM	P(%)	R ²	r	c	id	Desemp.
7	4	Geral	0,069	304,029	0,832	0,912	0,912	0,766	Muito bom
		Trein.	0,047	313,494	0,885	0,941	0,941	0,840	Muito bom
		Val. Int.	0,109	323,349	0,734	0,857	0,857	0,643	Mediano
		Teste	0,113	196,376	0,719	0,848	0,848	0,622	Mediano
		Val. Ext.	0,065	313,532	0,712	0,844	0,919	0,775	Muito bom
8	6	Geral	0,122	408,172	0,482	0,694	0,816	0,566	Sofrível
		Trein.	0,084	319,025	0,619	0,787	0,868	0,683	Bom
		Val. Int.	0,158	177,507	0,540	0,735	0,824	0,606	Sofrível
		Teste	0,267	1062,286	0,048	0,218	0,528	0,115	Péssimo
		Val. Ext.	0,115	507,691	0,475	0,689	0,815	0,562	Sofrível

Mod.: Modelos propostos de RNA; Modelo1: Areia, Silte e Argila (CC); Modelo 2: Areia, Silte, Argila, Ds, Dp e MO (CC); Modelo 3: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (CC); Modelo 4: Micro e Ds (CC); Modelo5: Areia, Silte e Argila (PMP); Modelo 6: Areia, Silte, Argila, Ds, Dp e MO (PMP); Modelo 7: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (PMP); Modelo 8: Micro, Pt, MO e Argila (PMP); Neur.: número de neurônios na camada oculta; Calib.: fase de calibração; EQM: erro quadrático médio; P(%): erro médio relativo; R²: coeficiente de determinação; r: coeficiente de correlação de Pearson; c: índice de concordância; id: índice de desempenho; Trein.: Fase de treinamento; Val. Int.: fase de validação interna; Val. Ext.: fase de validação externa.

Para o Modelo 1 (Areia, Silte e Argila) a rede escolhida possui 19 neurônios na camada oculta e foi encontrada no treinamento 556. A rede necessitou de 75 ciclos para chegar à convergência estipulada no programa de treinamento. Esse ciclo indica o ponto em que a rede obteve o menor EQM e após isto passou a apresentar o fenômeno de *overfitting*. Portanto, após esse ciclo de treinamento a rede passou a generalizar os dados e a reduzir sua capacidade preditiva em relação a dados externos. Essa rede apresentou desempenhos sofrível e mediano nas fases de validação externa e treinamento, respectivamente. O R² foi de 0,561 no treinamento e 0,438 na validação externa. Isso demonstra uma baixa capacidade preditiva do modelo gerado a partir da RNA. Por outro lado, para essas variáveis (Areia, Silte e Argila), já era esperado um desempenho similar na predição da CC, já que não apresentaram uma alta correlação com a variável predita (CC).

No Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO) a rede escolhida apresentou uma menor quantidade de neurônios na camada oculta em relação ao Modelo 1 (6 neurônios). Essa rede foi encontrada no treinamento 581, necessitando de 39 ciclos para chegar à convergência. Essa rede apresentou desempenho muito bom nas fases de validação externa e treinamento. O R² foi de 0,805 no treinamento e 0,750 na validação externa. Isso demonstra uma melhor capacidade preditiva do Modelo 2 comparado ao Modelo 1. Logo, o incremento das variáveis Ds, Dp e MP contribuiu na predição da variável CC, no Modelo 2 gerado pela RNA.

Para o Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade) a rede escolhida possui 6 neurônios na camada oculta, foi encontrada no treinamento 529 e necessitou de 51 ciclos para chegar à convergência. Essa rede foi a que apresentou o menor erro quadrático médio em relação aos Modelos 1, 2 e 4, para todas as fases, exceto na validação externa comparada ao Modelo 4 (Modelo 3: EQM = 0,011; Modelo 4: EQM = 0,010). A rede também apresentou desempenhos ótimos em todas as fases. O R^2 na validação externa foi de 0,832 e 0,951 no treinamento. O coeficiente de correlação de Pearson foi próximo de 1 em todas as fases, demonstrando que além de uma relação de linearidade muito forte, existe uma tendência crescente, para todos os conjuntos analisados.

A rede escolhida para o Modelo 4 (Micro e Ds) apresentou 5 neurônios na camada oculta. Essa rede foi encontrada no treinamento 242, necessitando de 45 ciclos para chegar à convergência. Essa rede obteve ótimos desempenhos para todas as fases. O R^2 foi de 0,852 no treinamento e 0,837 na validação externa. O coeficiente de Pearson para todas as fases foi próximo a 1. Isso demonstra que as variáveis Micro e Ds são fortes preditoras da variável CC. Outro ponto a ser abordado é que a RNA foi capaz de gerar um modelo de FPT com ótimos desempenhos com apenas duas variáveis preditoras para a CC. O modelo gerado pela RNA obteve valores de R^2 , r, c e id superiores ao mesmo modelo gerado pela RLM. O EQM e o P% também apresentaram valores menores no modelo de RNA.

Para o Modelo 5 (Areia, Silte e Argila) a rede escolhida possui 13 neurônios na camada oculta e foi encontrada no treinamento 915. Essa rede necessitou de 8 ciclos para chegar à convergência. Essa rede apresentou desempenhos mediano e sofrível nas fases de validação externa e treinamento, respectivamente. O R^2 foi de 0,489 no treinamento e 0,579 na validação externa. Isso demonstra uma baixa capacidade preditiva do modelo gerado, a partir da RNA, para o PMP.

No Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO) a rede escolhida apresentou uma menor quantidade de neurônios na camada oculta em relação ao Modelo 5 (4 neurônios). Essa rede foi encontrada no treinamento 934 e necessitou de 10 ciclos para chegar à convergência. Isso também foi observado entre os Modelos 1 e 2 na predição da variável PMP. Essa rede apresentou desempenho bom em todas as fases. O R^2 foi de 0,619 no treinamento e 0,689 na validação externa. Isso demonstra uma melhor capacidade preditiva comparado ao Modelo 5. Esse fenômeno também foi observado entre os Modelos 1 e 2 para CC, com o incremento das variáveis Ds, Dp e Macroporosidade ao modelo.

Para o Modelo 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade) a rede escolhida possui 4 neurônios na camada oculta e foi encontrada no treinamento 474. Essa rede necessitou de 71 ciclos para chegar à convergência. Essa rede foi a que apresentou o menor erro quadrático médio em relação aos Modelos 5, 7 e 8, para todas as fases, exceto na validação interna e teste comparada ao Modelo 6 (Modelo 6: Val. Int.: EQM = 0,084; Teste: EQM = 0,108; Modelo 7: Val. Int.: EQM = 0,109; Teste: EQM = 0,113). A rede também apresentou desempenho muito bom nas fases de treinamento de validação externa. O R^2 na validação externa foi de 0,712 e 0,885 no treinamento. O coeficiente de correlação de Pearson foi próximo de 1 em todas as fases.

A rede escolhida para o Modelo 8 (Micro, Pt, MO e Argila) apresentou 6 neurônios na camada oculta. Essa rede foi encontrada no treinamento 427, necessitando de 102 ciclos para atingir à convergência. Essa rede obteve desempenhos bom e sofrível para as fases de treinamento e validação externa. O R^2 foi de 0,619 no treinamento e 0,475 na validação externa. Isso demonstra que as variáveis Micro, Pt, MO e Argila, propostos no modelo de RLM para PMP, não foram bons preditores da variável PMP. Em contrapartida, o Modelo 8 gerado pela RNA obteve R^2 , r , id e c superiores ao mesmo modelo gerado pela RLM. O EQM e o P% também foram menores comparados ao modelo de RLM.

As redes selecionadas para cada modelo testaram 1.000 ciclos (Épocas) para chegar à convergência estipulada no programa de treinamento. Com isso, interromperam o treinamento no ciclo em que foi apresentado o menor EQM entre as fases de Treinamento, Validação e Teste. O treinamento das redes neurais ajustou os valores dos neurônios da camada oculta e os valores dos *bias* de cada um, assim como do neurônio de saída.

As Figuras 29, 30, 31 e 32 representam as fases de treinamento, validação e teste, para cada rede neural selecionada nos modelos 1, 2, 3 e 4, com a estimativa da capacidade de campo (CC). Nota-se nas figuras o ponto exato de convergência (circulado) para cada modelo, observando-se o menor EQM nas três fases. Após esse ponto, percebe-se que o EQM para a fase de treinamento reduz até atingir uma faixa constante. Em contrapartida, os EQMs das fases de validação e teste seguem sentido oposto, demonstrando um aumento desse erro em relação a fase de treinamento, até atingirem a faixa constante. Isso se deve pelo fato da rede se especializar nos valores observados na fase de treinamento. Por outro lado, a rede reduz, a partir desse ponto, sua capacidade assertiva a valores externos. Por esse motivo são usados pontos aleatórios nas fases de validação e teste (pontos que a rede nunca observou ou que não foram

usados no treinamento) para testar a rede verificando a sua capacidade de generalização, bem como observar o ponto em que a rede obteve o menor EQM para as três fases.

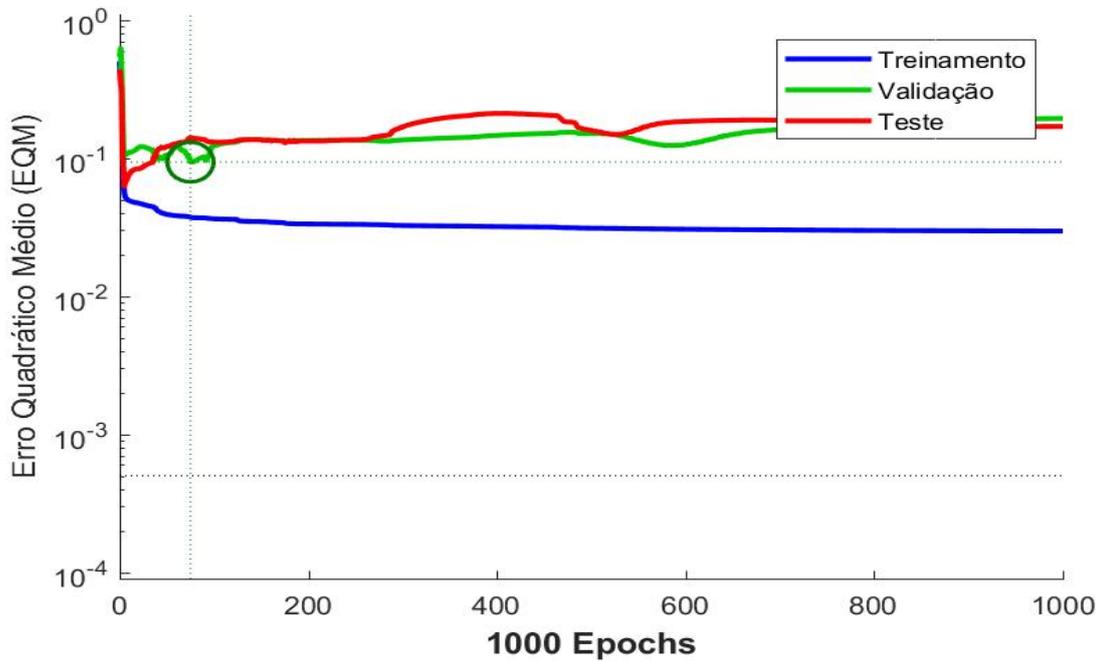


FIGURA 29 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).

Fonte: Próprio autor.

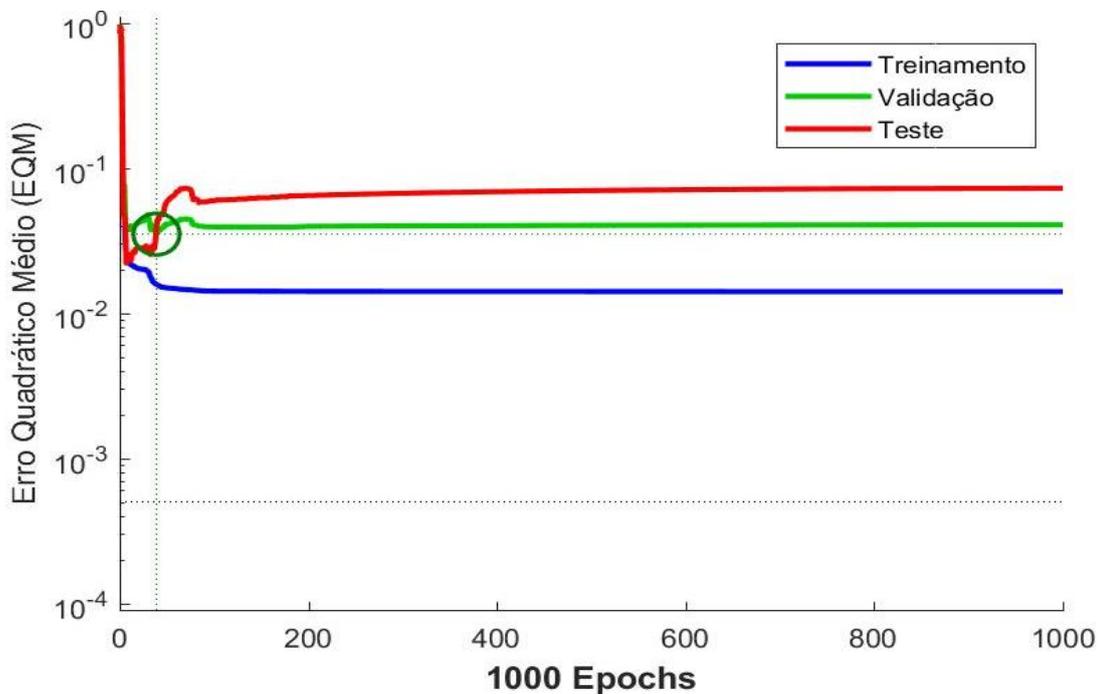


FIGURA 30 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

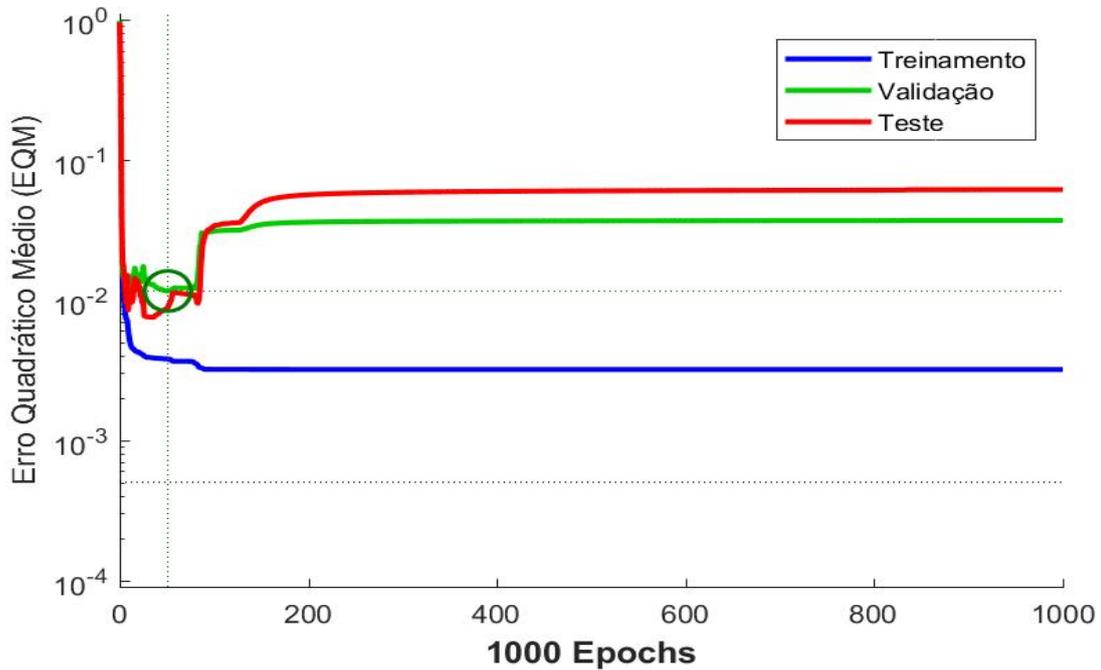


FIGURA 31 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).

Fonte: Próprio autor.

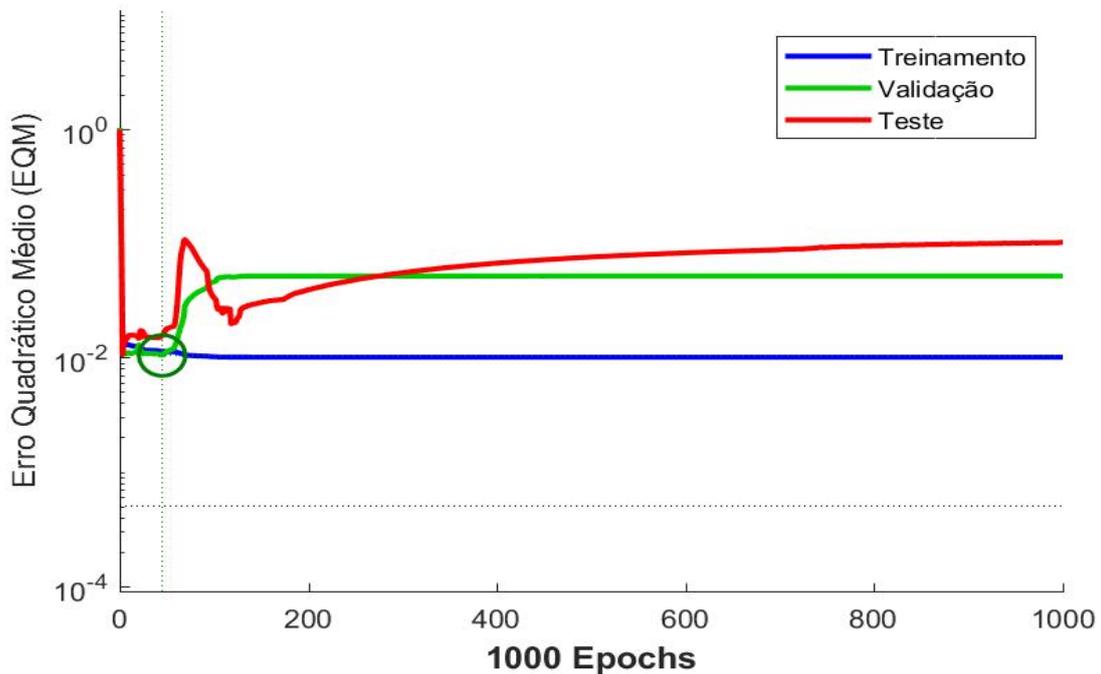


FIGURA 32 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds).

Fonte: Próprio autor.

As Figuras 33, 34, 35 e 36 representam as fases de treinamento, validação e teste, para cada rede neural selecionada nos modelos 5, 6, 7 e 8, com a estimativa do ponto de murcha

permanente (PMP). Nota-se também na figura, o ponto de convergência (circulado) para cada modelo, observando-se o menor EQM nas três fases.

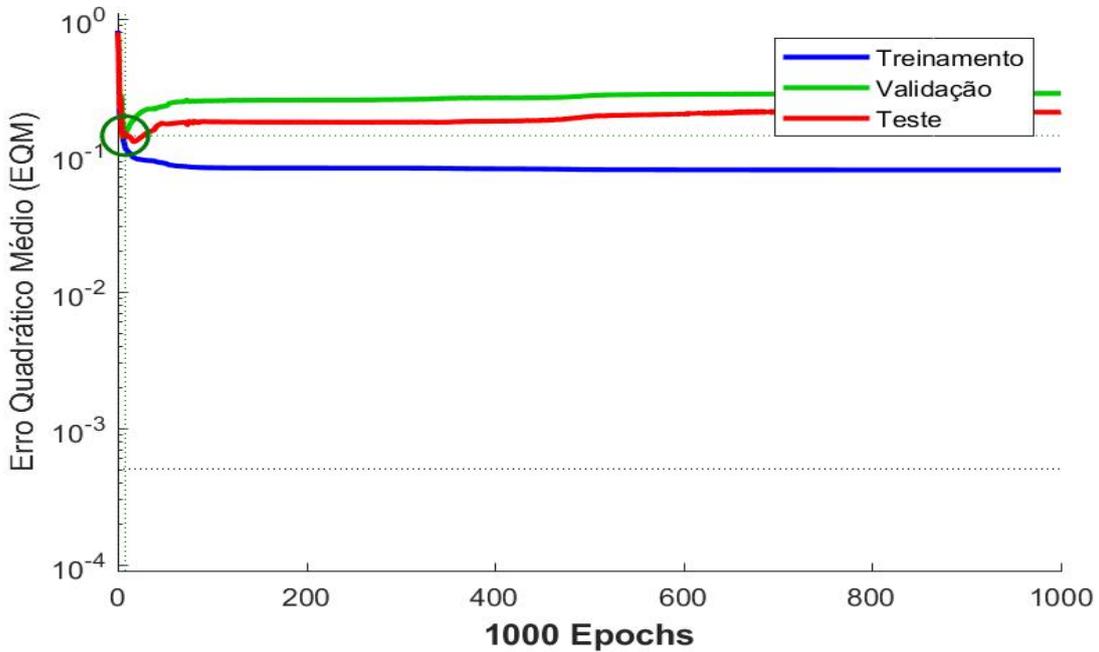


FIGURA 33 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).

Fonte: Próprio autor.

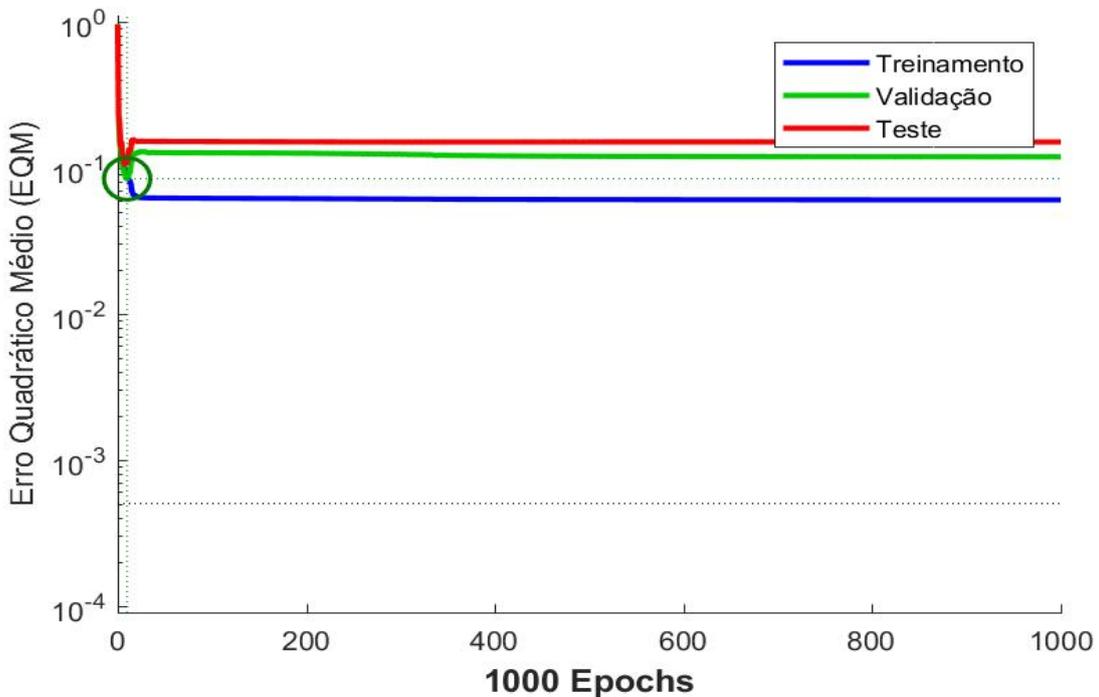


FIGURA 34 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

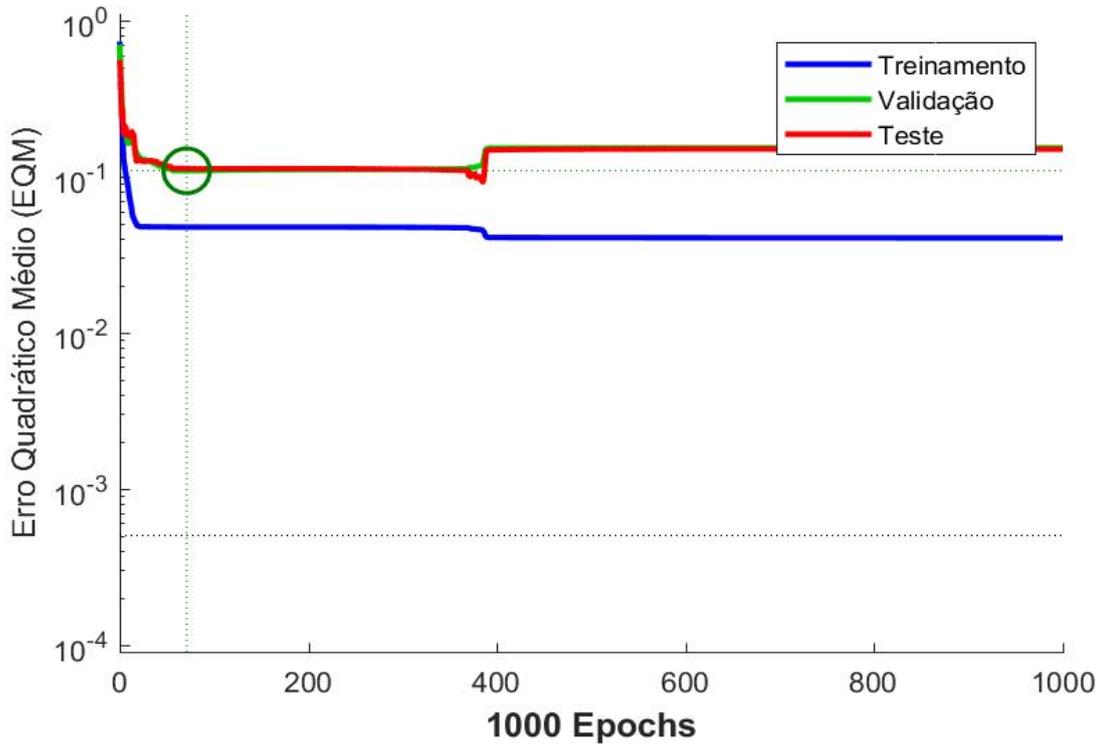


FIGURA 35 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, Pt, Macro, Micro, MO e Profundidade).

