

UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE CIÊNCIAS RURAIS  
PROGRAMA DE PÓS-GRADUAÇÃO  
EM ENGENHARIA AGRÍCOLA

Luiz Patric Kayser

**ESTIMATIVA DOS PARÂMETROS DE FUNÇÕES DE  
PEDOTRANSFERÊNCIA PARA OS SOLOS DO RIO GRANDE DO  
SUL**

Santa Maria, RS  
2019

Luiz Patric Kayser

**ESTIMATIVA DOS PARÂMETROS DE FUNÇÕES DE PEDOTRANSFERÊNCIA  
PARA OS SOLOS DO RIO GRANDE DO SUL**

Tese apresentada ao Curso de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria (UFSM-RS), como requisito parcial para a obtenção do título de **Doutor em Engenharia Agrícola**.

Orientadora: Prof<sup>a</sup> Dr<sup>a</sup>. Marcia Xavier Peiter

Santa Maria, RS  
2019

Luiz Patric Kayser

**ESTIMATIVA DOS PARÂMETROS DE FUNÇÕES DE PEDOTRANSFERÊNCIA  
PARA OS SOLOS DO RIO GRANDE DO SUL**

Tese apresentada ao Curso de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria (UFSM-RS), como requisito parcial para a obtenção do título de **Doutor em Engenharia Agrícola**.

Aprovado em 29 de Abril de 2019:

---

Marcia Xavier Peiter, Dr<sup>a</sup>. (UFSM)  
(Presidente / Orientadora)

---

Adroaldo Dias Robaina, Dr. (UFSM)  
(Coorientador)

---

Elódio Sebem, Dr. (UFSM)

---

Liane de Souza Weber, Dr<sup>a</sup>. (UFSM)

---

Rogério Ricalde Torres, Dr. (IFRS – Campus Vacaria)

---

Tonismar Pereira, Dr. (UFPEl)

Santa Maria, RS  
2019

## DEDICATÓRIA

Dedico este trabalho a minha família, em especial aos meus pais Aldemar e Edir, que infelizmente não puderam presenciar esta conquista, que também é deles, a minha esposa Erika e a minha filha Maria Alice.

## AGRADECIMENTOS

Com o término deste trabalho encerra-se mais uma etapa da minha vida, e gostaria de me apropriar de uma frase de Isaac Newton: “Se eu vi mais longe, foi por estar sobre ombros de gigantes”. Gratidão. Este é o sentimento que me domina neste momento tão especial. Pois se cheguei até este ponto, foi porque recebi o apoio de muitas pessoas, que foram especiais e enviadas por Deus para me amparar naquele exato momento em que eu mais precisava:

Primeiramente a Deus e Nossa Senhora, por me carregarem quando eu já tinha desistido de andar, por me fazerem entender, quando eu já não aceitava os acontecimentos, por passarem na frente abrindo todas as portas que eu necessitava;

Aos meus pais, Aldemar e Edir, que me deram educação e estudo, mas sobretudo amor, e tudo que sou hoje devo a eles. Infelizmente o destino quis que eles não estivessem presentes fisicamente para presenciar este momento, mas sei que de onde estão me abençoaram e olharam por mim;

Agradeço também a minha esposa Erika e a minha filha Maria Alice, que tiveram muita paciência para muitas vezes suportar a minha ansiedade em realizar o trabalho, e outras vezes aceitaram a minha ausência, por vezes uma ausência presente;

A minha sogra Dona Carmen, que também não está mais neste plano, mas que sei o quanto ficaria orgulhosa em presenciar este momento;

A minha orientadora Professora Marcia Xavier Peiter, pela oportunidade de realizar este trabalho, mas também pela amizade, ensinamentos, conselhos, críticas, atenção, confiança, disponibilidade e sobretudo paciência com que me ajudou durante esta jornada;

Ao meu coorientador Professor Adroaldo Dias Robaina, por todo o apoio que me deu durante estes 18 anos de convivência, ensinamentos, amizade, preocupação, confiança e claro, os puxões de orelha, que me fizeram focar no trabalho quando necessário;

As minhas cunhadas Helga e Lydia e meus sobrinhos Bento e Loren, por estarem sempre presentes em minha vida;

A Beatriz, por toda a ajuda e dedicação tanto a minha pessoa, como também a Erika e principalmente ao cuidado que tem com nossa filha;

Ao meu amigo, colega e orientador de mestrado Professor Enio Giotto, por todo o apoio e amizade durante toda a minha jornada na universidade;

Aos meus amigos Elódio, Jéferson, Júnior e Michele, pela amizade e incontestável parceria, vocês foram muitas vezes o meu amparo para seguir em frente, Deus não poderia ter colocado amigos melhores em minha vida;

A minha tia, Edite, meu primo, Sérgio, meu Irmão, Paulo, cunhadas, sobrinhos e sobrinhas, pela compreensão da minha ausência.

Aos meus vizinhos Armando e Vilma, Aline e Daniela, que sempre me ajudaram e me trataram como filho e irmão.

Aos colegas de laboratório de Engenharia de Irrigação da UFSM: Anderson, Bruna, Elisa, Fábio, Franciele, Helena, Jardel, Jéssica, Jhosefe, Laura, Leonita, Luís Humberto, Marcos, Marcos Vinícius, Miguel, Pablo, Ricardo Boscaíni, Ricardo Rosso, Rogério, Silvana, Wellington e Yesica, pelo convívio diário, ensinamentos, discussões e amizade.