Fonte: Próprio autor.

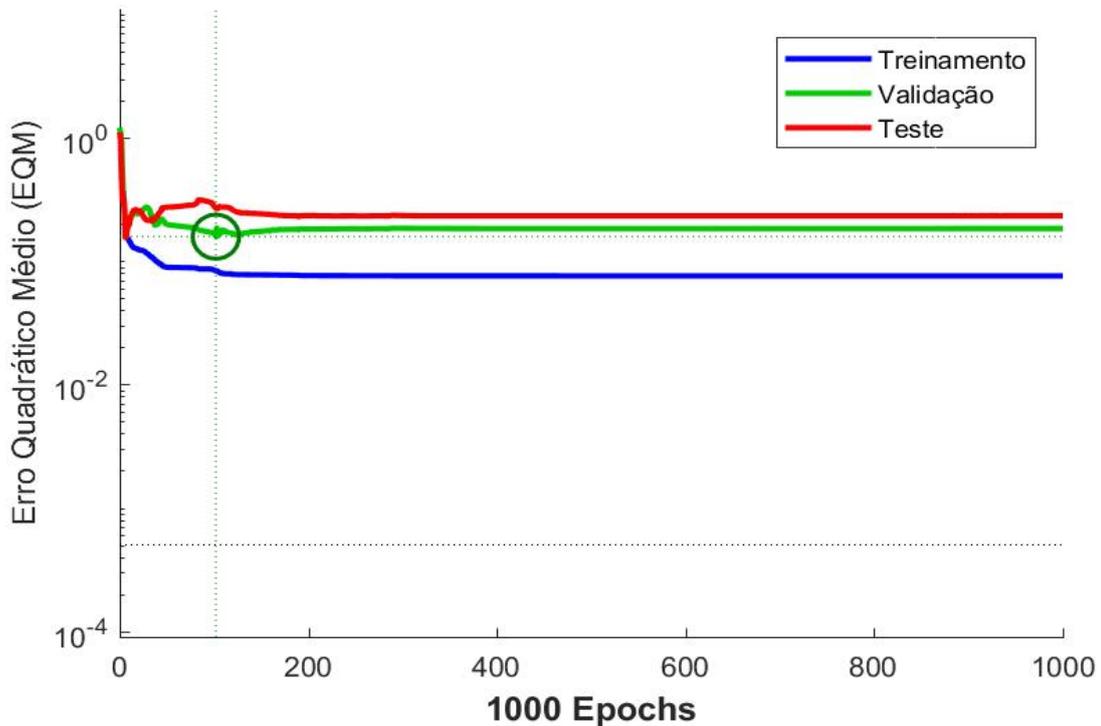


FIGURA 36 – Representação das fases de treinamento, validação e teste da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).

Fonte: Próprio autor.

4.4.3 Apresentação e comparação dos resultados das RNAs escolhidas

O programa utilizado gera gráficos de dispersão para as fases de treinamento, validação, teste e uma fase geral (onde são observados todos os valores das três fases). Os dados observados das variáveis de saída CC e PMP, estão no eixo X e os dados estimados pelas RNAs, também das variáveis CC e PMP, estão no eixo Y. O coeficiente de correlação (r) foi usado para testar a relação entre as variáveis observadas e estimadas pelas redes. Quanto mais próximo de -1 ou 1 esse coeficiente, maior será a relação entre os dois valores e melhor a capacidade preditiva da rede.

As Figuras 37, 38, 39 e 40 apresentam os resultados de comparação entre os valores observados e estimados nas fases de treinamento, validação, teste e geral para as redes selecionadas em cada modelo proposto para estimar a capacidade de campo (CC). Nota-se valores de coeficiente de correlação (r) mais próximos de 1 nos Modelos 3 e 4, expressos na Figura 39 e 40. Isso evidencia a capacidade que as redes têm de estimar os dados com acurácia.

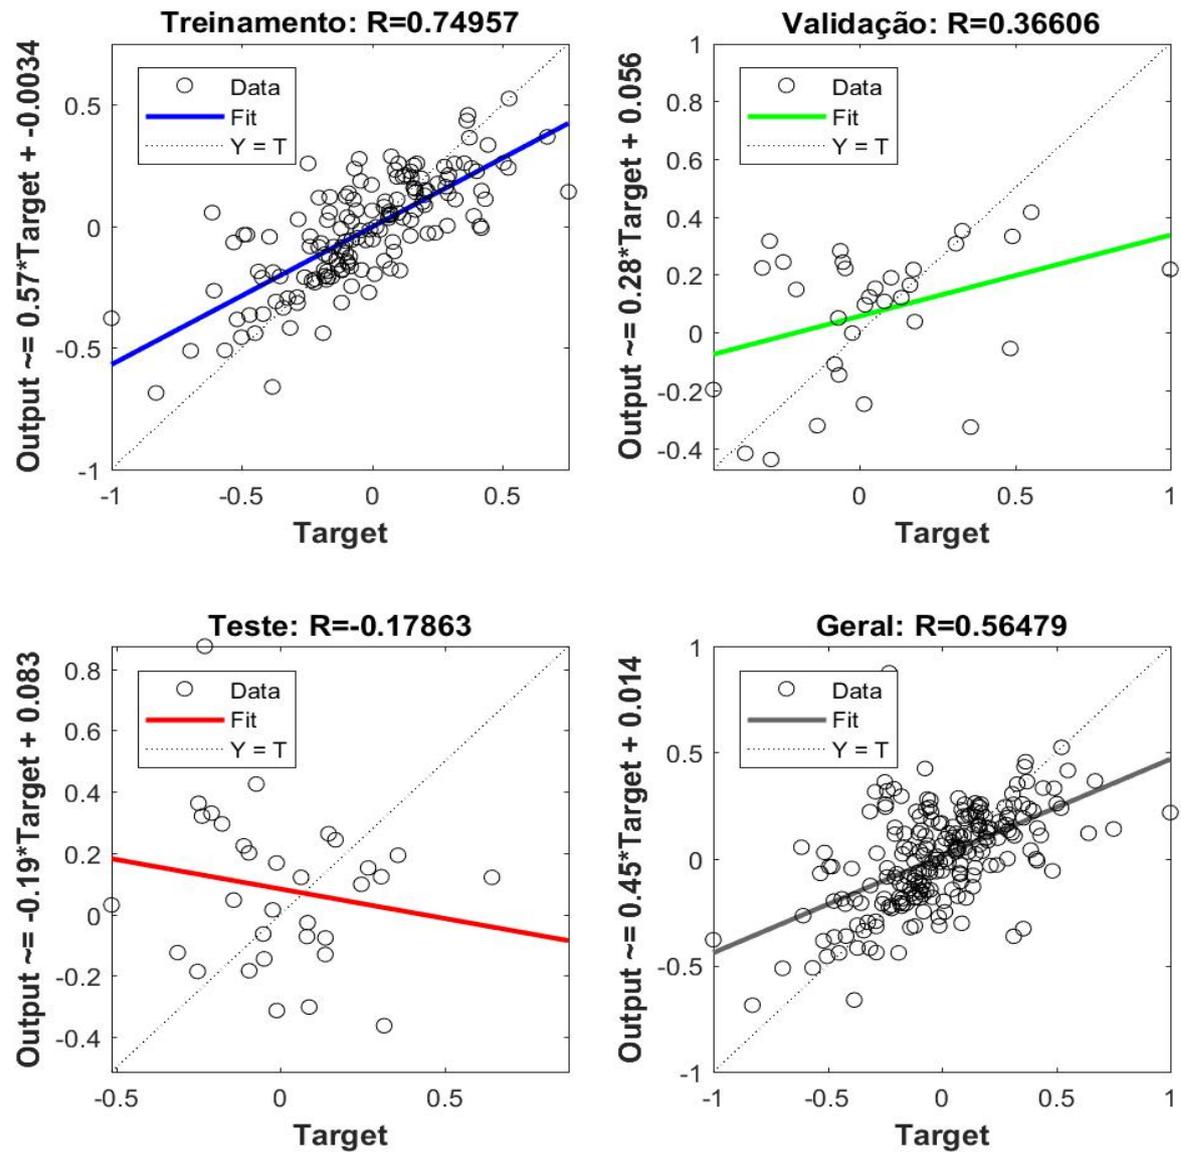


FIGURA 37 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).

Fonte: Próprio autor.

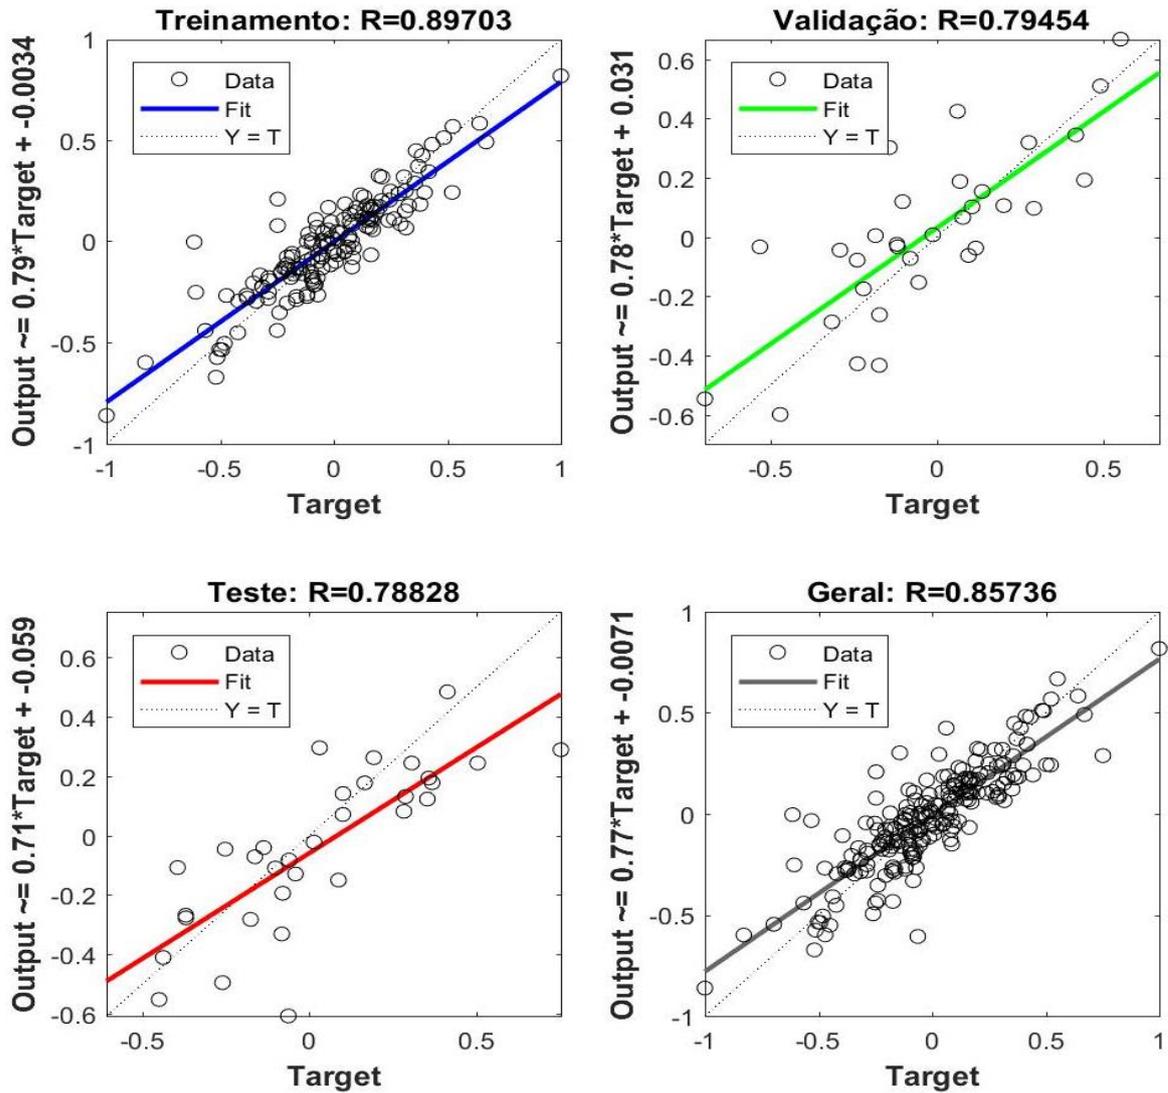


FIGURA 38 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

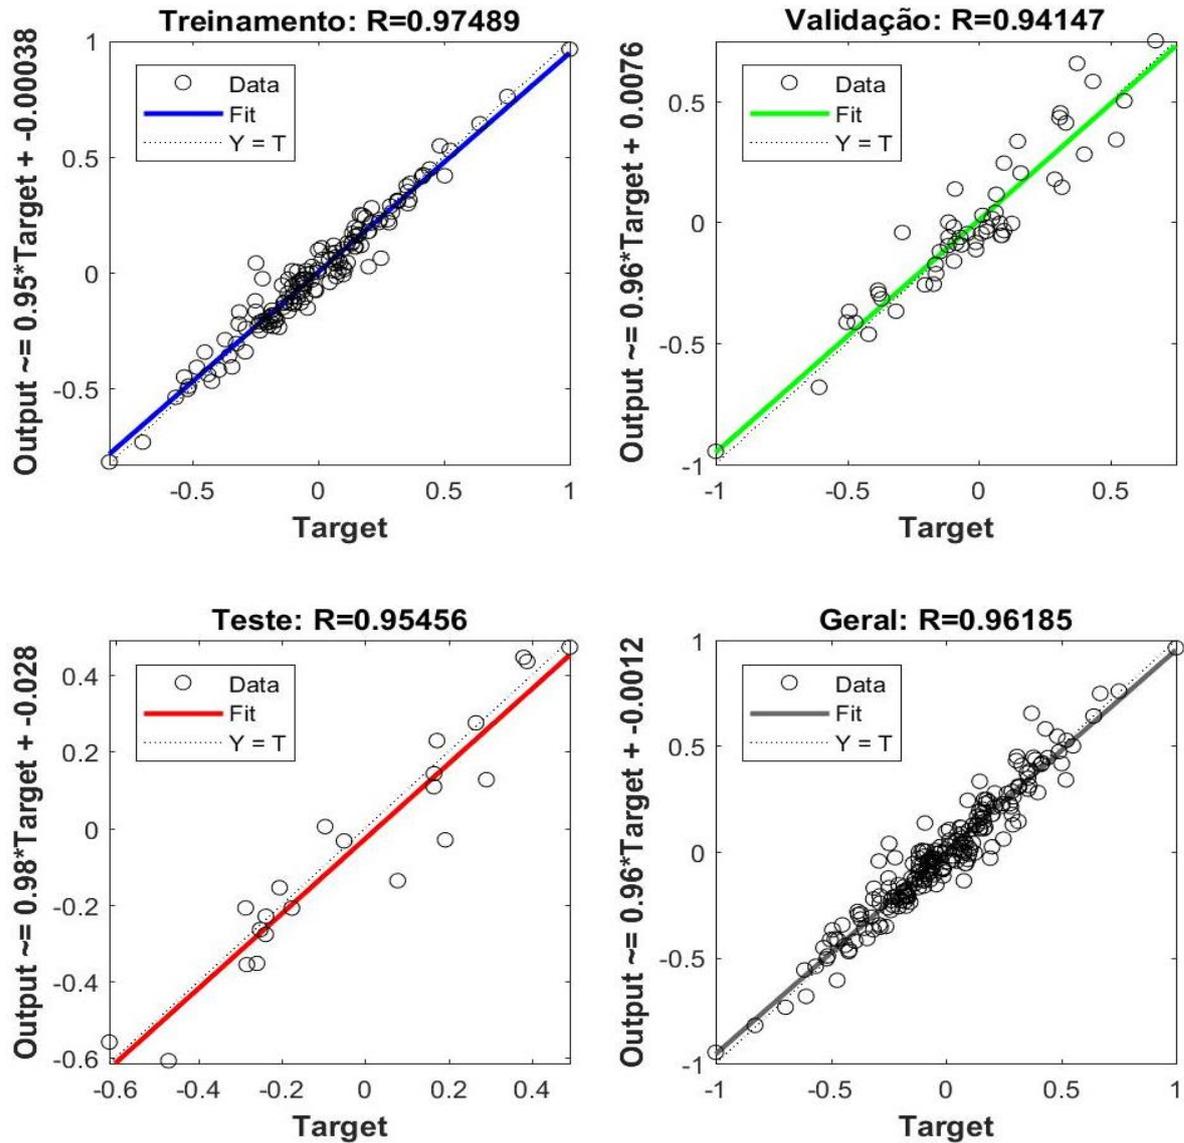


FIGURA 39 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).

Fonte: Próprio autor.

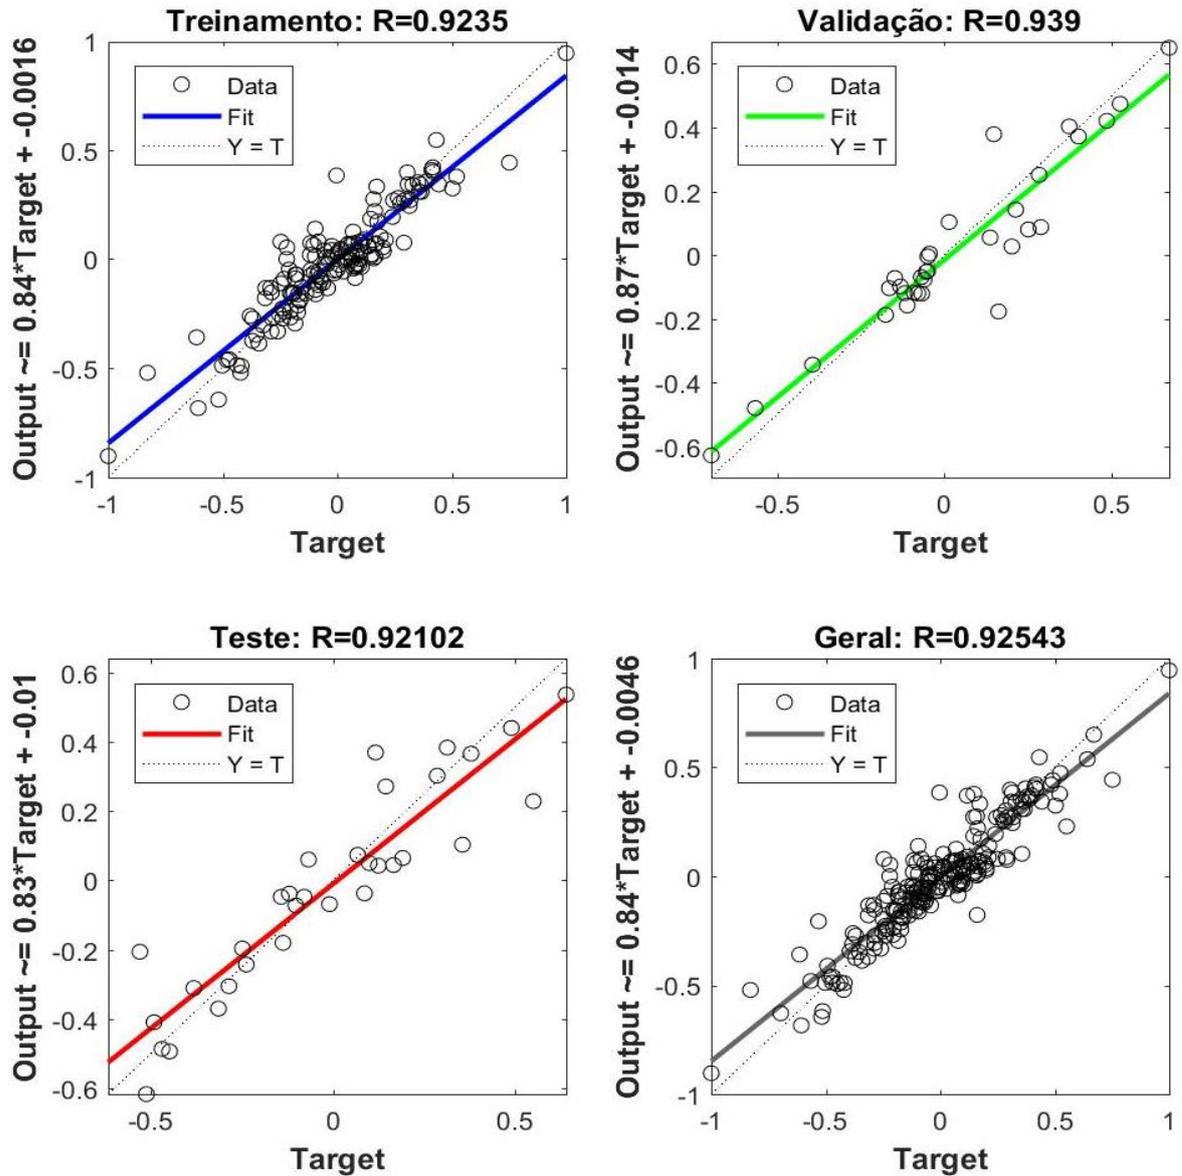


FIGURA 40 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds).

Fonte: Próprio autor.

As Figuras 41, 42, 43 e 44 representam os resultados de comparação entre os valores observados e estimados nas fases de treinamento, validação, teste e geral para as redes selecionadas em cada modelo proposto para estimar o ponto de murcha permanente (PMP). Nota-se que os maiores valores do coeficiente de correlação (r) foram obtidos nos Modelos 6 e 7, observados nas Figura 42 e 43. Os valores de r para PMP foram menores que os observados na CC. Em contrapartida, esses dois modelos propostos nas RNAs obtiveram coeficientes de correlação maiores que o modelo de RLM (Micro, Pt, MO e Argila) para estimativa do PMP.

Esse fato demonstra maior acurácia das RNAs na predição do PMP comparados ao modelo de RLM.

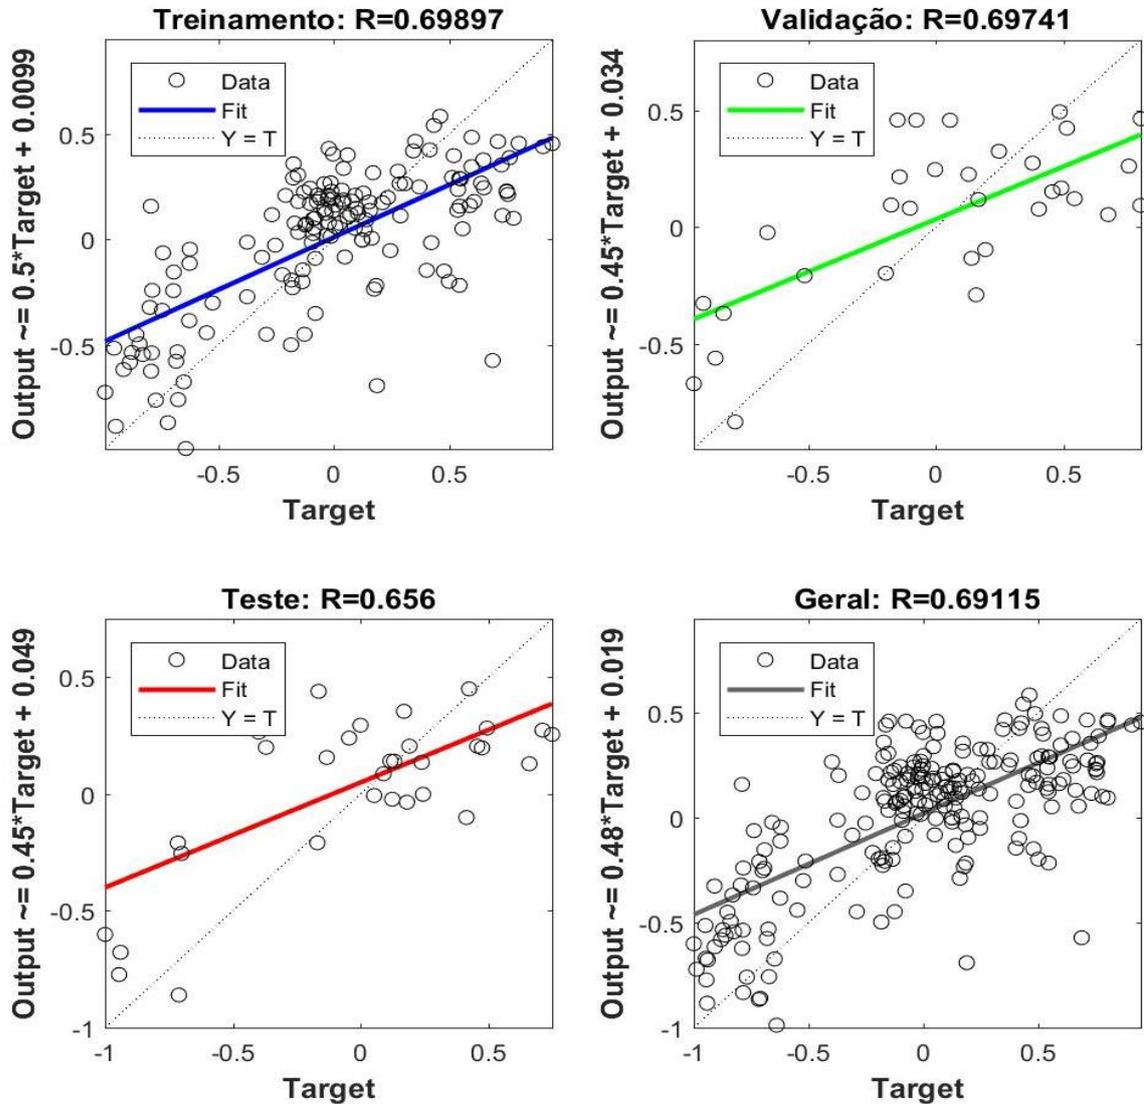


FIGURA 41 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).

Fonte: Próprio autor.