À banca examinadora pelas considerações, correções, sugestões, disponibilidade de tempo e empenho na colaboração e julgamento do trabalho.

A todos os meus amigos por estarem presentes em todas as etapas da minha caminhada. Pelos momentos de lazer, descontração e diversão, proporcionados nas horas vagas. Pelo companheirismo nos momentos difíceis, amizade e confiança depositados.

À Universidade Federal de Santa Maria e ao Programa de Pós-Graduação em Engenharia Agrícola pela oportunidade e excelente estrutura disponibilizada.

Ao Colégio Politécnico da UFSM, que esteve presente em minha vida desde o ensino técnico e hoje é o meu local de trabalho. Agradeço de um modo muito especial a todos os meus colegas servidores;

A todos os servidores e funcionários terceirizados da Universidade Federal de Santa Maria, pelos serviços essenciais prestados na manutenção e funcionamento da instituição;

## EPÍGRAFE

Se ao final do dia você não estiver cansado,  
então neste dia você não mereceu o seu  
salário.

(Aldemar Kayser)

## RESUMO

### ESTIMATIVA DOS PARÂMETROS DE FUNÇÕES DE PEDOTRANSFERÊNCIA PARA OS SOLOS DO RIO GRANDE DO SUL

AUTOR: Luiz Patric Kayser

ORIENTADORA: Prof<sup>a</sup> Dr<sup>a</sup>. Marcia Xavier Peiter

A curva de retenção de água no solo é uma informação importante para o manejo racional da irrigação. Devido a dificuldade na geração da mesma através de métodos tradicionais, existe a necessidade da criação de métodos alternativos, como as funções de pedotransferência, que geram a curva de forma indireta, utilizando dados que podem ser adquiridos de forma mais fácil e rápida. Neste contexto, o presente trabalho objetiva estimar os parâmetros do modelo de Van Genuchten através de funções de pedotransferência com dados físico-hídricos para solos do estado do Rio Grande do Sul utilizando Regressão Linear Múltipla e Redes Neurais Artificiais. Para estimar os parâmetros  $\theta_r$ ,  $\alpha$  e  $n$  da equação de Van Genuchten, foram utilizados os teores de areia, silte, argila, densidade do solo ( $d_s$ ), densidade de partículas ( $d_p$ ) e Matéria Orgânica (Mo) como variáveis independentes. As análises de regressão linear múltipla foram realizadas utilizando o procedimento stepwise (Forward) do software IBM SPSS Statistics 25, enquanto que as redes neurais artificiais foram geradas utilizando a função perceptron múltipla camada do mesmo software. Os resultados obtidos na estimativa dos parâmetros  $\alpha$ ,  $\theta_r$  e  $n$  podem ser considerados bons com ambas metodologias de estimativa. Na regressão linear múltipla os valores do coeficiente de determinação foram superiores a 0,9 na maioria dos modelos propostos, e a raiz do erro médio quadrado apresentou valores inferiores a 0,008. Usando redes neurais artificiais os valores de  $R^2$  foram superiores a 0,9 em todos os modelos propostos, e a RMSE apresentou valores inferiores a 0,0012. Com isto, podemos afirmar que o uso de Regressão Linear Múltipla e das Redes Neurais Artificiais se mostrou eficiente em gerar Funções de Pedotransferência, para a base de dados utilizada, estimando os parâmetros da equação de Van Genuchten com alta capacidade preditiva dos modelos propostos, sendo que a segunda metodologia apresentou valores maiores de  $R^2$  e menores de RMSE.

**Palavras-Chave:** Redes Neurais Artificiais, Regressão Linear Múltipla, Van Genuchten, Curva de Retenção de Água no Solo.

## ABSTRACT

### ESTIMATION OF THE PARAMETERS OF PEDOTRANSFERENCE FUNCTIONS FOR SOILS OF RIO GRANDE DO SUL

AUTHOR: Luiz Patric Kayser  
ADVISOR: Prof<sup>a</sup> Dr<sup>a</sup>. Marcia Xavier Peiter

The soil water retention curve is an important information for the rational management of irrigation. Due to the difficulty in generating it through traditional methods, there is a need to create alternative methods, such as pedotransfer functions, that generate the curve indirectly, using data that can be acquired more easily and quickly. In this context, the present work aims to estimate the parameters of the Van Genuchten model through pedotransfer functions with physical-hydro data for soils of the State of Rio Grande do Sul using Multiple Linear Regression and Artificial Neural Networks. To estimate the parameters  $\theta_r$ ,  $\alpha$  and  $n$  of the Van Genuchten equation, the levels of sand, silt, clay, soil density ( $d_s$ ), particle density ( $d_p$ ) and organic matter ( $M_o$ ) were used as independent variables. Multiple linear regression analyzes were performed using the stepwise (Forward) procedure of the IBM SPSS Statistics 25 software, while the artificial neural networks were generated using the multiple layer perceptron function of the same software. The results obtained in the estimation of the parameters  $\alpha$ ,  $\theta_r$  and  $n$  can be considered good with both estimation methodologies. In the multiple linear regression the values of the coefficient of determination were higher than 0.9 in most of the proposed models, and the root mean square error presented values lower than 0.008. Using artificial neural networks, the  $R^2$  values were higher than 0.9 in all the proposed models, and the RMSE presented values lower than 0.0012. With this, we can affirm that the use of Multiple Linear Regression and Artificial Neural Networks was efficient in generating Pedotransfer Functions, for the data base used, estimating the parameters of the Van Genuchten equation with high predictive capacity of the proposed models. that the second methodology had higher values of  $R^2$  and lower values of RMSE.