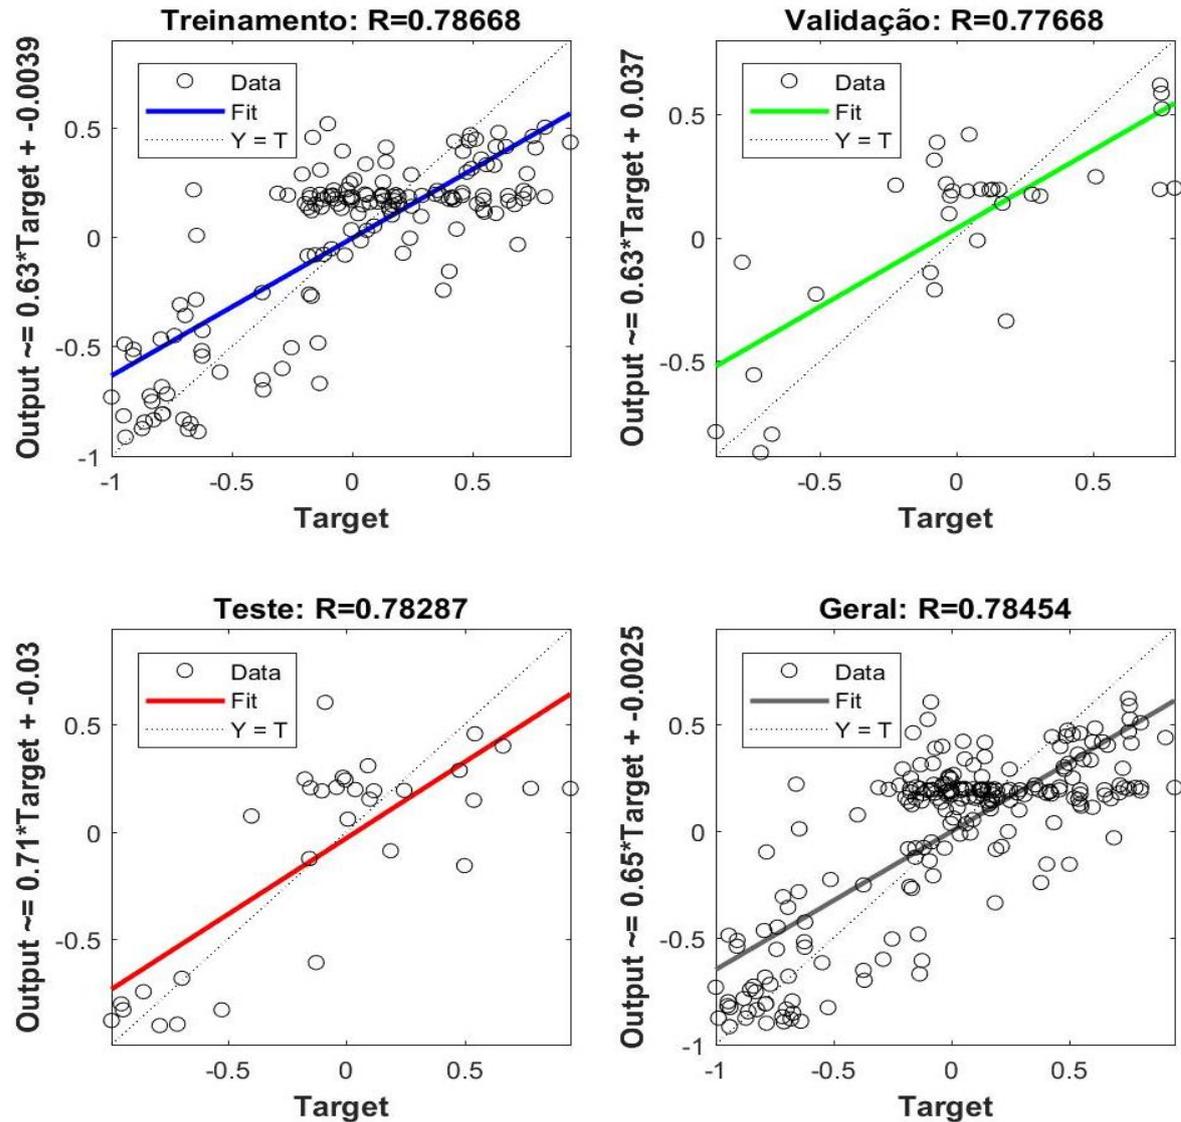


FIGURA 42 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

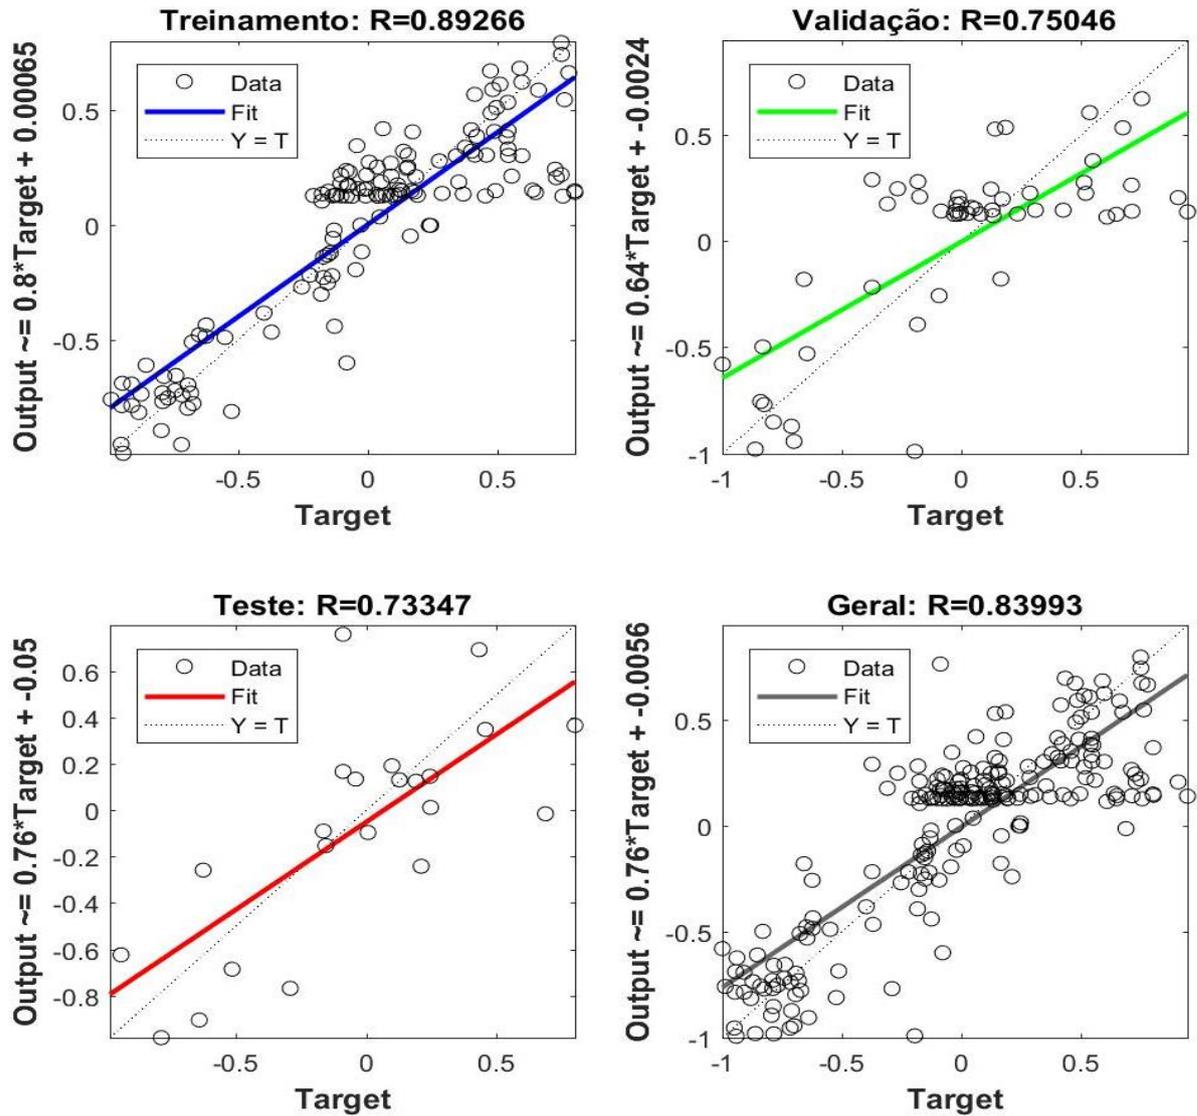


FIGURA 43 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).

Fonte: Próprio autor.

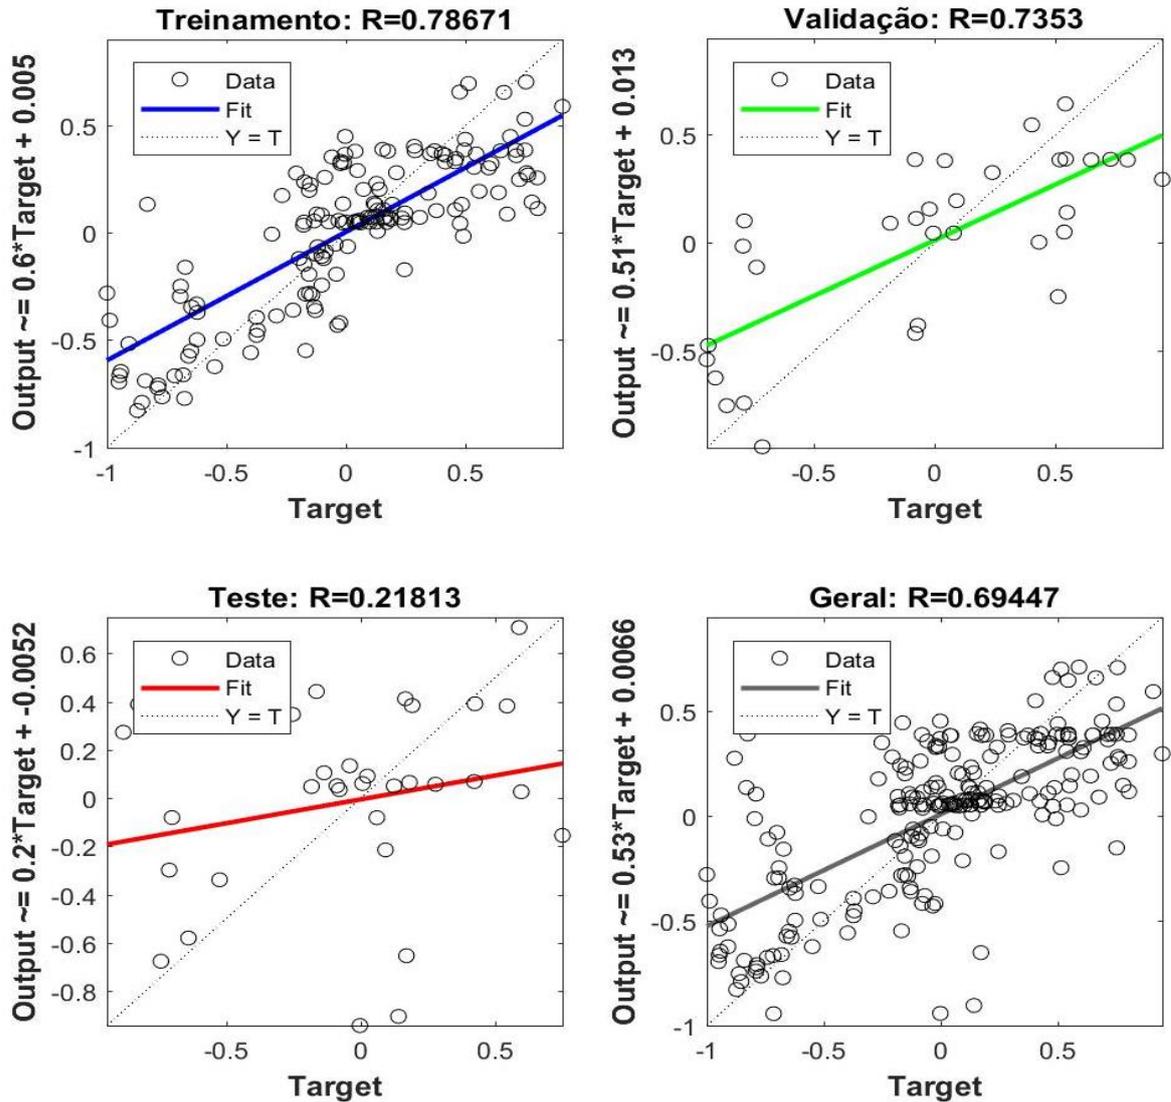


FIGURA 44 – Representação gráfica do coeficiente de correlação (r) nas fases de treinamento, validação, teste e geral, para a RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).

Fonte: Próprio autor.

Nas Figuras 45, 46, 47 e 48, nota-se duas linhas que representam os dados observados (em vermelho) e os dados estimados (em preto) da capacidade de campo (CC), para as RNAs selecionadas em cada modelo (1, 2, 3 e 4). Quanto mais próxima a linha dos dados estimados estiverem da linha dos dados observados maior será a capacidade assertiva da rede. Percebe-se que as tendências que obtiveram os melhores ajustes foram observadas nos Modelos 3 e 4 (Figuras 47 e 48, respectivamente). Essas redes obtiveram um baixo erro aleatório, uma vez que os valores estimados praticamente acompanharam os valores observados para os 240 pontos amostrados.

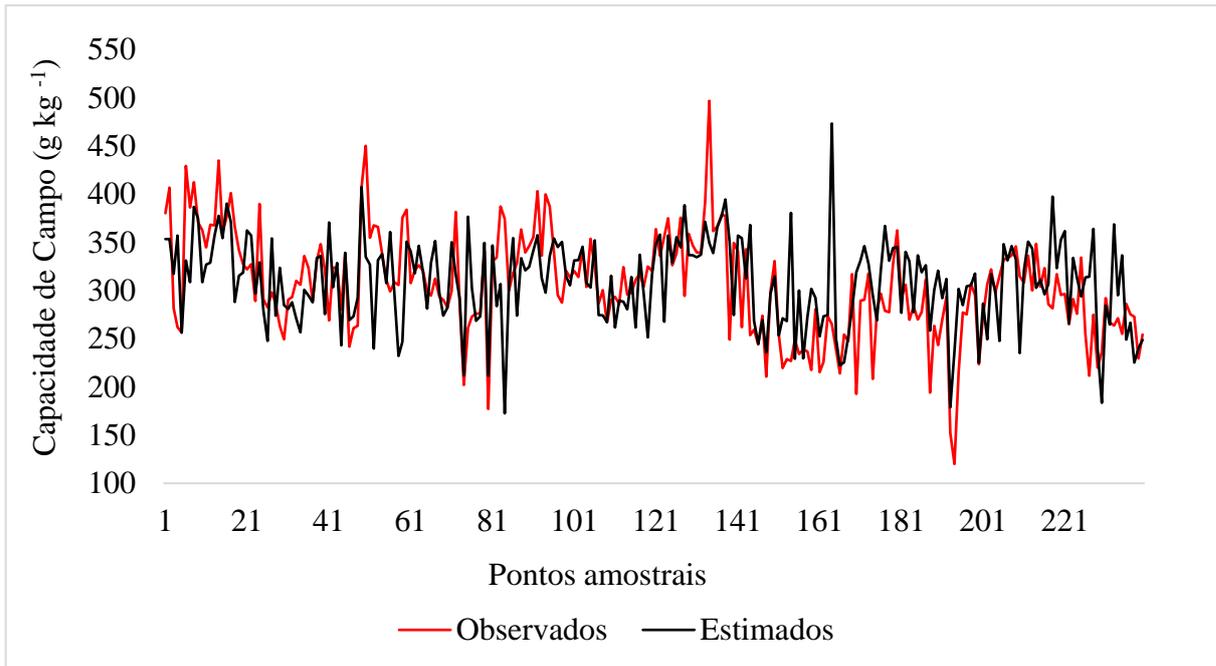


FIGURA 45 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 1 (Areia, Silte e Argila).

Fonte: Próprio autor.

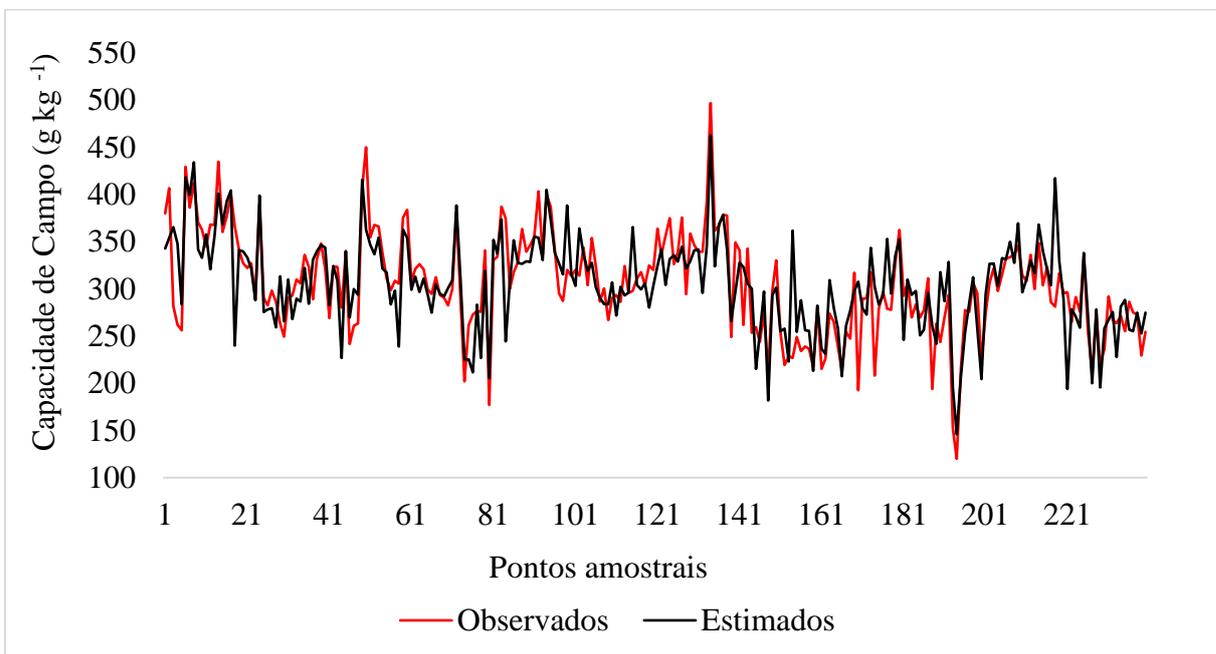


FIGURA 46 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 2 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

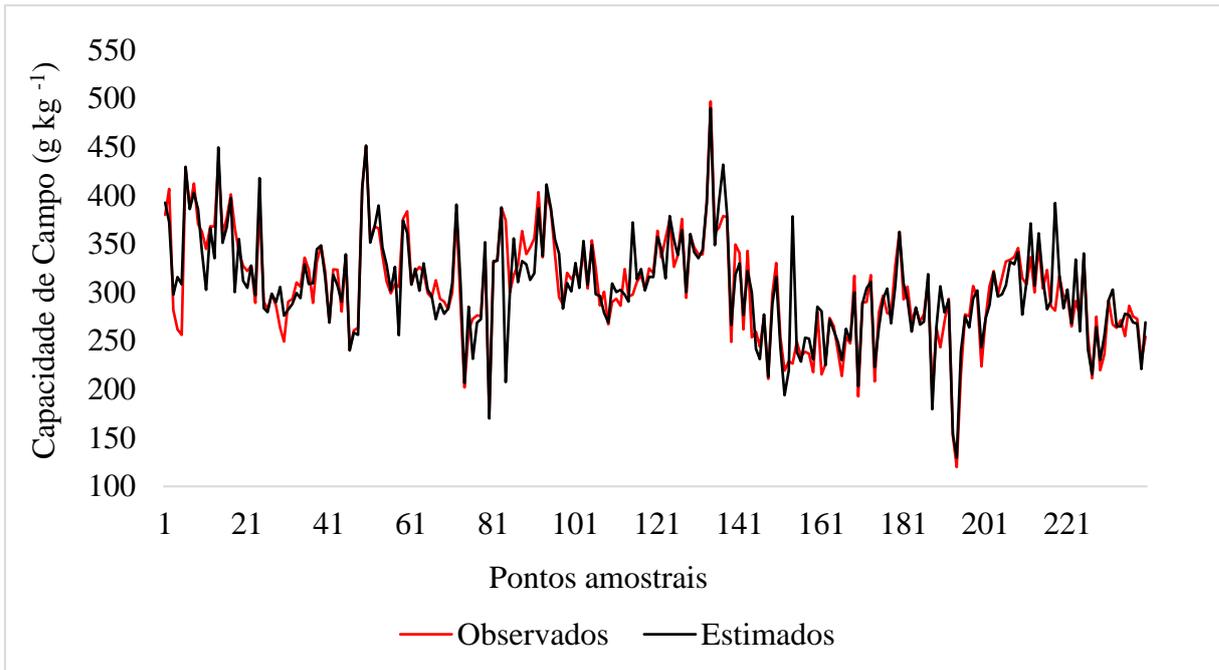


FIGURA 47 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 3 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).

Fonte: Próprio autor.

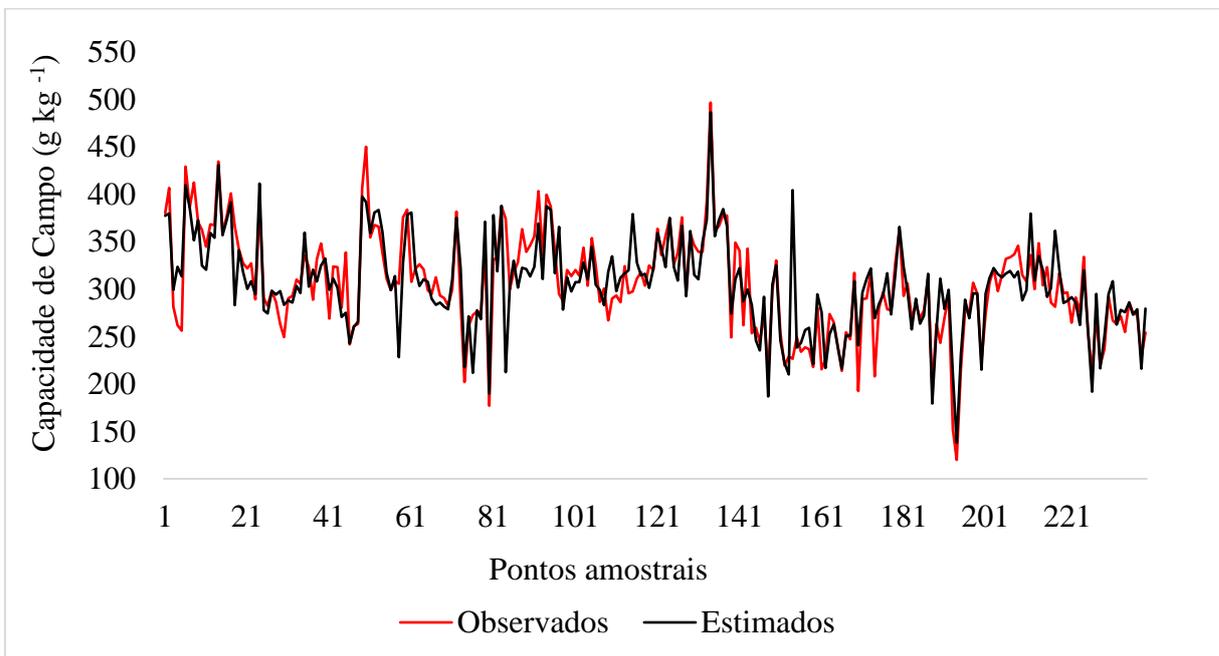


FIGURA 48 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável capacidade de campo (CC) a partir do Modelo 4 (Micro e Ds).

Fonte: Próprio autor.

As Figuras 49, 50, 51 e 52 representam os dados observados (em vermelho) e os dados estimados (em preto) do ponto de murcha permanente (PMP), para as RNAs selecionadas em cada modelo (5, 6, 7 e 8). Nota-se que as tendências que obtiveram os melhores ajustes foram

observadas nos Modelos 6 e 7 (Figura 50 e 51, respectivamente). As redes dos Modelos 5 e 8 (Figura 49 e 52, respectivamente) apresentaram os maiores erros relativos comparadas aos Modelos 6 e 7.

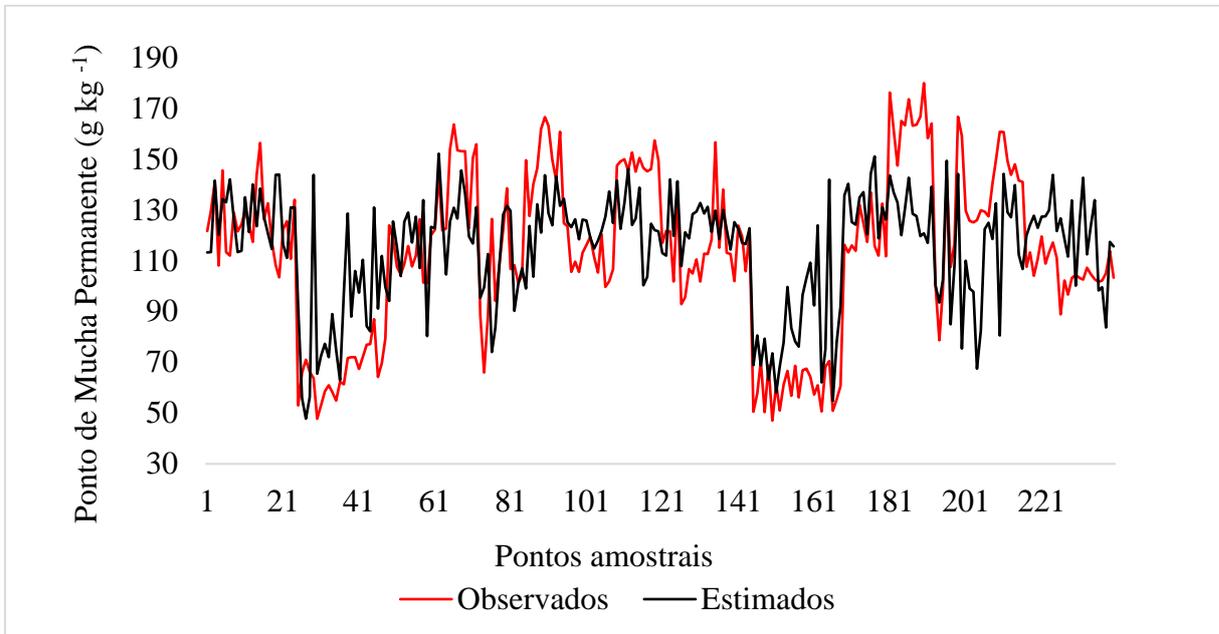


FIGURA 49 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 5 (Areia, Silte e Argila).

Fonte: Próprio autor.

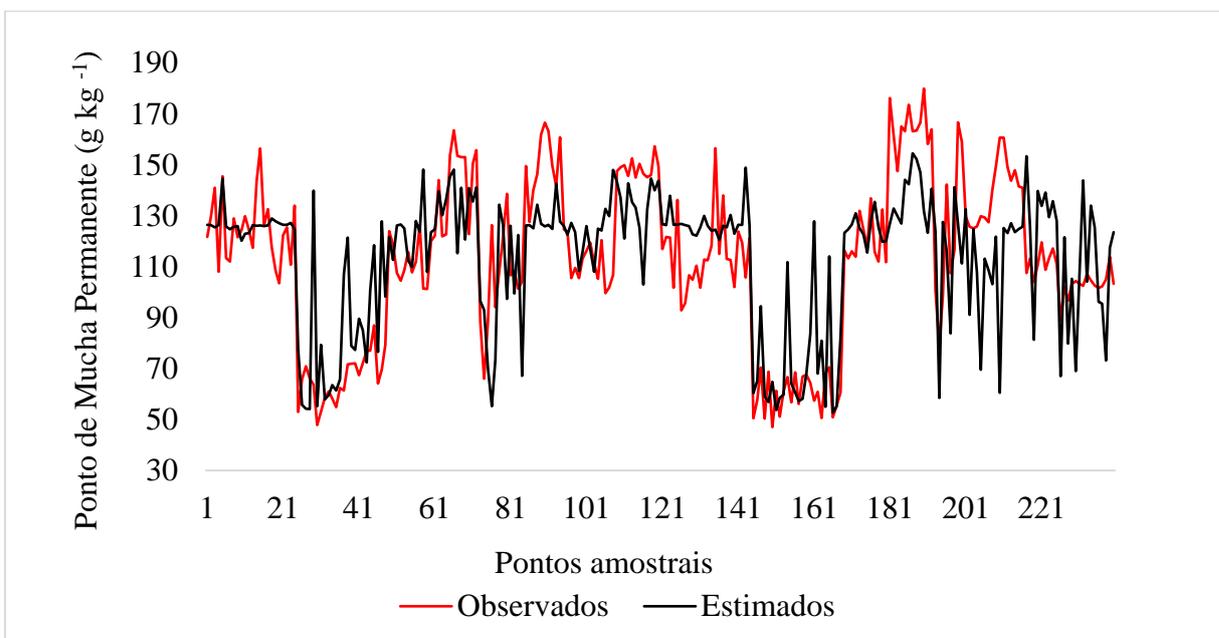


FIGURA 50 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 6 (Areia, Silte, Argila, Ds, Dp e MO).

Fonte: Próprio autor.

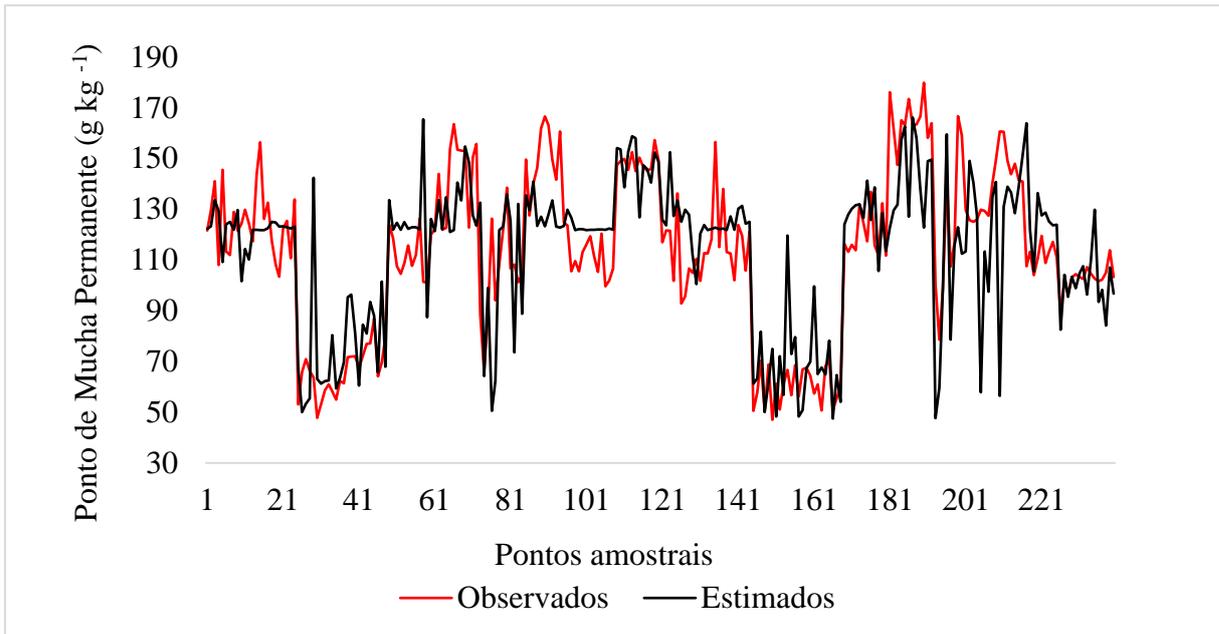


FIGURA 51 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 7 (Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade).

Fonte: Próprio autor.

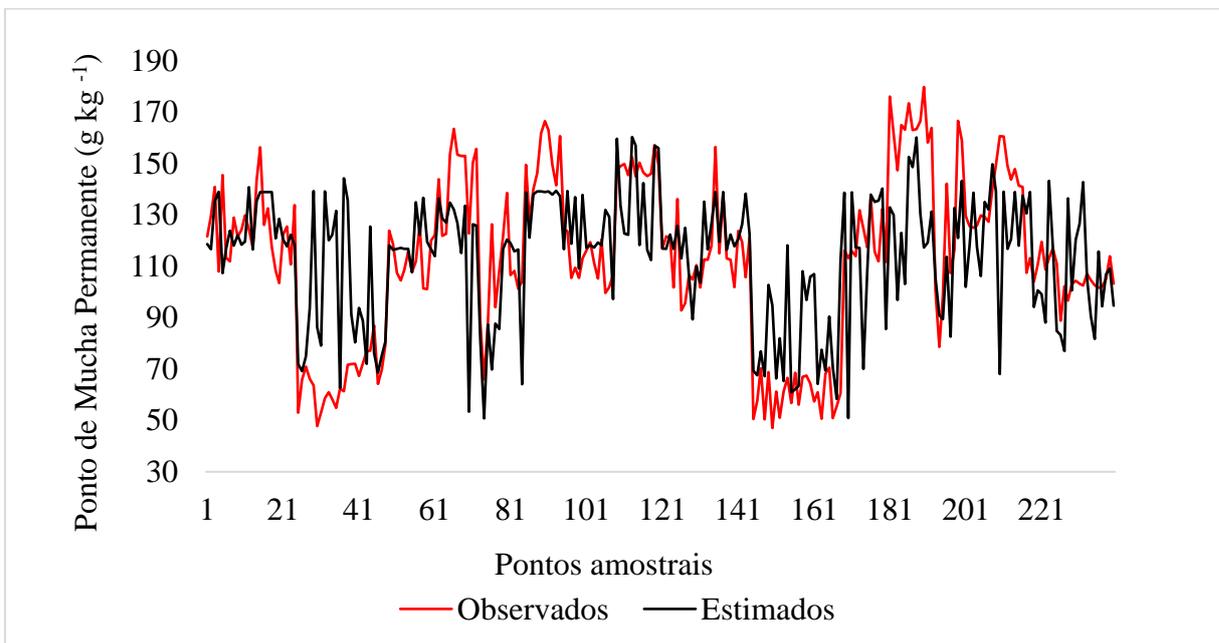


FIGURA 52 – Representação gráfica dos valores Observados x Estimados da RNA escolhida para a estimativa da variável ponto de murcha permanente (PMP) a partir do Modelo 8 (Micro, Pt, MO e Argila).

Fonte: Próprio autor.

O Teste-t foi feito para verificar se houve diferença significativa entre as variáveis observadas e as variáveis estimadas pelos Modelos de RNAs tanto para CC quanto para PMP. Constatou-se a 95% de significância (n=240), para as duas variáveis (CC e PMP), que não

houve diferença significativa entre os valores observados e estimados nos Modelos 1, 2, 3, 4, 5, 6, 7 e 8, conforme Tabelas 23 e 24. Isso demonstra a confiabilidade dos modelos em relação à estimativa das variáveis.

TABELA 23 – Teste-t dos dados observados e estimados pelas RNAs, para a variável capacidade de campo (CC), a partir dos Modelos 1, 2, 3 e 4.

	Observados		Estimados		
	CC	Modelo 1	Modelo 2	Modelo 3	Modelo 4
Média	305,264	309,097	305,004	305,937	305,235
Variância	2.830,862	2.012,228	2.401,450	2.800,709	2.418,565
Observações	240	240	240	240	240
gl	478				
p-Value		0,394	0,955	0,889	0,995

CC: capacidade de campo (g kg^{-1}) observada pelo método da mesa de tensão; Modelo 1, 2, 3 e 4: capacidade de campo (g kg^{-1}) estimada pela RNA; Gl: graus de liberdade; p-Value: teste de t-student significativo a 5% de probabilidade.

Fonte: Próprio autor.

TABELA 24 – Teste-t dos dados observados e estimados pelas RNAs, para ponto de murcha permanente (PMP), a partir dos Modelos 5, 6, 7 e 8.

	Observados		Estimados		
	PMP	Modelo 5	Modelo 6	Modelo 7	Modelo 8
Média	113,004	114,657	113,298	112,801	113,698
Variância	1.023,015	500,451	707,028	841,233	602,570
Observações	240	240	240	240	240
gl	478				
p-Value		0,512	0,913	0,965	0,790

PMP: ponto de murcha permanente (g kg^{-1}) observada pelo método da mesa de tensão; Modelo 5, 6, 7 e 8: ponto de murcha permanente (g kg^{-1}) estimada pela RNA; Gl: graus de liberdade; p-Value: teste de t-student significativo a 5% de probabilidade.

Fonte: Próprio autor.

4.5 Comparação das FPTs geradas pela RLM e pela RNA

A Tabela 25 apresenta a comparação entre os modelos gerados pela RLM e pela RNA para as variáveis capacidade de campo e ponto de murcha permanente, com os valores estimados na fase de validação. Os critérios avaliativos de comparação foram: Erro quadrático médio (EQM), P(%), Coeficiente de determinação (R^2), Coeficiente de Pearson (r), Índice de concordância (c) (WILLMONT, 1981) e Índice de desempenho (id) (CAMARGO e SENTELHAS, 1997).

TABELA 25 – Comparação entre as metodologias para geração das FPTs (RLM x RNA) observando-se a fase de validação.

Metodologia	Modelo	EQM	P(%)	R ²	r	c	id	Desempenho
RNA	1	0,047	178,615	0,438	0,662	0,802	0,531	Sofrível
RNA	2	0,018	125,195	0,750	0,866	0,919	0,796	Muito bom
RNA	3	0,011	79,957	0,832	0,912	0,946	0,862	Ótimo
RNA	4	0,010	75,853	0,837	0,915	0,952	0,871	Ótimo
RNA	5	0,094	152,229	0,579	0,761	0,844	0,642	Mediano
RNA	6	0,070	330,031	0,689	0,830	0,906	0,752	Bom
RNA	7	0,065	313,532	0,712	0,844	0,919	0,775	Muito bom
RNA	8	0,115	507,691	0,475	0,689	0,815	0,562	Sofrível
RLM	2	0,053	51,888	0,787	0,887	0,941	0,835	Muito bom
RLM	4	0,226	236,499	0,164	0,441	0,599	0,264	Péssimo

RNA: Rede Neural Artificial: Modelo1: Areia, Silte e Argila (CC); Modelo 2: Areia, Silte, Argila, Ds, Dp e MO (CC); Modelo 3: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (CC); Modelo 4: Micro e Ds (CC); Modelo5: Areia, Silte e Argila (PMP); Modelo 6: Areia, Silte, Argila, Ds, Dp e MO (PMP); Modelo 7: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (PMP); Modelo 8: Micro, Pt, MO e Argila (PMP); RLM: Regressão Linear Múltipla: Modelo 2: Micro e Ds (CC); Modelo 4: Micro, Pt, MO e Argila (PMP); Fonte: Próprio autor.

Os modelos gerados pela RNA para estimativa da CC obtiveram desempenhos que variavam de sofrível a ótimo. Os Modelos 3 e 4 apresentaram ótimos desempenhos nas fases de validação. Esses modelos apresentaram um R² de 0,832 e 0,837, respectivamente. Em contrapartida, o Modelo 1 apresentou um R² de 0,438. Esse coeficiente indica a capacidade do modelo em explicar a variável CC. O coeficiente de correlação de Pearson demonstrou uma forte correlação positiva (>0,80) dos Modelos 3 e 4 entre as variáveis observadas e estimadas nos modelos. O Test-t não apresentou diferença estatística significativa entre os valores observados e estimados para todos os modelos a 5% de probabilidade. Os Modelos 3 e 4 apresentaram os menores EQM e P%, o que indica uma maior precisão na estimativa da CC. Logo, os Modelos 3 e 4 gerados pela RNA são fortes indicadores para estimar a variável CC.

O Modelo 2 (Micro e Ds), gerado pela RLM para estimativa da CC, apresentou um desempenho muito bom (id=0,835) na fase de validação. O R² do modelo foi de 0,787 e o coeficiente de correlação de Pearson foi de 0,887. Isso indica um bom ajuste do modelo em explicar a variável CC. Esses valores foram superiores aos observados nos Modelos 1 e 2 gerados pela RNA e inferiores aos modelos 3 e 4 também gerados pela RNA. Apesar disso, os valores observados e estimados não diferiram a 5% de probabilidade pelo Teste-t. O P% para o Modelo 2 da RLM (P%=51,888%) foi o menor observado entre os modelos de estimativa da CC. Isso demonstra uma maior precisão em estimar essa variável. Logo, o Modelo 2, gerado pela RLM, é um forte indicador para estimar a variável CC.

Os modelos gerados pela RNA para estimativa do PMP obtiveram desempenhos que variavam de sofrível a muito bom. Os Modelos 6 e 7 apresentaram desempenhos Bom e Muito bom, respectivamente, na fase de validação. O Modelo 7 apresentou o maior R^2 (0,712) dentre os demais, indicando a capacidade do modelo em explicar a variável PMP. O coeficiente de correlação de Pearson apresentou uma forte correlação positiva ($>0,80$) nos Modelos 6 e 7 entre as variáveis observadas e estimadas no modelo. O Test-t não apresentou diferença significativa entre os valores observados e estimados para todos os modelos a 5% de probabilidade. Os Modelos 6 e 7 apresentaram os menores EQMs, indicando uma maior precisão na estimativa do PMP por esses modelos. Logo, os Modelos 6 e 7, gerados pela RNA, são fortes indicadores para estimar a variável PMP.

O Modelo 4 (Micro, Pt, MO e Argila), gerado pela RLM para estimativa da PMP, apresentou um desempenho péssimo ($id=0,835$) na fase de validação. O R^2 do modelo foi de 0,164 e o coeficiente de correlação de Pearson foi de 0,441. Esses coeficientes indicam uma baixa capacidade preditiva do modelo em explicar a variável PMP. Esse modelo apresentou os piores resultados comparados aos modelos gerados pela RNA para estimativa do PMP. Apesar disso, os valores observados e estimados não diferiram a 5% de probabilidade pelo Teste-t. Com esses resultados o Modelo 4 gerado pela RLM não é um modelo indicado para estimar a variável PMP.

Os valores observados nas RNAs foram semelhantes aos apresentados por Pachepsky et al. (1996). Lakzian et al. (2010) observaram que a capacidade preditiva das RNAs foi superior a RLM, quando comparados a RLM para as predições de CC e PMP. Netto (2007) observou alto desempenho das RNAs na estimativa de retenção de água no solo, conseguindo explicar 93% da variação da retenção de água no solo.

Bayat e Zadeh (2018), desenvolveram FPTs, a partir de RNAs, com propriedades físico-químicas do solo, para estimar a curva de retenção de água no solo nas províncias do Azarbaijão Ocidental, Hamedan, Dars e Curdistão do Irã. Os resultados obtidos corroboraram com o presente trabalho, comprovando a eficácia das RNAs na solução de problemas de predição das umidades do solo.

Pequeno et al. (2018) testaram FPTs para a estimativa da retenção de água em um Latossolo no Estado de Rondônia. Os modelos propostos para a estimativa do potencial matricial de -0,01 MPa continham as variáveis preditoras: Argila, Areia Média e Microporosidade; Areia, Argila e Densidade do Solo, corroborando com as variáveis testadas nos modelos gerados pelas RNAs e RLMs.

Os modelos propostos por Minasny et al. (1999) para estimativa da CC e do PMP tendo como preditores granulometria e densidade do solo, corroboraram com os modelos observados no presente trabalho, comprovando a correlação desses atributos às umidades do solo.

Tormena e Silva (2002) verificaram a incorporação da densidade do solo no ajuste de modelos à curva de retenção de água no solo, comprovando a importância desse atributo à predição das umidades do solo. Isso também foi observado nos Modelos 2, 3, 4, 6 e 7 gerados pela RNA e o Modelo 2 gerado pela RLM.

Na Tabela 26 estão os valores dos coeficientes de determinação (R^2), coeficiente de Pearson (r) das fases gerais e o critério de informação de Akaike (AIC) (AKAIKE, 1974) para indicação dos modelos mais parcimoniosos ou que melhor explicam as variáveis CC e PMP. O AIC pressupõe que para um modelo ser considerado parcimonioso não deve ser complexo, ou seja, deve conseguir responder as variáveis com um menor número de preditores. Nota-se na tabela, que os modelos indicados para essa função são aqueles com um menor valor de AIC. Logo, para predição da variável CC pelo critério de informação de Akaike os Modelos 2 (AIC=7,518; $R^2=0,890$) gerado pela RLM, Modelo 1 (AIC=7,640; $R^2=0,319$) e 4 (AIC=7,816; $R^2=0,856$) gerados pela RNA, foram os modelos que apresentaram os melhores indicativos do AIC. Para a variável PMP, o Modelos 4 (AIC=5,746; $R^2=0,241$) gerado pela RLM, Modelo 5 (AIC=6,249; $R^2=0,477$) e 8 (AIC=6,443; $R^2=0,482$) gerados pela RNA foram os modelos indicados no critério de informação de Akaike.

TABELA 26 – Tabela de comparação e escolha dos modelos pelo critério de seleção de Akaike (AIC).

Metodologia	Modelo	R^2	r	AIC
RNA	1	0,319	0,565	7,640
RNA	2	0,734	0,857	7,842
RNA	3	0,925	0,962	8,029
RNA	4	0,856	0,925	7,816
RNA	5	0,477	0,691	6,249
RNA	6	0,616	0,785	6,619
RNA	7	0,832	0,912	6,827
RNA	8	0,482	0,694	6,443
RLM	2	0,890	0,943	7,518
RLM	4	0,241	0,491	5,746

RNA: Rede Neural Artificial: Modelo1: Areia, Silte e Argila (CC); Modelo 2: Areia, Silte, Argila, Ds, Dp e MO (CC); Modelo 3: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (CC); Modelo 4: Micro e Ds (CC); Modelo5: Areia, Silte e Argila (PMP); Modelo 6: Areia, Silte, Argila, Ds, Dp e MO (PMP); Modelo 7: Areia, Silte, Argila, Ds, Dp, MO, Pt, Micro, Macro e Profundidade (PMP); Modelo 8: Micro, Pt, MO e Argila (PMP); RLM: Regressão Linear Múltipla: Modelo 2: Micro e Ds (CC); Modelo 4: Micro, Pt, MO e Argila (PMP);
Fonte: Próprio autor.

Embora os Modelos 1, 5 e 8 gerados pela RNA e Modelo 4 Gerado pela RLM terem sido indicados pelo critério de informação de Akaike, por serem modelos que apresentaram um R^2 baixo (0,319, 0,477, 0,482 e 0,241, respectivamente), não são modelos indicados para explicar as variáveis CC e PMP pela baixa capacidade preditiva.

Com isso, os Modelos 4 (AIC=7,816; $R^2=0,856$) e 6 (AIC=6,619; $R^2=0,616$), gerados pela RNA e o Modelo 2 (AIC=7,518; $R^2=0,890$), gerado pela RLM, são os modelos indicados para a estimativa da CC e do PMP pelos critérios do AIC e R^2 .

5. CONCLUSÕES

Este trabalho apresentou um estudo no qual se buscou verificar a viabilidade da aplicação de Redes Neurais Artificiais (RNAs) no estabelecimento de modelos para predição da capacidade de campo e o ponto de murcha permanente. Com o objetivo de apresentar um parâmetro de referência para o estudo, foi realizado um estudo adicional empregando Regressão Linear Multipla aos mesmos dados utilizados no estudo das RNAs.

A análise dos dados coletados indicou que tanto a regressão linear múltipla quanto a rede neural artificial foram capazes de prever a variável capacidade de campo com um ótimo desempenho, conforme resultados apresentados. Desta forma, verifica-se a viabilidade e similitude da qualidade das metodologias para a predição do problema apresentado.

As RNAs do tipo *Multilayer Perceptron* (MLP) com treinamentos supervisionados foram capazes de estimar, com assertividade, as umidades na CC e no PMP utilizando as propriedades do solo: Areia, Silte, Argila, Densidade do Solo, Densidade de Partículas, Matéria Orgânica, Porosidade Total, Microporosidade, Macoporosidade e Profundidade.

O estudo demonstrou que o modelo gerado pela RLM para a predição do PMP não apresentou a mesma performance do modelo com RNAs, não tendo acurácia na estimativa. Um indício de o modelo não ser indicado para a predição dessa variável. A análise dos resultados indicou a superioridade do desempenho da RNA em relação à RLM para a predição da variável PMP.

Verificou-se, também, que as arquiteturas de RNA para as variáveis apresentaram boa performance com um relativo baixo custo computacional. Os melhores desempenhos foram verificados com uma arquitetura de oito neurônios (2 para a entrada, 5 intermediários e um para a saída) para a Capacidade de Campo e onze neurônios (6 para a entrada, 4 intermediários e 1 para a saída) para o Ponto de Murcha Permanente.

Os resultados verificados indicam a validade do emprego de RNAs na predição das umidades do solo, tanto na capacidade de campo quanto no ponto de murcha permanente. Desta forma, apresenta-se uma ferramenta com grande potencial de emprego nas decisões e melhoria dos processos no desenvolvimento da agricultura de precisão.

6. REFERÊNCIAS

- ABBAD, G. e TORRES, C.V. Regressão múltipla stepwise e hierárquica em Psicologia Organizacional: Aplicações, problemas e soluções. **Estudos de Psicologia**, Campinas, v.7, n.esp., p.19-29, 2002.
- ABNT NBR 6458:2017. **Grãos de pedregulho retidos na peneira de 4,8 mm - Determinação da massa específica, da massa específica aparente e da absorção de água**. ABNT NBR 6458:2016 Versão Corrigida 2:2017. ABNT/CEE-221 Solos, 2017. 10p. (Norma Técnica)
- ACTION. PORTAL ACTION. **Regressão Linear Múltipla**. 2020. Disponível em: <<http://www.portalaction.com.br/analise-de-regressao/regressao-linear-multipla>>. Acesso em: 09 abr. 2020.
- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, Boston, v.19, n.6, p.716-723, 1974.
- ALMEIDA, B.G.; FREITAS, P.L.; TEIXEIRA, W.G.; VIANA, J.H.M.; DONAGEMMA, G.K. Porosidade. In: Teixeira, P.L.; Donagemma, G.K. **Manual de métodos de análise de solo**. Brasília: Embrapa, 2017. Cap.9, p.108-119.
- ALMEIDA, C.X. de; CENTURION, J.F.; FREDDI, O. da S.; JORGE, R.F.; BABOSA, J.C. Funções de pedotransferência para a curva de resistência do solo à penetração. **Rev. Bras. Ci. Solo**, Viçosa, v.32, n.6, p.2235-2243, 2008.
- ALVES, G.R.; TEIXEIRA, I.R.; MELO, F.R.; SOUZA, R.T.G.; SILVA, A.G., Estimating soybean yields with artificial neural networks. **Acta Sci. Agron.**, Maringá, v.40, e35250, p.1-9, 2018.
- ALVES, J.R. **Estimativa da produtividade da soja com redes neurais artificiais**. 2016. p.76. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás, Campus Anápolis de Ciências Exatas e Tecnológicas Henrique Santillo, Programa de Pós Graduação stricto sensu em Engenharia Agrícola, Anápolis, Goiás, 2016.
- ALVES, W.W.A.; OLIVEIRA, F. de A.; AZEVEDO, C.A.V. de; ALBUQUERQUE, J.H. de. Métodos de determinação e níveis de água disponível no solo: efeito sobre a cultura do algodoeiro herbáceo. **Rev. Caatinga**, Mossoró, v.23, n.4, p.91-94, 2010.
- ANDRADE, C.L.T.; FREITAS, J.A. D.; LUZ, L.R.Q.P. Características físico-hídricas de solos arenosos de tabuleiro litorâneos. In: Congresso Nacional de Irrigação e Drenagem, 9., 1991, Natal. **Anais...** Natal: ABID, 1991. v.1, p.1069-1095.
- ANDRADE, R. da S.; STONE, L.F. Estimativa da umidade na capacidade de campo em solos sob Cerrado. **Rev. Bras. Eng. Agrícola e Ambiental**, Campina Grande – PB, v.15, n.2, p.111-116, 2011.

ANTUNES JÚNIOR, E. de J. **Desempenho operacional e propriedades físico-mecânicas de um latossolo em função do tipo de pneu e cargas aplicadas à barra de tração**. 2016. p.69. Dissertação (Mestrado) – Universidade Estadual de Goiás Stricto Sensu em Engenharia Agrícola, Anápolis. 2016.