**Keywords:** Artificial Neural Networks, Multiple Linear Regression, Van Genuchten, Soil Water Retention Curve.

## LISTA DE ILUSTRAÇÕES

### APRESENTAÇÃO

Figura 1 - Variabilidade textural dos solos do Estado do Rio Grande do Sul disponíveis na base de dados.....28

Figura 2 – Variáveis independentes e dependentes da RLM.....31

### ARTIGO 1

Figura 1. Gráficos valores estimados x valores observados para o parâmetro  $\alpha$ .....45

Figura 2. Gráficos valores estimados x valores observados para o parâmetro  $n$ .....46

Figura 3. Gráficos valores estimados x valores observados amostrados para o parâmetro  $\theta_r$ .....47

### ARTIGO 2

FIGURA 1. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro  $\alpha$ .....60

FIGURA 2. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro  $n$ .....61

FIGURA 3. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro  $\theta_r$ .....62

### DISCUSSÃO

Figura 3 - Comparação das umidades estimadas por RLM e RNA nos diversos potenciais para os dados gerais.....75

## LISTA DE TABELAS

### APRESENTAÇÃO

Tabela 1 - Valores mínimos, médios, máximos, desvio padrão e coeficiente de variação (CV) .....29

Tabela 2 - Número de amostras utilizadas para treinamento, testes e validação nas distintas classes texturais.....30

### ARTIGO 1

Tabela 1. Número de amostras utilizadas, para geração e validação das FPT .....39

Tabela 2. Estatística descritiva da base de dados .....41

Tabela 3. Correlação das variáveis independentes com as variáveis dependentes .43

### ARTIGO 2

TABELA 1. Número de amostras utilizadas, para geração e validação das FPT, nas distintas classes texturais.....57

TABELA 2. Número de neurônios na camada oculta .....63

TABELA 3. Indicadores de desempenho das estimativas dos parâmetros  $\alpha$ ,  $n$  e  $\theta_r$  65

### DISCUSSÃO

Tabela 3 - Indicadores de desempenho da estimativa do parâmetro  $\alpha$ .....71

Tabela 4 - Indicadores de desempenho da estimativa do parâmetro  $n$ .....71

Tabela 5 - Indicadores de desempenho da estimativa do parâmetro  $\theta_r$ .....72

## SUMÁRIO

<b>1</b>	<b>APRESENTAÇÃO .....</b>	<b>12</b>
1.1	INTRODUÇÃO .....	12
1.2	OBJETIVOS .....	14
<b>1.2.1</b>	<b>Objetivo Geral.....</b>	<b>14</b>
<b>1.2.2</b>	<b>Objetivos Específicos .....</b>	<b>14</b>
1.3	HIPÓTESES.....	15
1.4	REVISÃO BIBLIOGRÁFICA.....	15
<b>1.4.1</b>	<b>Curva Característica de água no solo .....</b>	<b>15</b>
1.4.1.1	<i>Fatores que influenciam a curva de água no solo.....</i>	<i>16</i>
1.4.1.2	<i>Métodos para obtenção da curva de retenção da água no solo.....</i>	<i>18</i>
1.4.1.2.1	Métodos Diretos .....	18
1.4.1.2.2	Métodos indiretos: Pedotransferência .....	20
1.5	MATERIAIS E MÉTODOS .....	27
<b>1.5.1</b>	<b>Bases de dados: obtenção e caracterização .....</b>	<b>27</b>
<b>1.5.2</b>	<b>Desenvolvimento das Funções de Pedotransferência .....</b>	<b>29</b>
<b>1.5.3</b>	<b>FPT geradas por regressão linear múltipla.....</b>	<b>30</b>
<b>1.5.4</b>	<b>FPT geradas a partir de Redes Neurais Artificiais .....</b>	<b>31</b>
1.5.4.1	<i>Definição da entrada e saída das RNA .....</i>	<i>32</i>
1.5.4.2	<i>Treinamento e validação da RNA .....</i>	<i>32</i>
<b>1.5.5</b>	<b>Análise dos dados.....</b>	<b>33</b>
<b>2</b>	<b>ARTIGO 1 – ESTIMATIVA DOS PARÂMETROS DO MODELO DE VAN GENUCHTEN VIA REGRESSÃO LINEAR MÚLTIPLA.....</b>	<b>35</b>
<b>3</b>	<b>ARTIGO 2 – ESTIMATIVA DOS PARÂMETROS DO MODELO DE VAN GENUCHTEN VIA REDES NEURAIAS ARTIFICIAIS.....</b>	<b>52</b>
<b>4</b>	<b>DISCUSSÃO .....</b>	<b>70</b>
4.1	COMPARAÇÃO ENTRE AS FPT DESENVOLVIDAS POR RLM E RNA .....	70
4.2	ESTIMATIVA DAS UMIDADES ATRAVÉS DA EQUAÇÃO DE VAN GENUCHTEN .....	73
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>77</b>
	<b>REFERÊNCIAS.....</b>	<b>78</b>

# 1 APRESENTAÇÃO

## 1.1 INTRODUÇÃO

A Curva de Retenção de Água no solo (CRAS) é a relação entre a quantidade de água em um volume de solo, e permite o conhecimento detalhado quanto a retenção e absorção de água. Proporciona condições necessárias para a determinação do teor de água disponível no solo e de outras variáveis que servirão para o manejo adequado da água de irrigação e o balanço hídrico.