ARAÚJO, E.S.; MARSOLA, T.; MIYAZAWA, M.; SOARES, L.H.B.; URQUIAGA, S.; BODDEY, R.M.; ALVES, B.J.R. Calibração de câmara semi-aberta estática para quantificação de amônia volatilizada do solo. **Pesq. Agropec. Bras.**, Brasília, v.44, n.7, p.769-776, 2009.

ARRUDA, F.B.; ZULLO Jr.J.; OLIVEIRA, J.B. de. Parâmetros de solo para o cálculo da água disponível com base na textura do solo. **Rev. Bras. Ci. Solo**, Viçosa, v.11, n.1, p.11-15, 1987.

ÁVILA, L. F.; MELLO, C. R.; MELLO, J. M.; SILVA, A. M. Padrão Espaço-Temporal da Unidade Volumétrica do Solo em uma Bacia Hidrográfica com Predominância de Latossolos. **Rev. Bras. Ci. Solo**, Viçosa, v.35, n.5, p.1801-1810, 2011.

AZEVEDO, J.A. de; SILVA, E.M. da. **Tensiômetro: dispositivo prático para controle da irrigação**. Planaltina: Embrapa Cerrados, p.33, 1999. (Embrapa Cerrados. Circular Técnica, 001).

BAKER, L. Development of class pedotranfer functions of soil water retention – A refinement. **Geoderma**, Amsterdam, v.144, n.1-2, p.225-230, 2008.

BAPTISTELLA, M.; STEINER, M.T.A.; NETO, A.C. O uso de redes neurais e regressão linear múltipla na engenharia de avaliações: determinação dos valores venais de imóveis urbanos. In: XXXVIII SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 2006. **Pesquisa Operacional na Sociedade: Educação, Meio Ambiente e Desenvolvimento**. Goiânia, 2006, p.1-11.

BARRETO, J.M. **Introdução às Redes Neurais Artificiais**. 2002. Laboratório de Conexão e Ciências Cognitivas UFSC – Departamento de Informática e de Estatística, Florianópolis, SC, 2002. Disponível em: <<http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf>>. Acesso em: 24 abr. 2020. (Tutorial).

BASHEER, I.A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, Amsterdam, v.43, n.1, p.3–31, 2000.

BAYAT, H.; ZADEH, G.E. Estimation of the soil water retention curve using penetration resistance curve models. **Computers and Electronics in Agriculture**, Oxford, v.144, p.329-343, 2018.

BENITE, M. **Aplicação de modelos de redes neurais na elaboração e análise de cenários macroeconômicos**. 2003. Dissertação (Mestrado em Engenharia de Produção), Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2003.

BENNETT, H.H. **Elements of Soil Conservation**. 2nd Edition. New York: Mcgraw-Hill Book Company, 1955. 358p.

BERG, M.V.D.; KLAMT, E.; REEUWIJK, L.P.V.; SOMBROEK, W.G. Pedotransfer functions for the estimation of moisture characteristics of Ferralsols and related soils. **Geoderma**, Amsterdam, v.78, n.3-4, p.161-180, 1997.

BERNARDO, S. **Manual de irrigação**. 2.ed. Viçosa, UFV, Imprensa Universitária, 1982. 463p.

BERNARDO, S.; SOARES, A.A.; MANTOVANI, E.C. **Manual de irrigação**. 7. ed. Viçosa: UFV, Imprensa Universitária, 2007.

BERNARDO, S.; SOARES, A.A.; MANTOVANI, E.C. **Manual de irrigação**. 8.ed. Viçosa: Editora UFV, 2008. 625p.

BERTOL, I.; SANTOS, J.C.P. Uso do solo e propriedades físico-hídricas no Planalto Catarinense. **Pesquisa Agropecuária Brasileira**, Brasília, v.30, n.2, p.263-267, 1995.

BERTONI, J.; LOMBARDI NETO, F. **Conservação dos Solos**. 5.ed. São Paulo: Ícone, 2005. 355p.

BEZERRA, J.R.C.; AMORIM NETO, M. da S.; LUZ, M.J.S. e; BARRETO, A.N.; SILVA, L.C. da. Irrigação do algodoeiro herbáceo. In: Beltrão, N.E. de M. (Org.). **O agronegócio do algodão no Brasil**. Brasília: Embrapa Comunicação para Transferência de Tecnologia, 1999, v.1, p.619-682.

BIASSUSI, M.; PAULETTO, E.A.; CRESTANA, S. Estudo da deformação de um Vertissolo por meio da tomografia computadorizada de dupla energia simultânea. **Rev. Bras. Ci. Solo**, Viçosa, v.23, n.1, p.1-7, 1999.

BINOTI, D.H.B.; BINOTI, M.L.M. da S.; LEITE, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira (Braz. J. Wood Sci.)**, Pelotas, v.5, n.1, p.58-67, 2014.

BITTAR, R.B.; ALVES, S.M.F.; MELO, F.R. Estimation of physical and chemical soil properties by Artificial Neural Networks. **Revista Caatinga**, Mossoró, v.31, n.3, p.704-712, 2018.

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

BLACK, C.A. **Soil - plant relationships**. 2nd Edition. New York: John Wiley e Sons, 1968. 792p.

BONDER, B.H. **Curvas de retenção de água de um solo Coluvionar de Campinas obtidas mediante técnicas de laboratório e de campo**. 2008. p.152. Dissertação (Mestrado em Engenharia Civil), Universidade Estadual de Campinas, Faculdade de Engenharia Civil e Arquitetura. 2008.

BOTTENBERG, R.A.; WARD, J.H.Jr. **Applied Multiple Linear Regression**. Texas: 6570th Personnel Research Laboratory, Lackland Air Force Base, 1963. 139p.

BOUMA, J. Using soil survey data for quantitative land evaluation. **Advances in Soil Science**, New York, v.9, p.177-213, 1989.

BOUYOUCOS, G.J. A new, simple and rapid method for determination the moisture equivalent of soils, and the role of soil colloids on this moisture equivalent. **Soil Sci.**, v.27, n.7, p.233-242, 1929.

BRADY, N.C. **Natureza e propriedades dos solos**. 7.ed. São Paulo: Freitas Bastos, 1989. 878p.

BRADY, N.C.; WEIL, R.R. **Elementos da Natureza e Propriedades do Solo**. 3.ed. Porto Alegre: Bookman, 2013. 716p.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDEMIR, T.B. **Redes neurais artificiais: Teoria e aplicações**. 2.ed. Rio de Janeiro: Livros Técnicos e Científicos, p.226, 2012.

BRAGA, M.B.; GUEDES, I.M.R.; SILVA, J. da; LIMA, C.E.P. **Determinação simplificada da umidade do solo visando o manejo de irrigação em hortaliças**. In: Boletim de Pesquisa e Desenvolvimento. Brasília, DF: Embrapa Hortaliças, 2018. 25p.

BRASIL. Secretaria de Estado de Gestão e Planejamento de Goiás. **Perfil Competitivo das Regiões de Planejamento do Estado de Goiás**. Goiânia, SGC/SEPLAN/GO, 2011. Disponível em: <<http://www.sgc.goias.gov.br/upload/anexos/2011-04/f40892f24f7def77a05e7bce682943ff.pdf>>. Acesso em: 03 dez. 2019.

BRIGGS, L. J.; SHANTZ, H. L. The wilting coefficient for different plants and its indirect determination. **Journal of Washington Academy of Sciences**. Washington, v.1, n.8, p.228-232, 1911.

BRIGGS, L.J.; McLANE, J.W. Moisture equivalent determinations and their application. **Am. Soc. Agronomy Proc.**, Washington, v.2, n.1, p.138-147, 1910.

BRISTOW, K.L.; SMETTEM, K.R.J.; ROSS, P.J.; FORD, E.J.; ROTH, C.; VERBURG, K. Obtaining Hydraulic properties for soil water balance models: some pedotransfer functions for tropical Australia. In: Van Genuchten, M.T.H.; Leij, F.J.; Wu, L. (Eds). **Characterization and measurement of the hydraulic properties of unsaturated porous media**. Part 2. Riverside, CA: University of California, 1999, p.1103-1120.

BRITO, A.S.; LIBARDI, P.L.; MOTA, J.C.A.; MORAES, S.O. Estimativa da capacidade de campo pela curva de retenção e pela densidade de fluxo da água. **Rev. Bras. Ci. Solo**, Viçosa, v.35, n.6, p.1939-1948, 2011.

BRITO, R.M.; SAMPAIO, A.A.M. Efeito de fontes de proteína nas características da carcaça e avaliação do rendimento de carne aproveitável estimada por meio de equações de regressão linear múltipla em touros $\frac{3}{4}$ Canchim $\frac{1}{4}$ Nelore. **ARS Veterinaria**, Jaboticaval, v.17, n.1, p.64-70, 2001.

BROCCA, L.; MELONE, F.; MORAMARCO, T.; MORBIDELLI, R. Soil moisture temporal stability over experimental areas in central italy. **Geoderma**, Amsterdam, v.148, n.3, p.364-374, 2009.

- BUSKE, T.C. **Comportamento da umidade do solo determinada por métodos expeditos**. 2013. p.67. Dissertação (Mestrado) – Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, RS, 2013.
- BUSSCHER, W.J. Adjustment of flat-tipped penetrometer resistance data to a common water content. **Transactions of the ASAE**, St Joseph, v.33, n.1, p.519-524, 1990.
- CAMARGO, A.P. de; COSTA, O.A.L. da. Determinação rápida da umidade do solo pelo método da reação com o carbureto de cálcio. **Bragantia**, Campinas, v.19, n.30, p.493-502, 1960.
- CAMARGO, A.P. de; GROHMANN, F.; CAMARGO, M.B.P de. Tensiômetro simples de leitura direta. **Pesq. Agropec. bras.**, Brasília, v.17, n.12, p.1763-1772, 1982.
- CAMARGO, Â.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Piracicaba, v.5, n.1, p.89-97, 1997.
- CAMPBELL, G.S. A Simple method for determining unsaturated hydraulic conductivity from moisture retention data. **Soil Science**, Baltimore, v.117, n.6, p.311-314, 1974.
- CANEDO, G. Guilda do Código. **Inteligência Artificial – Parte I**. 2016. Disponível em: <<https://guildadocodigo.atelie.software/intelig%C3%A2ncia-artificial-parte-i-ebd62adbc10>>. Acesso em: 20 abr. 2020.
- CAPUTO, H.P. **Mecânica dos Solos e suas Aplicações**. 6.ed. Rio de Janeiro: LTC, v.1, 1988. 234p.
- CARELLI, P.V. **Modelagem estocástica de neurônios e sua interação em tempo real com neurônios biológicos**. 2008. 113p. Tese (Doutorado em Ciências) – Universidade de São Paulo, Instituto de Física, São Paulo, 2008.
- CARRIJO, T.B. **Relação entre o índice I de Moran e a quantidade de dados observados**. 2015. p.83. Dissertação (Mestrado em Estatística), Universidade de Brasília, Departamento de Estatística – Instituto de Ciência Exatas, Brasília-DF, 2015.
- CARVALHO, E.J.M.; FIGUEIREDO, M. de S.; COSTA, L.M. da; Comportamento físico hídrico de um podzólico vermelho-amarelo câmbico fase terraço sob diferentes sistemas de manejo. **Pesq. Agropec. Bras.**, Brasília, v.34, n.2, p.257-265, 1999.
- CARVALHO, T.M. de; FERREIRA, M.E.; BAYER, M. Análise integrada do uso da terra e geomorfologia do Bioma Cerrado: um estudo de caso para Goiás. **Rev. Bras. Geo. Fís.**, Recife, v.1, n.1, p.62-72, 2008.
- CASSEL, D.K.; NIELSEN, D.R. Field capacity and available water capacity. In: Klute, A. (Ed.). **Methods of soil analysis**. Part.1. Physical and mineralogical methods. Madison: American Society of Agronomy, Soil Science Society of America, 1986. p.901-926.

- CASTILLA PRADO, N.; MONTALVO LOPES, T. Programación del riego. In: Cadahia, C. (Org.). **Fertirrigación: cultivos hortícolas y ornamentales**. 2.ed. rev., México: Mundi Prenda, 2000. cap.7, p.267-271.
- CASTRO, W.J. de; LEMKE-de-CASTRO, M.L.; LIMA, J. de O.; RODRIGUES, C.; FIGUEIREDO, C.C. de. Erodibilidade de solos do Cerrado Goiano. **Rev. Agroneg. Meio Ambien.**, Maringá, v.4, n.2, p.305-320, 2011.
- CERRI, C.C.; FELLER, C.; CHAUVEL, A. Evolução das principais propriedades de um Latossolo Vermelho-Escuro após desmatamento e cultivo por doze e cinquenta anos com cana-de açúcar. **Cahiers Orstom. Serie Pedologie**, Paris, v.26, n.1, p.37-50, 1991.
- CHILDS, E.C. The use of soil moisture characteristics in soil studies. **Soil Science**, Baltimore, v.50, n.4, p.239-252, 1940.
- CIRINO, C.G.; GUERRA, H.O.C. Utilização das relações energia/umidade na caracterização físico-hídrica dos solos. **Pesq. Agropec. Bras.**, Brasília, v.29, n.12, p.1973-1978, 1994.
- COELHO FILHO, M. A.; BASSOI, L. H.; ANGELOCCI, L. R.; COELHO, E. F.; PEREIRA, F, A, de C. Relação solo-planta-atmosfera. In: Sousa, V. F. de; Marouelli, W. A.; Coelho, E. F.; Pinto, J. M.; Coelho Filho, M. A. (Ed.). **Irrigação e fertirrigação em fruteiras e hortaliças**. Brasília, DF: Embrapa Informação Tecnológica, cap.1, 2011, p.27-90.
- COELHO, E.F.; SILVA, A.J.P. da; VELLAME, L. de M. **Sondas de TDR artesanais de três hastes para estimativa da umidade do solo**. Cruz das Almas, BA: Embrapa, p.1-6, 2016. (Embrapa. Circular Técnica, 119).
- COELHO, J.B.M.; BARROS, M. de F.C.; NETO, E.B.; SOUZA, E.R. de. Ponto de murcha permanente fisiológico e potencial osmótico de feijão caupi cultivado em solos salinos. **Rev. Bras. Eng. Agríc. Ambien.**, Campina Grande, v.18, n.7, p.708-713, 2014.
- CORREA, S.M.B.B. **Probabilidade e Estatística**. 2. ed. Belo Horizonte: PUC Minas Virtual, 2003. 116p.
- CORREIA, J.R.; REATTO, A.; SPERA, S.T. Solos e suas relações com o uso e o manejo. In: Sousa, D.M.G.; Lobato, E. **Cerrado: correção do solo e adubação**. 2.ed. Brasília, DF: Embrapa Informação Tecnológica, 2004. p.29-58.
- COSTA, A. da; **Retenção e disponibilidade de água em solos de Santa Catarina: avaliação e geração de funções de pedotransferência**. 2012. p.423. Tese (Doutorado) – Centro de Ciências Agroveterinárias, UDESC, Lages, 2012.
- COSTA, A.C.S. da., LIBARDI, P.L, MORAES, S.O.; REICHARDT, K. Retenção e movimento da água de um solo Terra Roxa Estruturada. In: ENCONTRO CIENTÍFICO DA UEM, 3, 1989, Maringá. **Anais...** Maringá: Fuem, 1989.
- COSTA, A.C.S. da; NANNI, M.R.; JESKE, E. Determinação da umidade na capacidade de campo e ponto de murchamento permanente por diferentes metodologias. **Rev. UNIMAR**, Marília, v.19, n.3, p.827-844, 1997.

COSTA, J.B. **Caracterização e constituição do solo**. 29.ed. Lisboa: Fundação Calouste Gulbenkion., 1979. 527p.

CRESSWELL, H.P.; PAYDAR, Z. Water retention in Australian soils. I. Description and prediction using parametric functions. **Australian Journal of Soil Research**, Collingwood, v.34, n.2, p.195-212, 1996.

CRUZ, A.C.R.; PAULETTO, E.A.; FLORES, C.A.; SILVA, J.B. Atributos físicos e carbono orgânico de um argissolo vermelho sob sistemas de manejo. **Rev. Bras. Ci. Solo**, Viçosa, v.27, n.6, p.1105-1112, 2003.

CZYZ, E.A.; DEXTER, A.R. Plant wilting can be caused either by the plant or by the soil. **Soil Research**, Wellington, v.50, n.8, p.708-713, 2012.

DAVALO, M.J. **Curva de retenção de água no solo estimado pelo método da câmara de Richards e psicrômetro**. 2013. p.36. Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, 2013.

DENER-ME. DEPARTAMENTO NACIONAL DE ESTRADAS E RODAGEM. **DNER-ME 052: Solos e agregados miúdos – Determinação da umidade com emprego do “Speedy”**. Rio de Janeiro, p.4, 1994.

DIAS JUNIOR, M.S. Compactação do solo. In: Novais, R.F.; Alvarez V., V.H.; Schaefer, C.E., eds. **Tópicos em ciência do solo**. Sociedade Brasileira de Ciência do Solo, Viçosa, v.1. p.55-94, 2000.

DONAGEMMA, G.K.; CAMPOS, D.D.; CALDERANO, S.B.; TEIXEIRA, W.G.; VIANA, J.H.M. **Manual de métodos de análise de solos**. 2. ed. Rio de Janeiro: Embrapa Solos, 2011. 230p.

DONAGEMMA, G.K.; VIANA, J.H.M.; ALMEIDA, B.G.; RUIZ, H.A.; KLEIN, V.A.; DECHEN, S.C.F.; FERNANDES, R.B.A. Análise Granulométrica. In: Teixeira, P.L.; Donagemma, G.K. **Manual de métodos de análise de solo**. Brasília: Embrapa, 2017. Cap.10, p.98-120.

DOURADO NETO, D.; JONG-VAN-LIER, Q. de J.V.; BOTREL, T.A.; LIBARDI, P.L. Programa para confecção da curva de retenção de água no solo utilizando o modelo de Genuchten. **Engenharia Rural**, Piracicaba: v.1, n.2, p.92-102, 1990.

DURBIN, J.; WATSON G.S. Testing for serial correlation in least squares regression I. **Biometrika**, London, v.37, n.3-4, p.409-428, 1950.

EMBRAPA. **Manual de métodos de análise de solo**. TEIXEIRA, P.C.; DONAGEMMA, G.K.; FONTANA, A.; TEIXEIRA, W.G. 3.ed. revi. e ampli. Brasília, DF: Embrapa, 2017, 509p.

EMBRAPA. **Método simplificado de determinação da umidade do solo para uso em manejo de irrigação em agricultura familiar**. In: Coelho, E.F.; Silva, T.S.M.; Santana Júnior, E.B.; Parizotto, I. Cruz das Almas, BA, p.1-4, 2013. (Comunicado Técnico, Cruz das Almas, BA)

EMBRAPA. Serviço Nacional de Levantamento e Conservação do Solo (Rio de Janeiro, RJ). **Manual de Métodos de Análise de Solo**. Embrapa Gado de Leite. Rio de Janeiro, 1979. Não Paginado. (Boletim técnico, 79)

EOS. Earth Observing System. **O controle de umidade do solo é um componente essencial da agricultura**. 2020. Disponível em: < <https://eos.com/pt/blog/umidade-do-solo/>>. Acesso em: 02 abr. 2020.

FABIAN, A.J.; OTTONI FILHO, T.B. Determinação de capacidade de campo *in situ* ou através de equações de regressão. **Pesq. Agropec. Bras.**, Brasília, v.35, n.5, p.1029-1036, 2000.

FABIAN, A.J.; OTTONI FILHO, T.B. Determinação de curvas de infiltração usando uma câmara de fluxo. **Rev. Bras. Ci. Solo**, Campinas, v.21, n.2, p.325-333, 1997.

FAGGION, F.; OLIVEIRA, C. A. S.; CHRISTOFIDIS, D. Uso Eficiente da água uma contribuição para o desenvolvimento sustentável da agropecuária. **Pesquisa Aplicada & Agrotecnologia**, Guarapuava, v.2, n.1, p.187-190, 2009.

FALLEIROS, M. de C. **Medida da umidade do solo com sonda de nêutrons**. 1994. p.131. Tese (Doutorado em Ciências na Área de Tecnologia Nuclear), Instituto de Pesquisas Energéticas e Nucleares, Autarquia Associada à Universidade de São Paulo, São Paulo, 1994.

FERNANDES, B.; RESENDE, M.; REZENDE, S.B. Caracterização de alguns solos sob cerrado e disponibilidade de água para culturas. **Experientiae**, Viçosa, v.24, n.9, p.211-260, 1978.

FERREIRA, A.A. **Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais**. 2004. Dissertação (Mestrado em Ciência da Computação), Centro de Informática UFPE, Universidade Federal de Pernambuco, Recife, PE, 2004.

FERREIRA, D.F. Sisvar: um sistema computacional de análise estatística. **Ciência e Agrotecnologia**, Lavras, v.35, n.6, p.1039-1042, 2014.

FERREIRA, E.; RESENDE, A.S. de; BALIEIRO, F.; ZOTARELLI, L.; SILVA, L.A. da; BACIS, M.; ALFARO, M.A.; ALVES, B.J.R.; URQUIGA, S. **Avaliação de diferentes tubos de acesso para medição da umidade do solo através do uso de sonda de nêutrons**. In: Documentos Embrapa, Seropédica, RJ: Embrapa Agrobiologia, p.12, 1998.

FERREIRA, M.M.; MARCOS, Z.Z. Estimativa da capacidade de campo de Latossolo Roxo distrófico e regossolo através do ponto de inflexão da curva característica de umidade. **Ciência e Prática**, Bebedouro, v.7, p.96-101, 1983.

FERREIRA, N.C.; BARCELOS, R.; FERREIRA, L.G. Transferência de informações ambientais geograficamente referenciadas no estado de Goiás: Subsídio à gestão territorial e ambiental integrada e democrática. In. XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 2005, Goiânia. **Anais...** Brasil, INPE, 2005. p.2137-2144.

FERRO, L.; STURABO, J.R. Aplicação da Rede Neural MLP (Multilayer Perceptron) em indústria de pisos e revestimentos do Pólo Cerâmico de Santa Gertrudes – SP. **Geociências**, São Paulo, v.32, n.4, p.706-714, 2013.

FIELD, A. **Descobrimo a estatística usando o SPSS [recurso eletrônico]**. 2. ed. – Dados Eletrônicos. – Porto Alegre: Artmed, 2009. 684p.

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

FONTANA, A. Matéria orgânica. In: Teixeira, P. L.; Donagemma, G.K. **Manual de métodos de análise de solo**. Brasília: Embrapa, 2017. 3ed. cap.5, p.355-357.

FRANÇA, A.M. da S. **Função de pedotransferência para estimativa de estoques de carbono em solo de áreas de campo limpo úmido do Distrito Federal**. 2011. p.128. Tese (Doutorado) – Universidade de Brasília, Instituto de Geociências, Brasília, DF, 2011.

FREITAS JÚNIOR, E de; SILVA, E.M. da. Uso da centrífuga para determinação da curva de retenção de água no solo, em uma única operação. **Pesq. Agropec. Bras.**, Brasília, v.19, n.11, p.1423-1428, 1984.

FUKUSHIMA, K. Cognitron: A self-organizing multilayered neural network. **Biological Cybernetics**, New York, v.20, n.3-4, p.121-136, 1975.

FURR, J.R.; REEVE, J.O. Range of soil-moisture percentages through which some plants undergo permanent wilting in some soils from semi arid irrigated áreas. **Journal of Agricultural Reseach**, Washington D.C., v.71, n.4, p.149-170, 1945.

FURTADO, M.I.V. **Redes Neurais Artificiais: Uma abordagem para sala de aula [recurso eletrônico]**. Ponta Grossa: Atena Editora, 2019. 105p.

GATTO, E.C. **Apostila de Perceptron e Multilayer Perceptron**. Universidade Federal de São Carlos, Departamento de Computação, Programa de Pós-Graduação em Ciência da Computação, São Carlos, SP, 2018. Disponível em: <<https://pt.slideshare.net/elainececiliagatto/perceptron-e-multilayer-perceptron>>. Acesso em: 22 abr. 2020. (Apostila).

GERS, F.; CUMMINS, F.; FERNANDEZ, S.; BAYER, J.; WIERSTRA, D.; TOGELIUS, J.; GOMEZ, F.; GAGLIOLO, M.; GRAVES, A. **Understanding LSTM Networks**. COLAH's Blog, GITHUB blog, 2015. Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 22 abr. 2020.

GHANBARIAN-ALAVIJEH, B.; MILLÁN, H. Point pedotransfer functions for estimating soil water retention curve. **International Agrophysics**, Lublin, v.24, n.3, p.243-251, 2010.

GHELFI FILHO, H. Estudo comparativo do método das pesagens e o método gravimétrico padrão para a determinação do teor de umidade do solo. **An. ESALQ**, Piracicaba, v.45, n.1, p.99-108, 1988.