Existem vários métodos experimentais para a determinação da curva de retenção da água no solo, cada um com suas peculiaridades, vantagens e limitações. Muitas vezes é necessário o uso de mais de um método para obter uma faixa mais ampla dos valores de umidade.

Os métodos de obtenção direta da curva necessitam de informações ou utilizam equipamentos de difícil acesso, sendo muitas vezes impraticável para a maioria das aplicações.

Desta forma, existe a necessidade de métodos alternativos, que se caracterizam pela estimativa indireta de propriedades físico-hídricas do solo, chamados de funções de pedotransferência (FPT). Estes métodos permitem a estimativa das propriedades hidráulicas a partir de informações facilmente mensuradas ou prontamente disponíveis.

O desenvolvimento e uso de funções de pedotransferência para estabelecer a relação entre as características do solo facilmente mensuráveis ou prontamente disponíveis, e os parâmetros de entrada de modelos mais complexos vem aumentando nos últimos anos. Nas últimas três décadas, um número considerável de FPT com diferentes requisitos de entradas de dados e princípios de modelagem tem sido propostas na literatura.

As FPT podem ser obtidas por vários métodos matemáticos, sendo que a maioria delas foi obtida por meio de métodos de regressão linear múltipla. Vários trabalhos estão utilizando técnicas de Inteligência Artificial no desenvolvimento destas FPT. Entre estas, destaca-se estimação da CRAS através de Redes Neurais Artificiais, utilizando bancos de dados existentes, aproveitando, desta forma, informações já disponíveis, e eliminando o retrabalho.

Dentre os vários trabalhos da literatura, destaca-se o trabalho desenvolvido por Moosavizadeh-Mojarrad e Sepaskhah (2011) que pesquisou redes neurais artificiais para previsão da curva de retenção de água no solo, afirmou que os resultados foram aceitáveis para predição da retenção de água usando redes neurais artificiais, aconselhando o uso dos modelos de inteligência para prever as propriedades hidráulicas do solo.

Soares (2014) utilizou redes neurais artificiais na estimativa da retenção de água do solo concluiu que o uso de redes neurais de múltiplas camadas, treinadas com o algoritmo *backpropagation* pode ser usada para a estimativa da curva de retenção de água no solo, auxiliando assim o setor agrícola para uma maior otimização dos sistemas irrigados.

Ebrahimi et al. (2014) trabalharam com capacidade de predição de diferentes modelos de curva de retenção de água no solo utilizando redes neurais artificiais. De acordo com a análise de sensibilidade, a textura do solo foi o fator mais importante para a retenção de água em solos de textura moderada a fina.

D'Emilio et al. (2018), basearam a sua pesquisa sobre redes neurais artificiais para predizer a curva de retenção de água do solo. Utilizando um banco de dados, as redes neurais artificiais podem ser usadas para o mapeamento do solo em áreas com características hidráulicas e texturais do solo similares, sem levantamentos de campo adicionais. Sugerindo que as RNAs implementadas poderiam ser consideradas uma abordagem geral valiosa para planejar a produção agrícola, otimizar o gerenciamento de recursos hídricos e selecionar operações de proteção ambiental.

Muitas FPT utilizam o modelo de Van Genuchten como base, pois apresenta muitas vantagens das quais se destacam: inclinação da curva de retenção de água no solo é contínua, evitando assim problemas de convergência numérica entre as umidades saturadas e residuais, é flexível para o uso em vários tipos de solo, formação de uma curva suave, e por ser o mais utilizado tornou-se um padrão mundial para modelos desse fim.

No entanto, FPT desenvolvidas a partir de bancos de dados com alguns tipos de condições do solo pode não ser diretamente aplicável a outros solos cujas condições são diferentes daqueles usados no estabelecimento de FPT. (YAO et al., 2015).

Neste contexto, o presente trabalho estudou a possibilidade de se relacionar uma base contendo dados físico-hídricos para os solos do estado do Rio Grande do Sul com os parâmetros de ajuste para o modelo de Van Genuchten e desenvolver um procedimento metodológico utilizando Regressão Linear Múltipla e Redes Neurais Artificiais.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo Geral

Desenvolver um procedimento metodológico que permita estimar os parâmetros do modelo de Van Genuchten a partir de características físico-hídricas do solo.

### 1.2.2 Objetivos Específicos

Para alcançar o objetivo geral, foram seguidos os seguintes objetivos específicos:

- ✓ Calcular os parâmetros dos modelos que foram utilizados com base no teor de umidade para os diferentes potenciais (0, -6, -10, -33, -100, -500 e -1500 kPa);
- ✓ Estabelecer e testar FPT paramétricas, que estimem os parâmetros do modelo supracitado para os dados existentes na base de dados geral, por meio de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA);
- ✓ Estabelecer e testar FPT paramétricas, que estimem os parâmetros do modelo supracitado para os dados existentes na base de dados separados por classe textural, por meio de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA);
- ✓ Avaliar a eficiência de predição das FPT, com os parâmetros estimados por RLM e RNA, propostas no trabalho, em relação às calculadas;
- ✓ Realizar um estudo avaliativo sobre as vantagens do uso da rede neural artificial em comparação com a Regressão Linear Múltipla, no aprimoramento de funções de pedotransferência para a estimativa dos parâmetros utilizados.