- GIAROLA, N.F.B.; SILVA, A.P.; IMHOFF, S. Relações entre propriedades físicas e características de solos da região Sul do Brasil. **Rev. Bras. Ci. Solo**, Viçosa, v.26, n.4, p.885-893, 2002.
- GÓMEZ-PLAZA, A.; ALVAREZ-ROGEL, J.; ALBALADEJO, J.; CASTILLO, V. M. Spatial patterns and temporal stability of soil moisture across a range of scales in a semi-arid environment. **Hydrological Processes**, Chichester, v.14, n.7, p.1261-1277, 2000.
- GONÇALVES, A.C.A.; TRINTINALHA, M.A.; TORMENA, C.A.; FOLEGATTI, M.V. Influência da densidade de solo na estimativa da umidade em um Nitossolo Vermelho Distroférico, por meio da técnica de TDR. **Rev. Bras. Ci. Solo**, Viçosa, v.35, n.5, p.1551-1560, 2011.
- GORGENS, E.B.; LEITE, H.G.; SANTOS, H. do N.; GLERIANI, J.M. Estimação do volume de árvores utilizando redes neurais artificiais. **Rev. Árvore**, Viçosa, v.33, n.6, p.1141-1147, 2009.
- GROHMANN, F.; MEDINA, H.P. Características de umidade dos principais solos do estado de São Paulo. **Bragantia**, Campinas, v.21, n.unico, p.285-295, 1962.
- GUARIZ, H.R.; CAMPANHARO, W.A.; PICOLI, M.H.S.; CECÍLIO, R.A.; HOLLANDA, M.P. Variação da umidade e da densidade do solo sob diferentes coberturas vegetais. In: XIV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 2009, Natal. **Anais...** Natal: INPE, 2009. p.7709-7716.
- GUPTA, S.C.; LARSON, W.E. Estimating soil water retention characteristics from particle size distribution, organic matter content, and bulk density. **Water Resources Research**, Minnesota, v.15, n.6, p.1633-1635, 1979.
- HAINES, W.B. Studies in the physical properties of soil. V. The hysteresis effect in capillary properties, and the modes of moisture distribution associated therewith. **The Journal of Agricultural Science**, Cambridge, v.20, n.1, p.97-116, 1930.
- HAYKIN, S. **Redes Neurais- Princípios e Práticas**. 2. ed. São Paulo: BOOKMAN, 2001. 900p.
- HEATHMAN, G.C.; LAROSE, M.; COSH, M.H.; BINDLISH, R. Surface and profile soil moisture spatio-temporal analysis during an excessive rainfall period in the southern great plains, USA. **Catena**, Amsterdam, v.78, n.2, p.159-169, 2009.
- HEBB, D.O. **The Organization of Behavior: A neuropsychological theory**. New York: Wiley, 1949. 335p.
- HILLEL, D. 1998. **Environmental soil physics**. 1. ed. Massachusetts: Academic Press, 1998. 771p.
- HILLEL, D.A.; KRENTOS, V.K.; STILIANOV, Y. Procedure and teste f na internal drainage method for measuring soil hydraulic characteristics in situ. **Soil Science**, Baltimore, v.114, p.395-400, 1972.

HORN, R.; LEBERT, M. Soil compactability and compressibility. In: Soane, B.D.; Ouwerkerk, C. van. **Soil compactation in crop production**. Developments in Agricultural Engineering, Amsterdam: Elsevier, v.11, n.3, p.45-69, 1994.

HURTADO, A.L.B.; CICHOTA, R.; VAN LIER, Q. de J. Parametrização do Método do Perfil Instantâneo para a determinação da Condutividade Hidráulica do solo em experimentos com evaporação. **Rev. Bras. Ci. Solo**, Viçosa, v.29, n.2, p.301-307, 2005.

IBGE / CNPS. IBGE: Embrapa Solos. CNPS – Centro Nacional de Pesquisa de Solos (Rio de Janeiro, RJ), 2001. **MAPA de solos do Brasil**. Mapa color. Escala 1:5.000.000. 2001.

IBGE. Bases Cartográficas Contínuas. **MAPA de limites da América do Sul**. Mapa color. Escala 1:5.000.000. 2017. Disponível em: <<https://www.ibge.gov.br/geociencias/downloads/geociencias.html>>. Acesso em: 12 fev. 2020.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo Agropecuário: 2006**. Brasil, grandes Regiões e unidades da Federação: segunda apuração. Rio de Janeiro, p.777, 2006.

IBM CORPORATION. Released 2017. **IBM SPSS Statistics for Windows, Version 25.0**. Armonk, NY: IBM Corp. 2017. Disponível em: <www.ibm.com/legal/copytrade.shtml>.

INSTITUTO MAURO BORGES. IMB. **Perfil Socioeconômico dos municípios Goianos**. Estatísticas Municipais (Séries Históricas). GOIÁS, 2018. Disponível em: <http://www.imb.go.gov.br/index.php?option=com_content&view=article&id=14&Itemid=218>. Acesso em: 03 dez. 2019.

KIEHL, E.J. **Fertilizantes Orgânicos**. Piracicaba: Editora Agronômica “Ceres”, 1985. 492p.

KIEHL, E.J. **Manual de edafologia, relações solo-planta**. São Paulo: Editora Agronômica “Ceres”, 1979. 262p.

KIM, Y.; EVANS, R.G.; IVERSEN, W.M. Remote sensing and control of an irrigation system using a distributed wireless sensor network. **IEEE transactions on instrumentation and measurement**, Piscataway, v.57, n.7, p.1379–1387, 2008.

KLEIN, V.A. **A física do solo**. Passo Fundo: Ed. Universidade de Passo Fundo, 2008. 212p.

KLEIN, V.A.; REICHERT, J.M.; REINERT, D.J. Água disponível em um latossolo vermelho argiloso e murcha fisiológica de culturas. **Rev. Bras. Eng. Agríc. Ambien.**, Campina Grande, v.10, n.3, p.646-650, 2006.

KLUTE, A. Waterretention: laboratory methods. In: Black, C.A. (Ed.). Methods of soil analysis. 2.ed. **Physical and mineralogical methods**, Madison: Soil Society of America, p.635-662, 1986.

KOKLAY, R.F.; CLARK, R.N. Spectroscopic Determination of Leaf Biochemistry Using Band-Depth Analysis of Absorption Features and Stepwise Multiple Linear Regression. **Remote Sensing of Environment**, New York, v.67, n.3, p.267-287, 1999.

KONDO, M.K.; DIAS JUNIOR, M.S. Compressibilidade de três Latossolos em função da umidade e uso. **Rev. Bras. Ci. Solo**, Viçosa, v.23, n.2, p.211-218, 1999.

KOVÁCS, Z.L. **Redes neurais artificiais: fundamentos e aplicações: um texto básico**. 4. ed. São Paulo: Editora Livraria da Física, 2006. 174p.

LACERDA, C.F. **Relações solo-água-plantas em ambientes naturais e agrícolas do Nordeste brasileiro**. Universidade Federal Rural de Pernambuco. Departamento de Engenharia Agrícola. Centro de Ciências Agrárias. Universidade Federal do Ceará. Recife: Pernambuco, 2007. 179p. (Apostila)

LAKZIAN, A.; BANNAYAN AVAL, M.M.; GORBANZADEH, N. Comparison of pattern recognition, Artificial Neural Network and Pedotransfer functions for estimation of soil water parameters. **Notulae Scientia Biologicae**, Cluj-Napoca, v.2, n.3, p.114-120, 2010.

LEAMER, R.W.; SHAW, B. A simple apparatus for measuring noncapillary porosity on an extensive scale. **Journal of American Society of Agronomy**, Madison, v.33, n.11, p.1003-1008, 1941.

LIAO, K.H.; XU, S.H.; WU, J.C.; JI, S.H.; LIN, Q. Assessing Soil Water Retention Characteristics and Their Spatial Variability Using Pedotransfer Functions. **Pedosphere**, Beijing, v.21, n.4, p.413-422, 2011.

LIBARDI, P.L. **Dinâmica da Água no Solo**. São Paulo: Ed. Universidade de São Paulo, v.61, 2005. 335p.

LIMA, H.V. de; SILVA, A.P. da; Mesa de tensão com areia: Procedimentos para montagem e validação. **Rev. Bras. Ci. Solo**, Viçosa, v.32, n.5, p.2209-2214, 2008.

LITTLEBOY, M. **Spatial generalisation of biophysical simulation models for quantitative land evaluation: a case study for dryland wheat growing areas of Queensland**. 1997. 255p. PhD (Thesis). The University of Queensland, Australia, 1997.

LOPES, A.S. **Solos sob "cerrado": características, propriedades e manejo**. 2. ed. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fósforo, 1984. 162p.

MAIA, C.E.; MORAIS, E.R.C de; OLIVEIRA, M. de. Classificação da composição iônica da água de irrigação usando regressão linear múltipla. **Rev. Bras. Eng. Agr. Ambien.**, Campinas Grande, v.5, n.1, p.55-59, 2001.

MANIERI, J.M.; VAZ, C.M.P.; MARIA, I.C. de. Sonda espiral de TDR para a medida da umidade no perfil do solo. **Rev. Bras. Ci. Solo**, Viçosa, v.31, n.2, p.191-198, 2007.

MANTOVANI, E.C. Compactação do solo. **Informe Agropecuário**, Belo Horizonte, v.13, n.147, p.52-55, 1987.

MARCOLIN, C. D.; KLEIN, V. A. Determinação da densidade relativa do solo por uma função de pedotransferência para a densidade do solo máxima. **Acta Scientiarum Agronomy**, Maringá, v.33, n.2, p.349- 354, 2011.

MARÔCO, J. **Análise Estatística – Com utilização do SPSS**. 2. ed. Lisboa: Edições Sílabo, 2003.

MARQUELLI, W.A. L. CARVALHO e SILVA, W.L. de; SILVA, H.R da. **Manejo da irrigação em hortaliças**. Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisa de Hortaliças – Brasília: EMBRAPA-SPI, ed.5, rev. e ampl., p.72, 1996.

MARQUES, J.D. de O. **Horizontes pedogenéticos e sua relação com camadas hidráulicas do solo**. 2000. p.86. Dissertação (Mestrado) Escola Superior de Agricultura de Luiz de Queiroz, Piracicaba, 2000.

MARQUES, M.A.P. **Análise e comparação de alguns métodos alternativos de seleção de variáveis preditoras no modelo de regressão linear**. 2018. p.80. Dissertação (Mestrado em Estatística) Instituto de Matemática e Estatística da Universidade de São Paulo, Programa: Estatística, São Paulo, 2018.

MATSUNAGA, V.Y. **Curso de Redes Neurais utilizando o MATLAB**. 2012. p.22. Disponível em: <<http://muriloleal.com/visao/repositorio/centec/eai/ia/REDES%20NEURAI%20-%20APOSTILA.pdf>>. Acesso em: 20 abr. 2020. (Apostila).

McBRATNEY, A.B.; MINASNY, B.; CATTLE, S.R.; VERVOORT, R.W. From pedotransfer functions to soil inference systems. **Geoderma**, Amsterdam, v.109, n.1-2, p.41-73, 2002.

McCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v.5, p.115-133, 1943.

MEDINA, D.F.; OLIVEIRA JÚNIOR, R.C. Relações entre capacidade de campo determinada IN SITU e em laboratório em Lotosolo Amarelo muito argiloso. **Rev. Bras. Ci. Solo**, Viçosa, v.11, n.2, p.91-95, 1987.

MELLO, C.R.; OLIVEIRA, G.C.; RESCK, D.V.S.; LIMA, J.M.; DIAS JÚNIOR, M.S. Estimativa da capacidade de campo baseada no ponto de inflexão da curva característica. **Ciênc. agrotec.**, Lavras, v.26, n.4, p.836-841, 2002.

MENDES, R.B. **Predição da retenção de água em solos de Santa Catarina através de redes neurais artificiais**. 2014. p.147. Dissertação (Mestrado em Ciência do solo), Universidade do Estado de Santa Catarina, Centro de Ciências Agroveterinárias, Programa de Pós-Graduação em Ciência do Solo, Lages, SC, 2014.

MENEGAZ, S.T.; NUNES, J.N.V.; PETRY, M.T.; BASSO, L.J.; HENCKES, J.R.; GOMES, H. Avaliação da qualidade físico-hídrica de solos irrigados em algumas regiões do Brasil. III INOVAGRI INTERNACIONAL MEETING, 11., 2015, Fortaleza. **Anais...** Fortaleza: INOVAGRI, 2015. p.536-546.

MERDUN, H.; ÇINAR, Ö.; MERAL, R.; APAN, M. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. **Soil and Tillage Research**, Amsterdam, v.90, n.1-2, p.108-116, 2006.

- MEYER, P.D.; GEE, G.W. Flux-based estimation of field capacity. **J. Geotechn. Geoenviron. Eng.**, Reston, v.125, n.7, p.595-599, 1999.
- MICHELON, C.J. **Pedofunções para retenção de água de solos do Rio Grande do Sul irrigados por aspersão**. 2010. p.109. Tese (Doutorado) – Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Ciências do Solo, 2010.
- MILONE, G.; ANGELINI, F. **Estatística geral: amostragem, distribuições amostrais, teoria da decisão estatística**. 1. ed. São Paulo: Atlas, 1993. 260p.
- MINASNY, B.; McBRATNEY, A.B. The Australian soil texture boomerang: a comparison of the Australian and USDA/FAO soil particle-size classification systems. **Australian Journal of Soil Research**, Victoria, v.39, n.6, p.1443-1451, 2001.
- MINASNY, B.; MCBRATNEY, A.B. The neuro-m method for fitting neural network parametric pedotransfer functions. **Soil Science Society of America Journal**, Madison, v.66, n.2, p.352-361, 2002.
- MINASNY, B.; MCBRATNEY, A.B.; BRISTOW, K.L. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. **Geoderma**, Amsterdam, v.93, n.3-4, p.225-253, 1999.
- MINASNY, B.; MCBRATNEY, A.B.; MENDONÇA-SANTOS, M de L.; SANTOS, H.G. dos; **Revisão sobre funções de Pedotransferência (PTFs) e novos métodos de predição de Classes e atributos do solo**. Rio de Janeiro, RJ: Embrapa Solos, 2003. 50p. (Embrapa Solos. Documentos; n.45)
- MINSKY, M.; PAPERT, S. **Perceptrons**. 1. ed. Cambridge: The MIT Press, MA, 1969.
- MIRANDA, F.A.; FREITAS, S.R.C.; FAGGION, P.L. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. **Boletim de Ciências Geodésicas**, Paraná, v.15, n.3, p.428-443, 2009.
- MORAN, P.A.P. Notes on continuous stochastic phenomena. **Biometrika**, Oxford, v.37, n.1-2, p.17-23, 1950.
- NASCIMENTO, P.S.; BASSOI, L.H.; PAZ, V.P.S.; VAZ, C.M.P.; NAIME, J.M.; MANIERI, J.M. Estudo comparativo de métodos para a determinação da curva de retenção de água no solo. **Irriga**, Botucatu, v.15, n.2, p.193-207, 2010.
- NATHANS, L.L.; OSWALD, F.L.; NIMON, K. Interpreting Multiple Linear Regression: A Guidebook of variable importance. **Practical Assessment, Research, and Evaluation**, Massachusetts, v.17, n.9, p.1-20, 2012.
- NETTO, A.A. **Estimativa da retenção de água no solo a partir do uso de equipamentos não convencionais e funções de pedotransferência**. 2007. p.167. Tese (Doutorado) – Programa de Pós Graduação e Área de Concentração em Ciências da Engenharia Ambiental, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2007.

NGUYEN, P.M.; HAGHVERDI, A.; PUE, J. de; BOTULA, Y.D.; LE, K.V.; WAEGEMAN, W.; CORNELIS, W.M. Comparison of statistical regression and data-mining techniques in estimating soil water retention of tropical delta soils. **Biosystems Engineering**, San Diego, v.153, p.12-27, 2017.

NORTON, E.R.; SILVERTOOTH, J.C. **Field determination of permanent wilting point**. Tucson: The University of Arizona, 1998. Disponível em: <<http://www.ag.arizona.edu/pubs/crops/az1006/az10065d.htm>>. Acesso em: 03 dez. 2019.

NUNES, L.C.; TORRES, G.N.; AMORIM, R.S.S.; COUTO, E.G.; NÓBREGA, R.L.B.; GEROLD, G. Funções de pedotransferência para predição da umidade retida a potenciais específicos em solos do Estado de Mata Grosso. XXXV CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO, Natal, RN, 3., 2015, Natal. **Anais...** Natal: CBCS, 2015. p.1-3.

OLIVEIRA, L.B. de. **Determinação da umidade a 1/10 de atmosfera na terra fina pela “Mesa de Tensão”**. Serviço Nacional de Levantamento e Conservação de Solos, Boletim de Pesquisa n° 22. Rio de Janeiro, EMBRAPA-SNLCS, 1983, p.9. (EMBRAPA.SNLCS. Boletim de Pesquisa 22)

OLIVEIRA, L.B. de; MARTINS, A.M.C.M. Considerações sobre a umidade a 15 atmosferas e a umidade de murchamento (Método Fisiológico), em solos do Nordeste. **Pesq. Agropec. Bras.**, Brasília, v.1, n.1, p.91-95, 1966.

OLIVEIRA, L.B. Determinação da macro e microporosidade pela “mesa de tensão” em amostras de solo com estrutura indeformada. **Pesq. Agropec. Bras.**, Brasília, v.3, n.1, p.197-200, 1968.

OLIVEIRA, P.M.O.; SILVA, A.M.; COELHO, G.; SILVA, R.A. Análise comparativa da caracterização físico-hídrica de um Latossolo Vermelho distrófico *in situ* e em laboratório. **Irriga**, Botucatu, v.10, n.1, p.1-19, 2005.

OLIVEIRA, V.A.; CALIL, P.M.; NOGUEIRA, S.A.J.; MARCO, T.G.S. Levantamento de reconhecimento de alta intensidade dos solos, avaliação da aptidão agrícola e uso atual das terras da bacia de drenagem do córrego das Pedras e do ribeirão Jurubatuba no estado de Goiás. In: **PROJETO PROTEÇÃO E CONSERVAÇÃO DA BACIA DO RIO MEIA PONTE A MONTANTE DE GOIÂNIA NO ESTADO DE GOIÁS**. Goiânia, SEMARH/AGÊNCIARURAL, p.1-142, 2003.

OLIVEIRA, M.H.C. de. **Estimativa do teor de água no solo em bacia hidrográfica com redes neurais artificiais utilizando fatores físicos e climáticos**. 2014. 124p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental), Universidade Federal do Rio Grande do Sul, Instituto de Pesquisas Hidráulicas, Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Porto Alegre, RS, 2014.

OTTO, S.R.L.; ALCAIDE, M. Utilização do método TDR-tensiômetro na obtenção da curva de retenção de água no solo. **Rev Bras. Eng. Agríc. Ambien.**, Campina Grande, PB. v.5, n.2, p.256-269, 2001.

PACHEPSKY, Y.A.; TIMLIN, A.D.; VARALLYAY, G. Artificial neural networks to estimate soil water retention from easily measurable data. **Soil Science Society of America Journal**, Madison, v.60, n.3, p.727-733, 1996.

PÁDUA, E.J. de; GUERRA, A.R.; ZINN, Y.L. Modelagem da densidade do solo em profundidade sob vegetação nativa em Minas Gerais. **Revista Brasileira de Ciência do Solo**, Viçosa, v.39, n.3, p.725-736, 2015.

PAIGE, G.B.; HILLEL, D. Comparison of three methods for assessing soil hydraulic properties. **Soil Sci.**, Philadelphia, v.155, n.3, p.175-189, 1993.

PALMIERE, S.E. **Arquitetura e Topologias de Redes Neurais Artificiais**. EMBARCADOS. 2020. Disponível em: < <https://www.embarcados.com.br/redes-neurais-artificiais/>>. Acessado em: 24 abr. 2020.

PAN, Y.X.; WANG, X.P.; JIA, R.L.; CHEN, Y.W.; HE, M.Z. Spatial variability of surface soil moisture content in a re-vegetated desert area in Shapotou, Northern China. **Journal of Arid Environments**, London, v.72, n.9, p.1675-1683, 2008.

PAYDAR, Z.; CRESSWELL, H.P. Water retention in Australian soils. II Prediction using particle-size, bulk density and other properties. **Australian Journal of Soil Research**, Victoria, v.34, n.5, p.679-693, 1996.

PAZ, A.M.; CIPRIANO, D.; GONÇALVES, M.C.; PEREIRA, L.S. Funções de pedotransferência para a curva de retenção da água no solo. **Revista Brasileira de Ciências Agrárias**, Recife, v.32, n.1, p.337-343, 2009.

PEDRON, F. de A.; SAMUEL-ROSA, A.; DALMOLIN, R.S.D. Variação das características pedológicas e classificação taxonômica de argissolos derivados de rochas sedimentares. **R. Bras. Ci. Solo**, Viçosa, v.36, n.1, p.1-9, 2012.

PEQUENO, P.L. de L.; FAGUNDES, F. de P.; SANTOS, R.C. dos; SANTINI, C.L. do A.; RAMBO, M.A.; SCHLINDWEIN, J.A. de. Uso de funções de pedotransferência para estimativa da retenção de água em um Latossolo no Estado de Rondônia. **Revista Eletrônica de Engenharia Civil**, Goiânia, v.14, n.2, p.229-239, 2018.

PEREIRA JÚNIOR, L.C. **O uso da água em Goiás, potencialidade, demanda para irrigação por pivôs centrais e perspectivas**. 2017. 93p. Dissertação (Mestrado em Ciências Ambientais), Universidade Federal de Goiás, Goiânia, 2017.

PETERS, P.H.C.R.; SILVA, B.M.; OLIVEIRA, G.C de; SILVA JÚNIOR, J.J. da; SILVA, E.A. da; BARBOSA, S.M. Construction and performance of a simplified tension table for the determination of soil physicohydraulic attributes. *Amazonian Journal of Agricultural and Environmental Sciences*, **Rev. Cienc. Agrar.**, Belém, v.57, n.1, p.95-100, 2014.

PROCÓPIO, S.O.; SANTOS, J.B.; SILVA, A.A.; DONAGEMMA, G.K.; MENDONÇA, E.S. Ponto de murcha permanente de soja, feijão e plantas daninhas. **Planta Daninha**, Viçosa, v.22, n.1, p.35-41, 2004.

R CORE TEAM (2015). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing. Vienna, Austria. Disponível em: <<https://www.R-project.org/>>.

RAJKAI, K.; KABOS, S.; GENUCHTEN, M.Th. van; JANSSEN, P. Estimating water retention characteristics from the bulk density and particle size distribution of Swedish soils. **Soil Sci.**, Philadelphia, v.161, n.12, p.832-845, 1996.

RAMOS, H.M. **Funções de pedotransferência para estimativa da densidade e atributos físico-hídricos de solos do Estado do Piauí**. 2017. p.50. Tese (Doutorado em Agronomia Agricultura Tropical) – Universidade Federal do Piauí, Teresina, 2017.

RAWLS, W.J.; BRAKENSIEK, D.L.; SAXTON, K.E. Estimation of soil water properties. **Transactions of the ASAE**, St. Joseph, v.25, n.5, p.1316-1320, 1982.

RAWLS, W.J.; PACHEPSKY, Y.A.; RITCHIE, J.C.; SOBECKI, T.M.; BLOODWOERTH. Effect of soil organic carbon on soil water retention. **Geoderma**, Amsterdam, v.116, n.1-2, p.61-76, 2003.

REATTO, A.; MARTINS, E.S. Classes de solos em relação aos controles da paisagem do Bioma Cerrado. In: Scariot, A.; Souza-Silva, J.C.; Felfini, J.M. **Cerrado: Ecologia, Biodiversidade e Conservação**. 1.ed. Brasília-DF: Ministério do Meio Ambiente, p.47-59, 2005.

REGAZZI, A.J.; LEITE, H.G. **Análise de regressão: Teoria à aplicação em manejo florestal**. Viçosa, MG, 1992. 236p. (Apostila)

REICHARDT, K. **A água em sistemas agrícolas**. São Paulo: Editora Manole, 1987. 188p.

REICHARDT, K. Capacidade de campo. **Rev. Bras. Ci. Solo**, Viçosa, v.12, p.211-216, 1988.

REICHARDT, K. **Processos de transferência no sistema solo-planta-atmosfera**. 4. ed. Campinas: Fundação Cargill, 1985. 445p.

RESENDE, M.; ALBUQUERQUE, P.E.P.; COUTO, L. **A cultura do milho irrigado**. 1. ed. Brasília: Editora Embrapa. Embrapa Milho e Sorgo, 2003. 318p.

RIBON, A.A.; FILHO, J.T.; FERNANDES, K.L.; HERMÓGENES, V.T.L. Seleção de método estatístico para modelos de estimativa da qualidade física de solos argilosos. **Revista de Agricultura**, Piracicaba, v.89, n.1, p.29-40, 2014.

RICHARDS, B.G.; BAUMGARTL, T.; HORN, R. Modelling coupled processes in structured unsaturated soils – Theory and examples. **Advances in Geocology**, Reiskirchen, v.32, n.47, p.175-190, 2000.

RICHARDS, L.A.; FIREMAN, M. Pressure plate apparatus for measuring moisture sorption and transmission by soils. **Soil Sci.**, Philadelphia, v.56, n.6, p.395-404, 1943.

ROCHA, I. J. F. **Estimativa do índice de área foliar para cultura irrigada por meio de pivô central utilizando imagens de sensoriamento remoto e redes neurais artificiais**.

2019. 107p. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás. Anápolis, 2019.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v.65, n.6, p.386-408, 1958.

ROSSATO, L.; ALVALÁ, R.C. dos S.; TOMASELLA, J. Climatologia da umidade do solo no Brasil. In: XII CONGRESSO BRASILEIRO DE METEOROLOGIA. 6., 2002, Foz de Iguaçu. **Anais...** Foz de Iguaçu, 2002. p.1910-1915.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning internal representations by error Propagation. In: Rumelhart, D.E. and McClelland, J.L. (eds.), **Parallel Distributed Processing: Explorations in the Microstructure of Cognition I**, MIT Press, Cambridge MA, 1986, p. 318-362.

RUSSELL, M.B.; RICHARDS, LA. The determination of soil moisture energy relations by centrifugation. **Soil Sci. Soc. Am. J.**, Madison, v.3, p.65-9, 1938.

SÁ, P.C.C.; VALE, C.N.C.; MAIA, C.E.; LEVIEN, S.L. A. Índice S e área sob a curva de retenção de água para avaliar qualidade física do solo. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.4, n.2, p.110-114, 2010.

SALES, M.A.M.P.; SILVA, E.P. da; ANDRADE, K.R.; SILVA SOUZA, W.L. da; ALMEIDA, B.G. de. Umidade do solo sob uso da mesa de tensão e do funil de Haines. In: XIII JORNADA DE ENSINO, PESQUISA E EXTENSÃO – JEPEX. 3., 2013, Recife. **Anais...** UFRPE: Recife, 2013. p.1-3.

SAMPAIO, F.M.T.; FERREIRA, M.M.; OLIVEIRA, M.S.; ALMEIDA, A.C.; JOSÉ, M.R. Variabilidade espacial da umidade de um Latossolo Vermelho-Amarelo sob plantio direto. **Eng. Agri.**, Jaboticabal, v.30, n.5, p.854-861, 2010.

SANCHEZ, P.A. **Suelos del trópico: características y manejo**. San José: IICA, 1981. 634p. (IICA. Libros y Materiales Educativos, 48).

SANO, E.E.; DAMBRÓS, L.A.; OLIVEIRA, G.; BRITES, R.S. Padrões de cobertura de solos do Estado de Goiás. In: Ferreira Júnior, L. G. **A encruzilhada socioambiental: biodiversidade, economia e sustentabilidade no Cerrado**. Goiânia: Editora UFG, 2008a. Cap.3, p.91-106.

SANO, E.E.; ROSA, R.; BRITO, J.L; FERREIRA JÚNIOR, L.G. Mapeamento semidetalhado (escala de 1:250.000) da cobertura vegetal antrópica do bioma Cerrado. **Pesquisa Agropecuária Brasileira**, Brasília, v.43, n.1, p.153-156, 2008b.

SANTOS, H.G. dos; JACOMINE, P.K.T.; ANJOS, L.H.C. dos; OLIVEIRA, V.A. de; LUMBREAS, J.F.; COELHO, M.R.; ALMEIDA, J.A. de; ARAUJO FILHO, J.C. de; OLIVEIRA, J.B. de; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. Empresa Brasileira de Pesquisa Agropecuária. Embrapa Solos – Livro técnico (INFOTECA-E). Ministério da Agricultura, Pecuária e Abastecimento. 5ed., ver. e ampl. – Brasília, DF: Embrapa, 2018. 356p. :il. color.

SANTOS, R.D. dos; LEMOS, R.C. de; SANTOS, H.G. dos; KER, J.C.; ANJOS, L.H.C. dos. **Manual de descrição e coleta de solo no campo**. 5. ed. rev. e ampl. Viçosa: Sociedade Brasileira de Ciência de Solo, 2005. 100p.

SANTOS, T.C.C.; CÂMARA, J.B.D. **GEO Brasil, 2002. Perspectivas do Meio Ambiente no Brasil**. Brasília: Edição IBAMA, 2002. 440p. Disponível em: <http://www.ibama.gov.br/sophia/cnia/site_cnia/geo_brasil_2002.pdf>.

SAS. Analytics Software & Solutions. SAS Insights. **Insights sobre análise de dados. Redes Neurais – O que são e qual sua importância?**. 2020. Disponível em: <https://www.sas.com/pt_br/insights/analytics/neural-networks.html>. Acesso em: 14 abr. 2020.

SCHNEIDER, P.R. **Análise de regressão aplicada à Engenharia Florestal**. Santa Maria: ed. UFSM/CEPEF, 1998. 236p.

SCHREINER, D.T.; BRAGA, F.V.A.; VOGELMANN, E.S.; RODRIGUES, M.F.; OLIVEIRA, A.E.; PREVEDELLO, J.; REICHERT, J.M. Efeito da compactação do solo na retenção de água em uma Toposequência argissolos-gleissolo no RS. In: XXXIII CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO. 4., 2010, Uberlândia. **Resumo Expandido...** Uberlândia: SBCS, 2010. p.1-4.

SCHULTZ, D.P.; SCHULTZ, S.E. **História da psicologia moderna**. 16. ed. São Paulo: Cultrix, 1992. 439p.

SECCO, D.; ROS, C.O. da; SECCO, J.K.; FIORIN, J.E.; Atributos físicos e produtividade de culturas em um Latossolo Vermelho Agiloso sob diferentes sistemas de manejo. **Revista Brasileira de Ciência do Solo**, Viçosa, v.29, n.3, p.407-414, 2005.

SHAPIRO, S.S. e WILK, M.B. An analysis of variance test for normality (complete sample). **Biometrika**, Great Britain, v.52, n.3-4, p.591-611, 1965.

SIEG. **Camadas**. MAPA Solos. Mapa color. Escala 1:1.000.000. 2005. Disponível em: <<http://www.sieg.go.gov.br/siegdownloads/>>. Aceso em: 12 fev. 2020.

SILVA JÚNIOR, R.M.V.; CRUZ, G.H.T.; SILVA, J. de O.; COSTA e SILVA, S.M. da; MOTA, T.R.; DEVILLA, I.A. Plano de manejo da irrigação por pivô central para a cultura da Soja em Sítio do Mato – BA. In: IV CONGRESSO DE ENSINO, PESQUISA E EXTENSÃO, 11., 2017, Pirenópolis. **Trabalho Completo...** Pirenópolis: UEG, 2017. p.1-10.

SILVA, A.P. da; TORMENA, C.A.; FIDALSKI, J.; IMHOFF, S. Funções de pedotransferência para as curvas de retenção de água e de resistência do solo à penetração. **Rev. Bras. Ci. Solo**, Viçosa, v.32, n.1, p.1-10, 2008.

SILVA, C.A.M. **Exploração de métodos de seleção de variáveis pela técnica de regressão logística para análise de dados epidemiológicos**. 2006. [s.n.] Dissertação (Mestrado) – Universidade Estadual de Campinas, Faculdade de Ciências Médicas, Campinas, SP, 2006.

SILVA, D.O.M. da. **Validação de um sensor de determinação da umidade do solo para o manejo da irrigação**. 2013. p.63. Dissertação (Mestrado em Engenharia Agrícola), Universidade Federal do Vale do São Francisco, Juazeiro, 2013.

SILVA, I.N. da; SPATTI, D.H.; FLAUZINO, R.A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. 2. ed. São Paulo: Artliber, 2016. 431p.

SILVA, M.L.M. da; BINOTI, D.H.B.; GLERIANI, J.M.; LEITE, H.G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Rev. Árvore**, Viçosa, v.33, n.6, p.1133-1139, 2009.

SILVA, V.R.; REINERT, D.J.; REICHERT, J.M. Fatores controladores da compressibilidade dos solos Argissolo Vermelho-Amarelo distrófico arênico e Latossolo Vermelho distrófico típico. I. Estado Inicial de compactação. **R. Bras. Ci. Solo**, v.26, n.1, p.1-8, 2002.

SLATYER, R. O. The significance of the permanent wilting percentage in studies of plant and soil water relations. **Botanical Review**, New York, v.23, n.10, p.585-636, 1957.

SMETTEM, K.R.J.; OLIVER, Y.M.; HENG, L.K.; BRISTOW, K.L.; FORD, E.J. Obtaining soil hydraulic properties for water balance and leaching models from survey data 1. Water retention. **Australian Journal of Soil Research**, East Melbourne, v.50, n.2, p.283-289, 1999.

SMITH, K.A.; MULLINS, C.E. **Soil and environmental analysis: Physical methods**. 2. ed. Revised and Expanded. New York: CRC Press, 2000. 660p.

SOARES, F.C. **Uso de diferentes metodologias na geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul**. 2013. 200p. Tese (Doutorado em Engenharia Agrícola), Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, Santa Maria, RS, 2013.

SOIL SURVEY STAFF. Department of Agriculture. Soil Survey Division. Soil Conservation Service. Revised and enlarged edition. **Soil survey manual**. Washington, D.C. 1993. p.437. (USDA. Agriculture Handbook, 18).

SOIL SURVEY STAFF. **Keys to Soil Taxonomy**. 12. ed. Washington: USDA-Natural Resources Conservation Service, 2014. 372p.

SOIL SURVEY STAFF. **Soil Taxonomy: A Basic System of Soil Classification for Making and Interpreting Soil Surveys**. 2. ed. Natural Resources Conservation Service. U.S. Department of Agriculture Handbook 436. 1999. 886p.

SOLOTEST. **CONJUNTO P/ RETENÇÃO DE ÁGUA MET HOLAND**. 2020. Disponível em: <<https://www.solotest.com.br/novo/produtos/conjunto-p--retencion-de-agua-met-holand/4.863.250>>. Acesso em: 24 mar. 2020.

SONDATERRA. **PRODUTOS – Soluções em Equipamentos Agrônômicos**. Piracicaba, 2020. Disponível em: <<http://www.sondaterra.com/conteudo-6-produtos.xhtml>>. Acesso em: 24 mar. 2020.

SOUSA, D.M.G. de e LOBATO, E. **Latossolos. Ministério da Agricultura, Pecuária e Abastecimento**. EMBRAPA. Agência de Informação Embrapa Bioma Cerrado. Brasília, DF, 2020. Disponível em:

<http://www.agencia.cnptia.embrapa.br/Agencia16/AG01/arvore/AG01_96_10112005101956.html>. Acesso em: 04 mai. 2020.

SOUZA, C.F.; MATSURA, E.E. Avaliação de sondas de TDR multi-haste segmentadas para estimativa da umidade do solo. **R. bra. eng. ambiente.**, Campina Grande, v.6, n.1, p.63-68, 2002.

SOUZA, C.S.; OLIVEIRA, F.A.; SILVA, I.F.; AMORIM NETO, M.S. Avaliação de métodos de determinação de água disponível em solo cultivado com algodão. **Pesq. Agropec. Bras.**, Brasília, v.37, n.3, p.337-341, 2002.

SOUZA, E.J. de; CUNHA, F.F. da; MAGALHÃES, F.F.; SILVA, T.R. da; BORGES, M.C.R.Z.; ROQUE, C.G. Métodos para estimativa da umidade do solo na Capacidade de Campo. **R. Ci. Agro-Ambien.**, Alta Floresta, v.11, n.1, p.43-50, 2013.

SOUZA, S.I.V.; MARTINS, F.G.; ALVIM-FERRAZ, M.C.M.; PEREIRA, M.C. Multiple linear regression and artificial neural networks based on principal components to predict ozone concentrations. **Environmental Modelling & Software**, Oxford, v.22, n.1, p.97-103, 2007.

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

STERMBER, J.C.; STILLS, H.S.; SCHWENDEMAN, R.H. Spectrophotometric analysis of multi component systems using the least squares method in matrix form. **Analytical Chemistry**, Washington, v.32, n.1, p.84-90, 1960.

STONE, L.F.; SILVEIRA, P.M. Efeitos do sistema de preparo e da rotação de culturas na porosidade e densidade do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v.25, n.2, p.395-401, 2001.

SUN, Y.; LI, L.; SCHULZE LAMMERS, P.; ZENG, Q.; LIN, J. SCHUMMAN, H. A solar powered wireless cell for dynamically monitoring soil water content. *Computers and Electronics in Agriculture*. **Computers and Electronics in agriculture**, Oxford, v.69, n.1, p.19-23, 2009.

SYKES, D. J. Reconsideração do conceito da umidade de murchamento permanente. **Turrialba**, San José, v.19, n.4, p.525-530, 1969.

TABACHNICK, B.; FIDELL, L.S. **Using multivariate statistics**. 3. ed. New York: Harper Collins, 1996. 880p.

TAFNER, M.A. **Redes Neurais Artificiais: Aprendizado e Plasticidade**. Universidade Estadual de Campinas, Rev. Cérebro e Mente, 1998. Disponível em: <<http://www.cerebromente.org.br/n05/tecnologia/rna.htm>>. Acessado em: 24 abr. 2020.

TEIXEIRA, W.G.; BHERING, S.B. Retenção de água no solo pelos métodos da Mesa de Tensão e da Câmara de Richards. In: Teixeira, P.L.; Donagemma, G.K. **Manual de métodos de análise de solo**. Brasília: Embrapa, 2017. Cap.4, p.43-55.

THOMAS, M.D.; HARRIS, K. The moisture equivalent of soils. **Soil Sci.**, Philadelphia, v.26, n.6, p.411-24, 1925.

TOMASELLA, J.; HODNETT, M.G. Estimating soil water retention characteristics from limited data in Brazilian Amazonia. **Soil Sci.**, **Philadelphia**, v.163, n.3, p.190-202, 1998.

TOMASELLA, J.; HODNETT, M.G.; ROSSATO, L. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. **Soil Sci. Soc. Am. J.**, Madison, v.64, n.1, p.327-338, 2000.

TORMENA, C.A.; VIDIGAL FILHO, P.S.; GONÇALVES, A.C.A.; ARAÚJO, M.A.; PINTO, J.C. Influência de diferentes sistemas de preparo do solo nas propriedades físicas de um Latossolo Vermelho distroférico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.8, n.1, p.65-71, 2004.

TORMENA, C.A.; SILVA, A.P. Incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo. **R. Bras. Ci. Solo**, Viçosa, v.26, n.2, p.305-314, 2002.

TRAUTNER, A.; van den AKKER, J.J.H.; FLEIGE, H.; ARVIDSSON, J.; HORN, R. A subsoil compaction database: Its development, structure and content. **Soil and Tillage Research**, Amsterdam, v.73, n.1-2, p.9-13, 2003.

TSEGAYE, T.D.; TEDESSE, W.; COLEMAN, T.L.; JACKSON, T.J.; TEWOLDE, H. Calibration and modification of impedance probe for near surface soil moisture measurements. **Canadian J. Soil Sci.**, Ottawa, v.84, n.2, p.237-243, 2004.

TUKEY, J.W. Box-and-Whisker Plots. In: TUKEY, J.W. **Exploratory Data Analysis**. Reading, MA: Addison Wesley; 1977. cap.2, p.39-43.

VALENTINI, C.M.A.; ESPINOSA, M.M.; PAULO, S.R. de. Estimativa do efluxo de CO₂ do solo, por meio de regressão múltipla, para floresta de transição no Noroeste de Mato Grosso. **Cerne**, Lavras, v.14, n.1, p.9-16, 2008.

VAN DEN BERG, M.; KLAMT, E.; VAN REUWIJK, L.P.; SOMBROEK, W.G. Pedotransfers functions for the estimation of moisture retention characteristics of Ferralsols and related soils. **Geoderma**, Amsterdam, v.78, n.3-4, p.161-180, 1997.

Van GENUCHTEN, M.T.A. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Sci. Soc. Am. J.**, Madison, v.44, n.5, p.892-897, 1980.

VANZELA, L.S.; ANDRADE, M.C.N. de. **Manejo da Irrigação Via Solo**. UNESP. Esquema didático da capacidade de água disponível. Disponível em: <<http://www2.feis.unesp.br/irrigacao/lsvmnejoirrigacao.htm>>. Acesso em: 15 fev. 2020.

VAZ, C.M.P.; NAIME, J.M.; MACEDO, A.; MELLO, S. **Análise granulométrica por raios gama**. São Carlos: EMBRAPA/CNDIA, 1997. (Boletim de Pesquisa, n.5, 1997. 13p.)

VEGA, M.A.A. **Um estudo comparativo de técnicas de Pruning para Redes Neurais Artificiais**. 1999. Monografia (Doutorado em Ciências da computação e matemática

computacional), Instituto de Ciências Matemáticas e de Computação, ICMC, USP, São Carlos, 1999.

VEIHMEYER, F.J.; HENDRICKSON, A.H. Methods of measuring field capacity and permanente wilting percentages of soils. **Soil Sci.**, Philadelphia, v.68, n.1, p.75-94, 1949.

VEIHMEYER, F.J.; HENDRICKSON, A.H. Soil moisture at permanent wilting of plants. **Plant Physiology**, Rockville, v.3, n.3, p.355–357, 1928.

VEIHMEYER, F.J.; HENDRICKSON, A.H. The moisture equivalent as a measure of the field capacity of soils. **Soil Sci.**, Philadelphia, v.32, n.3, p.181-193, 1931.

VEIMEYER, F.J.; ISRAELSEN, O.W.; CONRAD, J.P. **The moisture equivalent as influenced by the amount of soil used in its determination.** Berkeley: Univ. California Printing Office, 1924. (Univ. California. College of Agriculture. Agric. Exp. Stn. Technical Paper, 16).

VERECKEN, H.; MAES, H.; FEYEN, J.; DARIUS, P. Estimating the soil moisture retention characteristics from texture, bulk density, and carbon content. **Soil Sci.**, Philadelphia, v.148, n.6, p.389-403, 1989.

VIEIRA, S.R.; CASTRO, O.M. Determinação em laboratório, de curvas de retenção de água com tensiômetros. **Revista Brasileira de Ciência do Solo**, Campinas, v.11, n.2, p.87-90, 1987.

VIELMO, A.L. **Limite superior da retenção da água no solo: método de campo e método de estimativa.** 2008. p.82. Dissertação (Mestrado) – Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, RS, 2008.

VIONE, M.T. **Modelagem matemática da evaporação da água do solo.** 2007. p.76. Dissertação Mestrado em Modelagem Matemática), Departamento de Física, Estatística e Matemática da Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Unijuí, 2007.

WARD A.D.; TRIMBLE, S.W. **Environmental Hydrology.** 2. ed. Boca Raton: Lewis Publishers, 2004. 475p.

WARRICK, A.W.; NIELSEN, D.R. Spatial variability of soil physical properties in the field. In: Hillel, D. **Applications of soil physics.** 1. ed. New York: Academic Press, 1980. p.319-344.

WATSON, K.K. An instantaneous profile method for determining the hydraulic conductivity of unsaturated porous materials. **Water Resources Research**, Washington, v.2, n.4, p.709-715, 1966.

WIDROW, B.; HOFF, M.E. **Adaptive switching circuits.** IRE WESCON Convention Record. New York: Institute of Radio Engineers, 1960. cap.4, p.96-104.

WILLIAMS J.; PREBBLE, J.E.; WILLIAMS, W.T.; HIGNETT, C.T. The influence of texture, structure and clay mineralogy on the soil moisture characteristic. **Australian Journal of Soil Research**, East Melbourne, v.21, n.1, p.15-32, 1983.

WILLIAMS, J.; ROSS, P.J.; BRISTOW, K.L. Prediction of the Campbell water retention function from texture, structure and organic matter. In: Van Genuchten, M.T.H.; Leij, F.J.; Lund, L.J. (Eds.) **Proceedings of the international workshop on indirect methods for estimating the hydraulic properties of unsaturated soils**. Riverside, CA: University of California, p.427-441, 1992.

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

WOSTEN, J.H.M.; GENUHTEN, M.Th. van. Using texture and other soil properties to predict the unsaturated soil hydraulic function. **Soil Sci. Soc. Am. J.**, Madison, v.52, n.6, p.1762-1770, 1988.

YI, Z.; TAN, K.K. **Convergence analysis of recurrent neural networks**. Springer Science & Business Media, 2013. v.13, p.233. (eBook)

7. APÊNDICES

APÊNDICE 1 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Jaraguá - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,308	2,048	19,532	25,066	9,180	0,870	0,066
Dp (g cm ⁻³)	2,736	0,074	2,592	2,850	2,710	0,970	0,907
Ds (g cm ⁻³)	1,166	0,095	1,018	1,300	8,188	0,934	0,418
Areia (g kg ⁻¹)	330,507	46,082	220,873	390,423	13,943	0,925	0,328
Silte (g kg ⁻¹)	96,635	58,320	21,801	210,957	60,351	0,947	0,589
Argila (g kg ⁻¹)	572,857	80,236	407,272	663,707	14,006	0,919	0,281
Pt (m ³ m ³)	0,543	0,043	0,472	0,604	7,907	0,931	0,389
Macro (m ³ m ³)	0,050	0,024	0,005	0,079	47,718	0,915	0,247
Micro (m ³ m ³)	0,493	0,038	0,422	0,547	7,632	0,943	0,541
CC (g kg ⁻¹)	355,108	58,386	256,312	429,492	16,442	0,888	0,111
PMP (g kg ⁻¹)	125,020	11,089	108,009	145,519	8,870	0,957	0,743

APÊNDICE 2 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Jaraguá - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	21,390	2,653	17,945	23,446	10,118	0,831	0,022
Dp (g cm ⁻³)	2,735	0,078	2,611	2,819	2,413	0,945	0,561
Ds (g cm ⁻³)	1,241	0,120	1,096	1,417	7,355	0,959	0,766
Areia (g kg ⁻¹)	316,085	113,506	252,509	363,909	12,145	0,908	0,199
Silte (g kg ⁻¹)	84,652	67,266	26,106	135,409	34,601	0,918	0,266
Argila (g kg ⁻¹)	599,263	109,571	519,657	663,172	7,903	0,923	0,315
Pt (m ³ m ³)	0,520	0,049	0,491	0,546	3,495	0,950	0,641
Macro (m ³ m ³)	0,037	0,016	0,005	0,070	51,682	0,957	0,746
Micro (m ³ m ³)	0,483	0,049	0,436	0,511	5,285	0,884	0,098
CC (g kg ⁻¹)	345,817	53,552	294,569	375,719	6,509	0,932	0,405
PMP (g kg ⁻¹)	110,257	33,157	92,825	136,246	11,220	0,963	0,832

APÊNDICE 3 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Goianésia - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	23,152	2,454	20,369	26,722	10,598	0,832	0,022
Dp (g cm ⁻³)	2,795	0,042	2,744	2,891	1,495	0,922	0,300
Ds (g cm ⁻³)	1,261	0,092	1,108	1,385	7,304	0,887	0,107
Areia (g kg ⁻¹)	265,085	35,150	220,129	329,591	13,260	0,937	0,461
Silte (g kg ⁻¹)	106,552	28,887	64,129	154,764	27,111	0,967	0,880
Argila (g kg ⁻¹)	628,363	47,890	556,654	687,930	7,621	0,836	0,025
Pt (m ³ m ³)	0,512	0,043	0,448	0,583	8,412	0,954	0,692
Macro (m ³ m ³)	0,013	0,013	0,002	0,043	100,555	0,787	0,007
Micro (m ³ m ³)	0,499	0,040	0,583	0,574	8,012	0,946	0,572
CC (g kg ⁻¹)	358,761	39,849	289,238	434,847	11,107	0,984	0,995
PMP (g kg ⁻¹)	124,809	15,188	103,446	156,366	12,169	0,964	0,840

APÊNDICE 4 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Goianésia - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,581	2,613	19,593	26,555	11,571	0,849	0,035
Dp (g cm ⁻³)	2,799	0,045	2,733	2,870	1,596	0,942	0,526
Ds (g cm ⁻³)	1,304	0,107	1,067	1,476	8,229	0,905	0,186
Areia (g kg ⁻¹)	252,702	36,707	196,507	309,097	14,526	0,940	0,492
Silte (g kg ⁻¹)	115,483	61,348	39,474	218,791	53,123	0,923	0,313
Argila (g kg ⁻¹)	631,816	37,656	564,447	681,161	5,960	0,946	0,580
Pt (m ³ m ³)	0,505	0,045	0,439	0,574	8,993	0,938	0,466
Macro (m ³ m ³)	0,011	0,007	0,002	0,026	69,770	0,882	0,092
Micro (m ³ m ³)	0,495	0,045	0,574	0,572	9,184	0,928	0,361
CC (g kg ⁻¹)	347,583	69,172	249,169	496,902	19,901	0,899	0,153
PMP (g kg ⁻¹)	119,835	14,740	101,939	156,522	12,301	0,859	0,047

APÊNDICE 5 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Vila Propício - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	20,301	1,798	17,781	23,115	8,855	0,923	0,315
Dp (g cm ⁻³)	2,671	0,047	2,607	2,772	1,763	0,943	0,542
Ds (g cm ⁻³)	1,366	0,044	1,297	1,435	3,232	0,955	0,713
Areia (g kg ⁻¹)	497,166	15,236	470,526	528,400	3,065	0,966	0,863
Silte (g kg ⁻¹)	148,693	53,330	72,089	256,818	35,866	0,958	0,752
Argila (g kg ⁻¹)	354,141	47,400	247,345	429,855	13,384	0,959	0,762
Pt (m ³ m ³)	0,462	0,017	0,442	0,507	3,785	0,885	0,101
Macro (m ³ m ³)	0,020	0,014	0,007	0,051	67,234	0,870	0,065
Micro (m ³ m ³)	0,442	0,022	0,419	0,499	4,931	0,838	0,026
CC (g kg ⁻¹)	294,149	23,690	249,501	335,881	8,054	0,976	0,964
PMP (g kg ⁻¹)	59,634	6,656	47,796	70,955	11,162	0,984	0,995

APÊNDICE 6 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Vila Propício - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	19,508	1,471	17,560	21,325	7,541	0,864	0,055
Dp (g cm ⁻³)	2,659	0,049	2,581	2,753	1,859	0,958	0,753
Ds (g cm ⁻³)	1,437	0,106	1,286	1,636	7,407	0,940	0,497
Areia (g kg ⁻¹)	502,175	16,237	469,365	535,901	3,233	0,956	0,730
Silte (g kg ⁻¹)	128,372	37,285	56,206	200,757	29,044	0,972	0,934
Argila (g kg ⁻¹)	369,452	31,009	329,878	407,893	8,393	0,856	0,044
Pt (m ³ m ³)	0,421	0,046	0,370	0,495	10,882	0,854	0,041
Macro (m ³ m ³)	0,027	0,016	0,010	0,062	57,882	0,905	0,181
Micro (m ³ m ³)	0,394	0,040	0,349	0,485	10,287	0,870	0,065
CC (g kg ⁻¹)	252,449	34,622	210,774	330,452	13,714	0,914	0,237
PMP (g kg ⁻¹)	59,172	8,216	47,030	70,352	13,885	0,918	0,272

APÊNDICE 7 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Carmo do Rio Verde - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	19,403	1,129	17,637	21,611	5,819	0,975	0,958
Dp (g cm ⁻³)	2,739	0,028	2,700	2,781	1,013	0,943	0,531
Ds (g cm ⁻³)	1,295	0,117	1,129	1,470	9,008	0,920	0,284
Areia (g kg ⁻¹)	427,382	33,708	360,137	476,655	7,887	0,962	0,810
Silte (g kg ⁻¹)	103,432	85,034	3,781	295,174	82,212	0,888	0,110
Argila (g kg ⁻¹)	469,186	74,985	306,342	562,983	15,982	0,932	0,398
Pt (m ³ m ³)	0,489	0,040	0,431	0,548	8,083	0,948	0,613
Macro (m ³ m ³)	0,049	0,029	0,021	0,124	59,567	0,838	0,026
Micro (m ³ m ³)	0,440	0,035	0,388	0,485	7,850	0,907	0,195
CC (g kg ⁻¹)	299,286	35,819	241,728	348,168	11,968	0,917	0,265
PMP (g kg ⁻¹)	72,547	6,913	61,327	86,931	9,528	0,967	0,872

APÊNDICE 8 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Carmo do Rio Verde - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	18,491	1,060	17,334	20,742	5,735	0,899	0,155
Dp (g cm ⁻³)	2,660	0,049	2,553	2,710	1,854	0,834	0,024
Ds (g cm ⁻³)	1,491	0,086	1,374	1,623	5,752	0,924	0,317
Areia (g kg ⁻¹)	403,203	34,662	343,441	459,468	8,597	0,974	0,950
Silte (g kg ⁻¹)	215,091	89,600	36,893	379,412	41,657	0,946	0,584
Argila (g kg ⁻¹)	381,705	79,376	259,041	552,419	20,795	0,952	0,665
Pt (m ³ m ³)	0,420	0,028	0,391	0,491	6,651	0,850	0,036
Macro (m ³ m ³)	0,024	0,014	0,010	0,056	57,185	0,871	0,068
Micro (m ³ m ³)	0,396	0,020	0,373	0,448	5,005	0,846	0,033
CC (g kg ⁻¹)	242,348	22,552	213,804	280,459	9,306	0,939	0,488
PMP (g kg ⁻¹)	60,792	6,785	50,669	70,514	11,161	0,938	0,477