### 1.3 HIPÓTESES

Existe a possibilidade de se relacionar uma base de dados geral (sem separação por classes texturais) composto por dados físico-hídricos para os solos do estado do Rio Grande do Sul com os parâmetros de ajuste para o modelo de Van Genuchten;

Existe melhoramento no desempenho do processo, quando os solos são classificados de acordo com a textura;

Redes Neurais Artificiais são mais acurados e precisos que os métodos estatísticos tradicionais como Regressões Lineares Múltiplas.

### 1.4 REVISÃO BIBLIOGRÁFICA

#### 1.4.1 Curva Característica de água no solo

Compreender corretamente o comportamento de retenção de água do solo é uma condição essencial para uma descrição detalhada de solos não saturados (NUTH E LALOU, 2008). Isto pode ser observado através da Curva de Retenção de Água no Solo (CRAS), curva característica de água do solo ou simplesmente curva de retenção, que pode ser definida como a relação entre a energia com que a água está retida nos constituintes do solo e o seu conteúdo, (DALMAGO et al., 2009).

A CRAS pode ser definida como a relação funcional entre a quantidade de solução em um volume do solo, em equilíbrio com a tensão aplicada. (LIBARDI, 2005; BEUTLER et al., 2002).

A determinação da CRAS é de suma importância, pois propicia condições necessárias para a determinação do teor de água disponível no solo, do teor de água atual e de outras variáveis básicas à execução do manejo adequado da água de irrigação e à quantificação dos processos dinâmicos envolvendo o sistema solo-planta-atmosfera. (COSTA et al., 2008).

Otto e Alcaide (2001), afirmam que a CRAS é de grande importância na agricultura irrigada, tanto no que se refere ao dimensionamento de sistemas de irrigação como ao manejo desses sistemas. Da Silva et al. (2006) dizem que conhecer a relação entre o teor de água e a energia com a qual ela está retida, é essencial no estudo das relações solo-água.

É necessária também em estudos relacionados com o balanço e com a disponibilidade de água às plantas, com a dinâmica da água e solutos no solo, com a infiltração e manejo de irrigação. (TORMENA e SILVA, 2002; Andrade e Stone, 2011). Libardi (2005) afirma que o balanço hídrico em um volume de solo para uma determinada cultura é o cômputo das entradas de água no solo (precipitação pluvial, irrigação e ascensão capilar), e das saídas (drenagem, evapotranspiração e escoamento superficial) em um determinado período de tempo. Cintra et al. (2000) relata que “o conhecimento de como as plantas utilizam a água no solo e de como respondem aos níveis de armazenagem a partir do balanço hídrico, pode ser uma saída viável para o estabelecimento de estratégias eficazes de manejo visando ao melhor uso possível das reservas de água no solo pelas culturas”. E este armazenamento, com o solo visto como um reservatório, é conhecido através da retenção de água pelo solo, determinado por meio da CRAS

Beutler et al. (2002) afirmam que a capacidade de campo (CC) e a capacidade de água disponível (CAD) podem ser estimadas através da adoção de certa tensão representativa, dado à praticidade de se caracterizar rapidamente a sua umidade correspondente, por meio de curvas características de retenção de água.

#### *1.4.1.1 Fatores que influenciam a curva de água no solo*

Segundo Klein e Libardi (2000), Oliveira (2004) e Huse (2007), diversos fatores podem afetar no formato da curva de retenção de água no solo, dentre eles: tipo de solo (textura, quantidade de matéria orgânica), umidade de moldagem, história das tensões, ciclo das secagens e umedecimento, composição mineralógica, temperatura, entre outros.

Klein et al. (2010) relatam que a textura tem papel fundamental na retenção de água no solo, sendo que o teor de argila é o maior responsável, pois define a distribuição do diâmetro dos poros, e determina a área de contato entre as partículas sólidas e a água, sendo responsável pela força de retenção.

Outro fator de influência é o grau de compactação do solo, Dias Junior e Estanislau (1999), trabalhando com Latossolos Roxo, Vermelho-Amarelo e Vermelho Escuro, afirmam que os graus de compactação da curva de compactação, promoveram um deslocamento das curvas características de água do solo em relação a obtida para o grau de compactação 100%. Com o aumento do grau de compactação, ocorre a diminuição da água do solo.

Tormena e Silva (2002) afirmam que a variabilidade espacial das propriedades do solo também influencia a retenção de água, resultando em ampla variação na disponibilidade de água às plantas, que segundo Moretti de Souza Filho e Gomes (2007), vai de 25mm até 400mm.

Outros fatores que afetam a curva de retenção são a expansão e a contração de argilas, o aprisionamento de bolhas de ar e variações na estrutura por secagem rápida ou saturação prolongada. A contração é inibida na presença de cátions bivalentes e pronunciada na presença de cátions monovalentes. (MACEDO et al., 2000).

Segundo Soares (2013), a matéria orgânica também pode afetar a CRAS, pois devido a sua alta capacidade absorptiva e a sua influência sobre a estrutura do solo, afeta a porosidade, distribuição do tamanho de poros, e, conseqüentemente, a absorção da água pelo solo.

Klein e Libardi (2000), constataram que o uso e o manejo do solo alteraram consideravelmente o traçado das curvas de retenção de água no solo com a redução na porosidade e alteração na distribuição do diâmetro dos poros, esta alteração foi mais acentuada na área irrigada, nas quais ocorreram os maiores valores de densidade.

#### 1.4.1.2 Métodos para obtenção da curva de retenção da água no solo

É inegável a importância da CRAS para a agricultura, pois fornece embasamento para determinar a qualidade física do solo. Soares (2013) menciona que existem vários métodos experimentais para a determinação da curva de retenção da água no solo, cada qual com suas peculiaridades metodológicas, vantagens e limitações. A autora relata ainda que a obtenção para uma faixa ampla de valores de umidade, usualmente se faz necessário o emprego de mais de um método, uma vez que os métodos apresentam diferentes faixas de tensão de atuação, restringindo seu uso.

A CRAS, pode ser obtida em laboratório fazendo uso de diferentes metodologias, como: funil de Buchner e mesa de tensão, câmara de pressão de Richards, células Tempe, psicrômetro termopar, método do equilíbrio com solução salina, entre outros (ANDRADE, 1998). Uma outra forma direta de obtenção da curva é *in situ*, ou seja, a campo, fazendo o uso de equipamentos para a medição da umidade e da tensão (LIN, 1999).

Todos os métodos mencionados acima necessitam de informações ou utilizam equipamentos de difícil acesso, sendo muitas vezes impraticável para a maioria das aplicações. Por este motivo, muitas aplicações dependem de métodos alternativos. Estes caracterizam-se pela estimativa indireta de propriedades físico-hídricas do solo e foram chamadas de funções de pedotransferência (FPT), por Bouma e Lamén (1987). As FPT permitem a estimativa das propriedades hidráulicas a partir de informações mais facilmente mensuradas ou mais prontamente disponíveis, por exemplo, textura do solo e densidade aparente, (RAJKAI et al., 2004).

##### 1.4.1.2.1 Métodos Diretos

Segundo Grigolon (2013), vários métodos são utilizados para a elaboração da curva de retenção de água no solo, mas dentre eles o método considerado clássico e

mais utilizado é o método da câmara de pressão de Richards (RICHARDS e FIREMAN, 1943; DONAGEMA et al., 2011). Este método, segundo Andrade et al. (1998) é também chamado de “extrator de membrana”, “extrator de placa porosa” ou “extrator de Richards”, e se presta à determinação da curva de retenção na faixa de -10 a -2.000 kPa.

A câmara de Richards não possui restrições sobre aplicações de altas pressões, no entanto 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, exigido longo tempo para os ensaios (até dois meses), além do alto custo do equipamento (TAVARES, 2008).

O Funil de Büchner é um método de laboratório para determinação da curva de retenção na faixa de potencial matricial de 0 a um máximo de -50 kPa (REICHARDT,1996). Segundo Andrade (1998), embora simples, este método, apresenta problemas como: dificuldade de contato solo-placa ou solo-meio poroso; perdas de água por evaporação durante o teste; variação da temperatura da água durante o teste e, distúrbio da amostra devido a sua manipulação

Segundo Veras de Lima e Pires da Silva (2008), a mesa de tensão foi proposta por Leamer & Shaw em 1941 e, no Brasil, por Oliveira em 1968, e apresenta como principal desvantagem a necessidade da troca constante do papel tipo mata-borrão, além de não suportar a aplicação de altas tensões, funcionando, confiavelmente, até tensões próximas à capacidade de campo, isto é, até 1,0 metro de coluna de água (mca).

Conforme Meira Cássaro et al. (2008), o funil de Haines, ou funil de placa porosa, é um equipamento utilizado para encontrar a umidade que permanece em uma amostra de solo após a aplicação de uma determinada sucção nela. Sales et al. (2013), afirma que este método embora não exija o uso de balança para obtenção do volume drenado, tem a desvantagem na quantidade de amostra por ensaio, permitindo o uso de apenas uma amostra de solo por vez, o que torna necessário o emprego de vários funis para agilizar a determinação da curva de retenção, encarecendo todo o processo.

Segundo Andrade (1998), o método das células Tempe ou células de fluxo funcionam como os extratores de placa porosa, porém são empregadas para potenciais na faixa de 0 a-100 kPa. É possível determinar o conteúdo de umidade atual da amostra que, juntamente com o valor da pressão aplicada, constitui um par de pontos para a curva de retenção

Outro método, que cabe destacar aqui, é o da centrífuga, que correlaciona rotações da centrífuga com potenciais matriciais. O método tem como vantagem promover a rapidez na obtenção do equilíbrio da umidade no solo, normalmente menos de seis horas. Porém, apresenta como desvantagens a presença de grumos, que dificultam e podem limitar o fatiamento da amostra e causar a compactação das amostras de solo, durante o processo de centrifugação (FREITAS JÚNIOR e SILVA, 1984).

Grigolon (2013), menciona o Dewpoint Potentia Meter (WP4) como um método relativamente novo e que tem sido utilizado por alguns pesquisadores principalmente para obtenção dos pontos de maior tensão. É um equipamento que mede o potencial da água retida no solo quando ocorre o equilíbrio entre a pressão de vapor de saturação na amostra e pressão de vapor do ar na câmara de leitura e calcula o potencial por meio da equação de kelvin. Possui a vantagem da obtenção rápida, menos de 5 minutos, do potencial de água por amostra de solo permitindo assim a determinação da curva de retenção da água no solo em poucas horas.

Pode-se utilizar ainda métodos a campo, que utilizam formas conjugadas de medição da umidade e da tensão. Um exemplo disso é o uso do TDR (Time Domain Reflectometry) para medir a umidade e a utilização de um tensiômetro para a medição da tensão, obtendo assim a curva de retenção de água no solo, em condições de laboratório e de campo. (OTTO E ALCAIDE, 2001).