APÊNDICE 9 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Campo Limpo - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	24,907	1,085	23,400	27,503	4,357	0,893	0,127
Dp (g cm ⁻³)	2,671	0,030	2,625	2,718	1,135	0,922	0,299
Ds (g cm ⁻³)	1,213	0,090	1,081	1,358	7,428	0,946	0,584
Areia (g kg ⁻¹)	382,213	33,010	317,294	424,973	8,636	0,952	0,670
Silte (g kg ⁻¹)	177,638	75,485	98,796	347,809	42,494	0,891	0,122
Argila (g kg ⁻¹)	440,149	67,679	302,087	531,395	15,376	0,923	0,312
Pt (m ³ m ³)	0,537	0,041	0,475	0,605	7,588	0,955	0,717
Macro (m ³ m ³)	0,040	0,015	0,021	0,062	36,661	0,888	0,110
Micro (m ³ m ³)	0,496	0,030	0,448	0,545	6,113	0,967	0,875
CC (g kg ⁻¹)	355,692	45,978	298,945	450,180	12,926	0,936	0,447
PMP (g kg ⁻¹)	112,284	8,533	101,172	126,277	7,600	0,941	0,510

APÊNDICE 10 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Campo Limpo - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,495	2,643	18,694	26,716	11,749	0,867	0,061
Dp (g cm ⁻³)	2,741	0,032	2,696	2,793	1,179	0,932	0,404
Ds (g cm ⁻³)	1,333	0,069	1,214	1,410	5,161	0,867	0,060
Areia (g kg ⁻¹)	355,015	30,643	303,839	388,894	8,632	0,872	0,069
Silte (g kg ⁻¹)	116,316	34,067	60,144	177,254	29,288	0,972	0,933
Argila (g kg ⁻¹)	528,669	41,708	440,713	580,437	7,889	0,938	0,467
Pt (m ³ m ³)	0,475	0,033	0,416	0,524	6,995	0,975	0,952
Macro (m ³ m ³)	0,030	0,012	0,018	0,062	39,377	0,797	0,009
Micro (m ³ m ³)	0,445	0,034	0,382	0,500	7,669	0,987	0,999
CC (g kg ⁻¹)	286,509	47,308	192,657	362,557	16,512	0,911	0,221
PMP (g kg ⁻¹)	120,163	8,903	111,717	136,854	7,409	0,824	0,018

APÊNDICE 11 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Jesúpolis - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	21,426	0,901	19,773	23,535	4,205	0,926	0,337
Dp (g cm ⁻³)	2,688	0,045	2,586	2,758	1,662	0,950	0,636
Ds (g cm ⁻³)	1,332	0,086	1,183	1,430	6,428	0,904	0,176
Areia (g kg ⁻¹)	348,210	22,818	309,195	386,401	6,553	0,954	0,697
Silte (g kg ⁻¹)	258,322	55,409	185,747	333,726	21,450	0,873	0,072
Argila (g kg ⁻¹)	393,468	63,725	310,905	477,473	16,196	0,856	0,043
Pt (m ³ m ³)	0,488	0,038	0,437	0,576	7,757	0,932	0,401
Macro (m ³ m ³)	0,025	0,015	0,011	0,063	58,168	0,840	0,028
Micro (m ³ m ³)	0,463	0,028	0,424	0,513	5,940	0,933	0,412
CC (g kg ⁻¹)	310,874	26,153	282,638	381,756	8,413	0,816	0,014
PMP (g kg ⁻¹)	143,035	15,863	121,913	163,531	11,090	0,800	0,009

APÊNDICE 12 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Jesúpolis - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	19,801	0,994	18,683	21,650	5,021	0,877	0,079
Dp (g cm ⁻³)	2,723	0,033	2,658	2,763	1,227	0,930	0,375
Ds (g cm ⁻³)	1,422	0,100	1,301	1,593	7,037	0,916	0,256
Areia (g kg ⁻¹)	307,767	52,658	200,271	377,359	17,110	0,955	0,704
Silte (g kg ⁻¹)	172,831	59,745	87,050	266,492	34,569	0,941	0,510
Argila (g kg ⁻¹)	519,402	85,457	397,037	694,959	16,453	0,951	0,645
Pt (m ³ m ³)	0,444	0,041	0,343	0,509	9,319	0,926	0,342
Macro (m ³ m ³)	0,016	0,006	0,005	0,025	35,923	0,937	0,457
Micro (m ³ m ³)	0,427	0,042	0,325	0,484	9,782	0,910	0,212
CC (g kg ⁻¹)	272,945	31,265	194,020	311,507	11,455	0,881	0,091
PMP (g kg ⁻¹)	165,156	8,511	147,433	179,854	5,153	0,933	0,411

APÊNDICE 13 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Ouro Verde - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,870	1,554	19,905	25,656	6,793	0,984	0,994
Dp (g cm ⁻³)	2,719	0,056	2,629	2,817	2,053	0,957	0,734
Ds (g cm ⁻³)	1,326	0,187	1,005	1,564	14,077	0,909	0,204
Areia (g kg ⁻¹)	492,404	96,852	344,101	635,925	19,669	0,938	0,473
Silte (g kg ⁻¹)	73,727	34,028	26,846	129,031	46,154	0,939	0,491
Argila (g kg ⁻¹)	433,869	119,048	238,329	610,429	27,439	0,937	0,459
Pt (m ³ m ³)	0,514	0,064	0,392	0,593	12,525	0,934	0,426
Macro (m ³ m ³)	0,056	0,019	0,022	0,097	34,202	0,963	0,639
Micro (m ³ m ³)	0,458	0,067	0,342	0,549	14,537	0,950	0,825
CC (g kg ⁻¹)	293,293	63,715	177,149	387,145	21,724	0,952	0,659
PMP (g kg ⁻¹)	104,353	19,254	65,959	138,511	18,450	0,974	0,950

APÊNDICE 14 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Ouro Verde - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,161	1,550	19,819	25,318	6,993	0,955	0,703
Dp (g cm ⁻³)	2,761	0,074	2,607	2,898	2,681	0,965	0,850
Ds (g cm ⁻³)	1,445	0,156	1,261	1,751	10,808	0,937	0,458
Areia (g kg ⁻¹)	479,501	81,373	327,998	660,284	16,970	0,951	0,644
Silte (g kg ⁻¹)	93,175	39,032	41,159	159,056	41,891	0,952	0,672
Argila (g kg ⁻¹)	427,324	74,050	297,716	572,948	17,329	0,989	1,000
Pt (m ³ m ³)	0,461	0,055	0,324	0,526	11,957	0,886	0,105
Macro (m ³ m ³)	0,039	0,025	0,016	0,110	65,264	0,771	0,034
Micro (m ³ m ³)	0,422	0,057	0,283	0,477	13,461	0,847	0,004
CC (g kg ⁻¹)	255,538	64,578	119,945	321,999	25,271	0,847	0,033
PMP (g kg ⁻¹)	122,979	25,204	78,637	166,635	20,495	0,973	0,938

APÊNDICE 15 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Anápolis - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	23,999	0,820	23,004	25,777	3,418	0,921	0,295
Dp (g cm ⁻³)	2,650	0,109	2,501	2,838	4,106	0,945	0,562
Ds (g cm ⁻³)	1,262	0,070	1,152	1,365	5,564	0,925	0,328
Areia (g kg ⁻¹)	359,257	37,274	318,883	421,683	10,375	0,895	0,137
Silte (g kg ⁻¹)	83,026	45,447	27,062	183,667	54,737	0,934	0,425
Argila (g kg ⁻¹)	557,717	41,830	485,186	616,868	7,500	0,964	0,836
Pt (m ³ m ³)	0,493	0,033	0,459	0,571	6,736	0,851	0,038
Macro (m ³ m ³)	0,013	0,006	0,006	0,025	45,253	0,921	0,293
Micro (m ³ m ³)	0,480	0,033	0,444	0,552	6,945	0,859	0,047
CC (g kg ⁻¹)	351,463	32,049	300,053	403,288	9,119	0,949	0,623
PMP (g kg ⁻¹)	146,261	15,238	123,621	166,544	10,418	0,918	0,268

APÊNDICE 16 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Anápolis - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	21,147	3,207	14,575	24,958	15,164	0,877	0,080
Dp (g cm ⁻³)	2,771	0,068	2,616	2,859	2,444	0,937	0,458
Ds (g cm ⁻³)	1,283	0,052	1,199	1,366	4,072	0,958	0,752
Areia (g kg ⁻¹)	365,695	35,192	311,869	420,434	9,623	0,933	0,412
Silte (g kg ⁻¹)	104,235	28,844	47,183	140,801	27,672	0,924	0,323
Argila (g kg ⁻¹)	530,069	36,919	472,907	577,800	6,965	0,927	0,354
Pt (m ³ m ³)	0,479	0,028	0,434	0,542	5,788	0,942	0,522
Macro (m ³ m ³)	0,012	0,007	0,002	0,029	59,789	0,955	0,709
Micro (m ³ m ³)	0,466	0,025	0,430	0,532	5,391	0,863	0,053
CC (g kg ⁻¹)	324,849	16,306	299,977	348,481	5,020	0,943	0,539
PMP (g kg ⁻¹)	143,375	11,044	127,416	160,645	7,703	0,931	0,392

APÊNDICE 17 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Santa Rita do Novo Destino - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	22,046	0,971	20,487	23,814	4,402	0,978	0,973
Dp (g cm ⁻³)	2,756	0,040	2,681	2,804	1,458	0,928	0,354
Ds (g cm ⁻³)	1,319	0,068	1,187	1,396	5,192	0,863	0,054
Areia (g kg ⁻¹)	263,959	54,954	193,922	363,971	20,819	0,938	0,473
Silte (g kg ⁻¹)	214,011	44,877	151,976	289,587	20,970	0,942	0,521
Argila (g kg ⁻¹)	522,030	59,180	435,405	641,137	11,336	0,967	0,875
Pt (m ³ m ³)	0,470	0,023	0,427	0,506	4,792	0,977	0,967
Macro (m ³ m ³)	0,013	0,010	0,002	0,041	75,219	0,799	0,009
Micro (m ³ m ³)	0,457	0,022	0,419	0,493	4,760	0,977	0,970
CC (g kg ⁻¹)	313,699	20,835	286,601	353,864	6,642	0,947	0,589
PMP (g kg ⁻¹)	109,536	6,675	99,603	120,395	6,094	0,950	0,640

APÊNDICE 18 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Santa Rita do Novo Destino - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	16,542	1,570	14,359	19,771	9,492	0,943	0,541
Dp (g cm ⁻³)	2,736	0,080	2,604	2,844	2,926	0,935	0,435
Ds (g cm ⁻³)	1,406	0,076	1,241	1,512	5,431	0,934	0,419
Areia (g kg ⁻¹)	217,637	46,028	158,396	317,380	21,149	0,910	0,213
Silte (g kg ⁻¹)	186,997	52,995	102,196	290,330	28,340	0,982	0,991
Argila (g kg ⁻¹)	595,367	78,212	462,685	689,279	13,137	0,928	0,358
Pt (m ³ m ³)	0,450	0,039	0,352	0,496	8,670	0,888	0,111
Macro (m ³ m ³)	0,011	0,005	0,003	0,017	42,062	0,941	0,513
Micro (m ³ m ³)	0,439	0,039	0,337	0,478	8,893	0,838	0,026
CC (g kg ⁻¹)	282,001	30,896	211,645	334,158	10,956	0,952	0,659
PMP (g kg ⁻¹)	107,732	8,695	88,859	119,544	8,071	0,944	0,554

APÊNDICE 19 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Rianópolis - Go, na profundidade de 0,0 – 0,20 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	20,277	1,059	19,078	22,339	5,224	0,923	0,311
Dp (g cm ⁻³)	2,575	0,040	2,533	2,648	1,552	0,864	0,055
Ds (g cm ⁻³)	1,227	0,051	1,172	1,320	4,173	0,900	0,160
Areia (g kg ⁻¹)	578,576	25,295	541,589	610,966	4,372	0,909	0,210
Silte (g kg ⁻¹)	44,613	23,531	10,644	84,271	52,744	0,933	0,410
Argila (g kg ⁻¹)	376,811	29,042	329,016	435,643	7,707	0,974	0,944
Pt (m ³ m ³)	0,474	0,015	0,448	0,496	3,229	0,934	0,425
Macro (m ³ m ³)	0,010	0,006	0,003	0,023	53,965	0,894	0,133
Micro (m ³ m ³)	0,464	0,014	0,440	0,487	3,049	0,958	0,758
CC (g kg ⁻¹)	302,687	17,608	267,036	324,831	5,817	0,944	0,552
PMP (g kg ⁻¹)	148,662	3,606	144,975	157,271	2,426	0,885	0,101

APÊNDICE 20 - Estatística Descritiva das variáveis dependentes e independentes referentes à cidade de Rianópolis - Go, na profundidade de 0,20 – 0,40 m do solo.

Atributos do solo	Média	Desvio padrão	Mínimo	Máximo	C.V. (%)	Shapiro-Wilk	
						W	p-value
MO (g kg ⁻¹)	19,335	0,705	18,553	20,805	3,644	0,844	0,031
Dp (g cm ⁻³)	2,605	0,037	2,550	2,674	1,401	0,978	0,977
Ds (g cm ⁻³)	1,391	0,081	1,275	1,557	5,797	0,948	0,603
Areia (g kg ⁻¹)	560,375	30,353	501,568	597,325	5,417	0,933	0,418
Silte (g kg ⁻¹)	55,708	27,314	11,278	97,350	49,031	0,937	0,464
Argila (g kg ⁻¹)	383,918	28,834	335,738	438,831	7,511	0,985	0,997
Pt (m ³ m ³)	0,429	0,029	0,374	0,470	6,750	0,904	0,176
Macro (m ³ m ³)	0,013	0,006	0,003	0,023	48,214	0,982	0,989
Micro (m ³ m ³)	0,417	0,031	0,359	0,461	7,410	0,937	0,463
CC (g kg ⁻¹)	260,230	22,288	219,760	291,995	8,565	0,951	0,652
PMP (g kg ⁻¹)	104,469	3,328	101,592	113,889	3,186	0,727	0,002

APÊNDICE 21 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Jaraguá - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Jaraguá	1	22 L 671447 8267312	617 m	15°39'59.25" S	49°24'01.33" W
	2	22 L 671506 8267258	617 m	15°40'00.99" S	49°23'59.34" W
	3	22 L 671531 8267289	617 m	15°39'59.98" S	49°23'58.50" W
	4	22 L 671590 8267288	615 m	15°40'00.00" S	49°23'56.52" W
	5	22 L 670825 8266650	691 m	15°40'20.94" S	49°24'22.05" W
	6	22 L 670852 8266484	684 m	15°40'26.33" S	49°24'21.10" W
	7	22 L 670902 8266190	674 m	15°40'35.89" S	49°24'19.35" W
	8	22 L 670968 8265787	668 m	15°40'48.98" S	49°24'17.03" W
	9	22 L 670850 8263437	671 m	15°42'05.47" S	49°24'20.40" W
	10	22 L 670909 8263427	673 m	15°42'05.78" S	49°24'18.41" W
	11	22 L 670956 8263540	669 m	15°42'02.09" S	49°24'16.86" W
	12	22 L 670995 8263475	668 m	15°42'04.19" S	49°24'15.54" W

APÊNDICE 22 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Goianésia - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Goianésia	13	22 L 696168 8316417	843 m	15°13'15.34" S	49°10'25.27" W
	14	22 L 696145 8316430	845 m	15°13'14.92" S	49°10'26.05" W
	15	22 L 696060 8316563	851 m	15°13'10.62" S	49°10'28.93" W
	16	22 L 696000 8316693	855 m	15°13'06.41" S	49°10'30.98" W
	17	22 L 695926 8316723	858 m	15°13'05.45" S	49°10'33.46" W
	18	22 L 695849 8316723	860 m	15°13'05.47" S	49°10'36.04" W
	19	22 L 684499 8326198	595 m	15°08'00.22" S	49°16'58.81" W
	20	22 L 684506 8326246	582 m	15°07'58.65" S	49°16'58.59" W
	21	22 L 684475 8326293	583 m	15°07'57.13" S	49°16'59.64" W
	22	22 L 684427 8326267	583 m	15°07'57.99" S	49°17'01.24" W
	23	22 L 684432 8326232	582 m	15°07'59.13" S	49°17'01.06" W
	24	22 L 684457 8326173	581 m	15°08'01.04" S	49°17'00.21" W

APÊNDICE 23 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Vila Propício - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Vila Propício	25	22 L 718966 8296858	633 m	15°23'44.96" S	48°57'35.34" W
	26	22 L 718942 8296810	634 m	15°23'46.53" S	48°57'36.13" W
	27	22 L 718990 8296774	632 m	15°23'47.69" S	48°57'34.51" W
	28	22 L 719038 8296761	629 m	15°23'48.10" S	48°57'32.90" W
	29	22 L 719012 8296707	631 m	15°23'49.86" S	48°57'33.75" W
	30	22 L 719047 8296656	628 m	15°23'51.51" S	48°57'32.56" W
	31	22 L 719100 8296641	627 m	15°23'51.98" S	48°57'30.78" W
	32	22 L 719115 8296590	625 m	15°23'53.63" S	48°57'30.26" W
	33	22 L 719116 8296526	624 m	15°23'55.72" S	48°57'30.21" W
	34	22 L 719160 8296509	621 m	15°23'56.26" S	48°57'28.73" W
	35	22 L 719202 8296560	620 m	15°23'54.58" S	48°57'27.34" W
	36	22 L 719196 8296634	621 m	15°23'54.58" S	48°57'27.34" W

APÊNDICE 24 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Carmo do Rio Verde - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Carmo do Rio Verde	37	22 L 644761 8301930	570 m	15°21'18.89" S	49°39'04.80" W
	38	22 L 644858 8301926	577 m	15°21'19.00" S	49°39'01.55" W
	39	22 L 644929 8301911	580 m	15°21'19.48" S	49°38'59.16" W
	40	22 L 645021 8301893	581 m	15°21'20.04" S	49°38'56.07" W
	41	22 L 644920 8301292	608 m	15°21'39.62" S	49°38'59.34" W
	42	22 L 644994 8301315	602 m	15°21'38.86" S	49°38'56.86" W
	43	22 L 645092 8301274	600 m	15°21'40.17" S	49°38'53.56" W
	44	22 L 645123 8301160	597 m	15°21'43.87" S	49°38'52.50" W
	45	22 L 645268 8300675	566 m	15°21'59.63" S	49°38'47.54" W
	46	22 L 645385 8300631	569 m	15°22'01.03" S	49°38'43.60" W
	47	22 L 645469 8300622	572 m	15°22'01.31" S	49°38'40.78" W
	48	22 L 645549 8300579	571 m	15°22'02.69" S	49°38'38.09" W

APÊNDICE 25 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Campo Limpo - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Campo Limpo	49	22 K 699973 8201213	872 m	16°15'41.75" S	49°07'43.58" W
	50	22 K 699920 8201157	874 m	16°15'43.59" S	49°07'45.35" W
	51	22 K 699832 8201177	879 m	16°15'42.96" S	49°07'48.32" W
	52	22 K 699895 8201236	879 m	16°15'41.03" S	49°07'46.22" W
	53	22 K 699928 8201249	875 m	16°15'40.59" S	49°07'45.11" W
	54	22 K 699988 8201254	867 m	16°15'40.41" S	49°07'43.09" W
	55	22 K 699660 8201319	896 m	16°15'38.40" S	49°07'54.15" W
	56	22 K 699649 8201400	898 m	16°15'35.77" S	49°07'54.55" W
	57	22 K 699623 8201450	901 m	16°15'34.15" S	49°07'55.44" W
	58	22 K 699809 8201073	877 m	16°15'46.35" S	49°07'49.06" W
	59	22 K 699866 8201016	869 m	16°15'48.19" S	49°07'47.12" W
	60	22 K 699878 8201113	876 m	16°15'45.03" S	49°07'46.75" W

APÊNDICE 26 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Jesópolis - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Jesópolis	61	22 L 668708 8237860	694 m	15°55'58.10" S	49°25'25.90" W
	62	22 L 668791 8237840	701 m	15°55'58.73" S	49°25'23.10" W
	63	22 L 668824 8238130	686 m	15°55'49.29" S	49°25'22.06" W
	64	22 L 668916 8238092	695 m	15°55'50.50" S	49°25'18.96" W
	65	22 L 669156 8238140	701 m	15°55'48.88" S	49°25'10.90" W
	66	22 L 669251 8238096	701 m	15°55'50.29" S	49°25'07.70" W
	67	22 L 669290 8238140	696 m	15°55'48.85" S	49°25'06.40" W
	68	22 L 669206 8238177	697 m	15°55'47.66" S	49°25'09.23" W
	69	22 L 669389 8238278	695 m	15°55'44.33" S	49°25'03.10" W
	70	22 L 669457 8238252	698 m	15°55'45.16" S	49°25'00.81" W
	71	22 L 666767 8236054	704 m	15°55'45.16" S	49°25'00.81" W
	72	22 L 666839 8235953	712 m	15°57'00.60" S	49°26'28.26" W

APÊNDICE 27 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Ouro Verde - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Ouro Verde	73	22 K 692987 8203397	892 m	16°14'32.75" S	49°11'39.48" W
	74	22 K 693026 8203337	908 m	16°14'34.69" S	49°11'38.15" W
	75	22 K 693063 8203460	930 m	16°14'30.68" S	49°11'36.94" W
	76	22 K 692966 8203543	931 m	16°14'28.01" S	49°11'40.23" W
	77	22 K 692839 8201618	941 m	16°15'30.66" S	49°11'43.94" W
	78	22 K 692897 8201553	956 m	16°15'32.76" S	49°11'41.96" W
	79	22 K 692969 8201617	965 m	16°15'30.66" S	49°11'39.56" W
	80	22 K 692894 8201663	956 m	16°15'29.18" S	49°11'42.10" W
	81	22 K 692479 8201741	953 m	16°15'26.76" S	49°11'56.09" W
	82	22 K 692527 8201655	950 m	16°15'29.55" S	49°11'54.45" W
	83	22 K 692608 8201719	945 m	16°15'27.44" S	49°11'51.74" W
	84	22 K 692558 8201798	946 m	16°15'24.89" S	49°11'53.45" W

APÊNDICE 28 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Anápolis - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Anápolis	85	22 K 726631 8191805	990 m	16°20'39.26" S	48°52'42.69" W
	86	22 K 726562 8191809	1014 m	16°20'39.15" S	48°52'45.01" W
	87	22 K 726505 8191815	1014 m	16°20'38.98" S	48°52'46.94" W
	88	22 K 727202 8191960	1007 m	16°20'34.02" S	48°52'23.51" W
	89	22 K 727266 8191962	1007 m	16°20'33.94" S	48°52'21.36" W
	90	22 K 727241 8192059	1003 m	16°20'30.79" S	48°52'22.23" W
	91	22 K 727311 8192071	1003 m	16°20'30.38" S	48°52'19.88" W
	92	22 K 727387 8192054	1003 m	16°20'30.90" S	48°52'17.31" W
	93	22 K 727472 8192030	1003 m	16°20'31.66" S	48°52'14.44" W
	94	22 K 727170 8191983	1007 m	16°20'33.29" S	48°52'24.60" W
	95	22 K 727033 8191849	1013 m	16°20'37.69" S	48°52'29.16" W
	96	22 K 726929 8192057	1005 m	16°20'30.96" S	48°52'32.74" W

APÊNDICE 29 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Santa Rita do Novo Destino - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Santa Rita do Novo Destino	97	22 L 697967 8325336	634 m	15°08'24.70" S	49°09'27.52" W
	98	22 L 698034 8325285	706 m	15°08'26.34" S	49°09'25.26" W
	99	22 L 698100 8325203	716 m	15°08'28.99" S	49°09'23.02" W
	100	22 L 698061 8325129	724 m	15°08'31.41" S	49°09'24.31" W
	101	22 L 697933 8325133	721 m	15°08'31.32" S	49°09'28.60" W
	102	22 L 697916 8325298	722 m	15°08'25.95" S	49°09'29.21" W
	103	22 L 697957 8325235	731 m	15°08'27.99" S	49°09'27.82" W
	104	22 L 697858 8325271	720 m	15°08'26.85" S	49°09'31.15" W
	105	22 L 697915 8325388	715 m	15°08'23.03" S	49°09'29.27" W
	106	22 L 697953 8325381	715 m	15°08'23.24" S	49°09'28.00" W
	107	22 L 698031 8325469	706 m	15°08'20.36" S	49°09'25.41" W
108	22 L 697992 8325530	703 m	15°08'18.39" S	49°09'26.73" W	

APÊNDICE 30 – Localização das coletas de solo em coordenadas UTM e geográfica, para o município de Rianópolis - Go.

Município	Pontos	UTM	Altitude	Coordenadas Geográficas	
				Latitude	Longitude
Rianópolis	109	22 L 665560 8291648	568 m	15°26'48.90" S	49°27'24.92" W
	110	22 L 665628 8291600	604 m	15°26'50.45" S	49°27'22.63" W
	111	22 L 665709 8291595	612 m	15°26'50.59" S	49°27'19.91" W
	112	22 L 665639 8291719	615 m	15°26'46.57" S	49°27'22.29" W
	113	22 L 665693 8291775	615 m	15°26'44.74" S	49°27'20.49" W
	114	22 L 665794 8291689	617 m	15°26'47.51" S	49°27'17.08" W
	115	22 L 665762 8291762	617 m	15°26'45.14" S	49°27'18.17" W
	116	22 L 665740 8291831	616 m	15°26'42.90" S	49°27'18.92" W
	117	22 L 665829 8291779	614 m	15°26'44.58" S	49°27'15.93" W
	118	22 L 665842 8291853	614 m	15°26'42.16" S	49°27'15.51" W
	119	22 L 665905 8291881	623 m	15°26'41.24" S	49°27'13.40" W
	120	22 L 665900 8291960	621 m	15°26'38.67" S	49°27'13.59" W