#### 1.4.1.2.2 Métodos indiretos: Pedotransferência

As características hidráulicas do solo, como a curva de retenção e condutividade hidráulica, são dados indispensáveis para a entrada de dados para a simulação na agricultura. No entanto a medição a campo destas características é

problemática devido à demora e alto custo na obtenção destes dados. Vários estudos estão sendo realizados para buscar alternativas em relação a estes problemas, uma destas abordagens são as funções de pedotransferência (MATULA, 2007).

Conforme Bouma (1989), um grande desafio para a ciência do solo é transformar os dados que se tem, nos dados que se necessita. Essa transformação, foi discutida por Lamb e Kneib (1981), e foi denominada de pedofunções. Em 1987 Bouma e Van Lanen usaram o termo funções de transferência, que depois foi substituído por funções de pedotransferência.

Os primeiros modelos de retenção de água (Gardner, 1958; Brooks e Corey, 1964; Campbell, 1974, van Genuchten, 1980; Fredlund e Xing, 1994) foram formulados como uma relação única entre a sucção e o grau de saturação ou o teor de água, (DIEUDONNE et al., 2017).

Brooks e Corey (1966), apresentam uma teoria que desenvolve as relações funcionais entre a saturação, a diferença de pressão e as permeabilidades do ar e do líquido em termos de propriedades hidráulicas de meios porosos parcialmente saturados. As permeabilidades do ar e do líquido em função da saturação e da pressão capilar são estimadas a partir das propriedades hidráulicas. Este modelo pode ser melhor visualizado através da equação 1.

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{(\alpha \Psi)^\lambda} \quad (1)$$

Sendo  $\theta$  a umidade,  $\theta_s$  a umidade de saturação,  $\theta_r$  a umidade residual,  $\Psi$  o potencial matricial,  $\lambda$  um parâmetro de ajuste para a distribuição do tamanho de poros e  $\alpha$  um parâmetro de ajuste para o potencial de entrada de ar.

Campbell (1974) apresenta um modelo em que a função de condutividade hidráulica não saturada para o solo pode ser calculada diretamente a partir de uma função de retenção de umidade e uma única medida de condutividade hidráulica em algum teor de água. Com o modelo, o ajuste da condutividade hidráulica calculada usando este procedimento com condutividades determinadas experimentalmente

para cinco amostras de solo foi pelo menos tão bom quanto com outros procedimentos de cálculo. A equação 2 apresenta o modelo de Campbell.

$$\theta = \theta_s \left( \frac{\Psi_e}{\Psi} \right)^\lambda \quad (2)$$

Sendo  $\theta$  corresponde a umidade,  $\theta_s$  a umidade de saturação,  $\Psi_e$  o potencial de entrada de ar/água,  $\Psi$  o potencial matricial e  $\lambda$  um parâmetro de ajuste que representa a inclinação da curva de retenção de água

Van Genuchten (1980) demonstrou uma equação nova e relativamente simples para a curva de retenção. Esta equação permite derivar expressões analíticas em forma fechada para a condutividade hidráulica relativa,  $K_r$ , quando substituída nos modelos de condutividade preditiva de Burdine (1953) ou Mualem (1976). As expressões resultantes para  $K_r(h)$  contêm três parâmetros independentes que podem ser obtidos ajustando o modelo de retenção de solo-água proposto aos dados experimentais. Na equação 3 pode-se observar o modelo de Van Genuchten.

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{[1 + (\alpha\Psi)^n]^m} \quad (3)$$

Sendo  $\theta$  equivale a umidade,  $\theta_r$  a umidade residual,  $\theta_s$  a umidade de saturação,  $\alpha$  um parâmetro de ajuste para o potencial de entrada de ar,  $n$  um parâmetro de ajuste que depende da pressão de borbulhamento e da distribuição do tamanho de poros,  $m$  correspondente a  $1 - 1/n$  e  $\Psi$  o potencial matricial.

Segundo Liang et al. (2016) o modelo de van Genuchten tem sido amplamente utilizado para descrever o comportamento de retenção de água dos solos. D'Emilio et al. (2018) relataram que a inclinação da curva de retenção de água no solo é contínua, evitando assim problemas de convergência numérica entre as umidades saturadas e residuais.

Segundo Sattari e Toker (2016), vem surgindo métodos de estimação a fim de eliminar completamente o custo e o tempo necessários para a realização de

experimentos de laboratório. Estes utilizam propriedades físicas do solo, tais como a distribuição de tamanho de partícula (PSD), para estimar a CRAS (ARYA E PARIS, 1981; VERECKEN et al., 1989; FREDLUND et al., 1997). Para tanto as funções de pedotransferência (FPT) Bouma (1989) usam dados de pesquisa do solo disponíveis.

O desenvolvimento e uso de funções de pedotransferência para estabelecer a relação entre as características do solo facilmente mensuráveis ou prontamente disponíveis, e os parâmetros de entrada de modelos mais complicados vem aumentando nos últimos anos. No entanto, FPT desenvolvidas a partir de bancos de dados com alguns tipos de condições do solo pode não ser diretamente aplicável a outros solos cujas condições são diferentes daqueles usados no estabelecimento de FPT. (YAO et al., 2015).

Nas últimas três décadas, um número considerável de FPT com diferentes requisitos de entradas de dados e princípios de modelagem tem sido propostas na literatura, como pode-se observar em trabalhos neste campo.

Tomasela (2003) et al. compararam duas técnicas para desenvolver funções de pedotransferência para a curva de retenção de água no solo: 1º utilizou a base de dados para gerar a CRAS, e após gerou a expressão da pedofunção com esta curva, e 2º utilizou a base de dados para estimar os parâmetros necessários em modelos que relacionam o teor de umidade com a tensão de água no solo, neste caso, a equação de Van Genuchten. Neste estudo a primeira abordagem proporcionou melhores resultados.

Bayat e Ebrahimi (2016), investigaram o impacto de diferentes variáveis de entrada sobre a previsibilidade do conteúdo de água utilizando os modelos da curva de retenção de água do solo (CRAS). Utilizou nove modelos de estimativas de CRAS, e verificou que as previsões de conteúdo de água obtidas usando diferentes modelos CRAS variaram porque diferentes variáveis de entrada foram empregadas.

Ebrahim-Zadeh et al. (2017), estudaram a correlação entre curva de resistência à tração do solo e a curva de retenção através da modelagem. O objetivo do estudo foi o de desenvolver funções pedotransferência (FPT) para estimar o teor de água através do modelo de Van Genuchten (1980), empregando os modelos de resistência

à tração. O resultado mostrou a alta capacidade de três equações na estimativa do teor de água, indicando significância na correlação entre as curvas estudadas.

Soares (2013) gerou FPT para as diferentes classes de solos do Estado do Rio Grande do Sul, utilizando redes neurais artificiais e regressão linear múltipla. Concluiu que as FPT desenvolvidas por RNA superaram a capacidade preditiva do método padrão (RLM). Deste modo, a estimativa da curva de retenção de água no solo, por meio das RNA treinadas por classes texturais, apresenta-se como um subsídio as técnicas adotadas na agricultura irrigada.

Pereira (2017) trabalhou com a estimativa da capacidade de suporte de carga do solo, estimando a pressão de preconsolidação e a resistência do solo à penetração, com o uso de metodologias de predição, utilizando de dados disponíveis na literatura, com valores de características físico-hídricas e mineralógicas dos solos. Os resultados obtidos mostraram que modelos de inteligência artificial são eficientes e possuem capacidade preditiva superior aos modelos consagrados.

Muitos programas computacionais foram desenvolvidos utilizando funções denominadas de pedotransferência. Schaap et al. (2001) propuseram um programa de computador, Rosetta, no qual foi implementada a estimativa da retenção de água e a condutividade hidráulica saturado e insaturado. Van Genuchten et al. (1991) criaram um software chamado RETC, capaz de analisar a retenção de água no solo e funções de condutividade hidráulica de solos não saturados. Acutis e Donatelli (2003) desenvolveram um software SOILPAR para estimar e criar mapas de parâmetros e funções hidrológicas do solo.

Segundo Ghanbarian et al. (2016), as funções de pedotransferência foram desenvolvidas usando várias técnicas, como regressão linear múltipla, redes neurais artificiais, programação genética, análise de árvore de decisão, método de tratamento de grupo, máquinas de vetor de suporte e regressão auxiliar de padrão de contraste.

FPT podem ser obtidas por vários métodos matemáticos, sendo que a maioria delas foi derivada através de métodos de regressão (FRANZMEIER, 1991).

A análise de Regressão Múltipla é uma metodologia estatística de previsão e estimação de valores de uma variável de resposta de interesse através de um conjunto de variáveis regressoras. Esta metodologia pode ser utilizada também para a

avaliação dos efeitos das variáveis regressoras como previsoras das variáveis de resposta (SILVA, 2017).

Dabral e Pandey (2016), concluíram que tanto a capacidade do campo como o ponto de murcha podem ser estimados usando Regressão Linear Múltipla, em diferentes profundidades do solo, utilizando propriedades de solo facilmente medidas, tais como densidade, porosidade, índice de vazios, percentual de silte e argila.

Soares (2013) afirma que o método de regressão mais utilizado, no contexto de geração de FPT é o *stepwise*. Segundo Nunes (2016) o procedimento *stepwise* é uma combinação de dois procedimentos: o avançado (*forward*) e seu contrário, o movimento para trás (*backward*), que é uma aplicação conjunta dos critérios de inclusão e exclusão de variáveis.

Nguyen (2017), afirma que as técnicas de regressão estatística fornecem modelos simples, razoáveis e fáceis de interpretar, mas também possuem várias desvantagens: os resultados das estimativas são fortemente tendenciosos no caso de uma amostra de tamanho pequeno; a forma correta da equação de regressão, que geralmente é desconhecida, deve ser determinada a priori; os pressupostos rigorosos sobre a distribuição de probabilidade de erro não são fáceis de cumprir em todo o intervalo de dados; e o mais importante, as equações de regressão precisam ser reconstruídas e republicadas caso novos dados estejam disponíveis.

Em contrapartida, a utilização de Inteligência Artificial (IA), através da Rede Neural Artificial (RNA) está se popularizando na última década. São sistemas que possuem a capacidade de ir além dos processos estabelecidos no seu desenvolvimento, sendo capazes de aprender, se adaptar e tomar decisões (LUSTOSA, 2010). A IA “é uma área da Ciência da Computação que compreende o projeto de sistemas computacionais que exibam características associadas, quando presentes no comportamento humano, a inteligência” (BARR & FEIGENBAUM, 1981).

Segundo Haykin (2001), “uma Rede Neural é um processador paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso”. Se assemelha ao cérebro humano em dois aspectos: adquire o conhecimento, de seu ambiente, através de um processo de aprendizagem; e possui forças de conexão

entre neurônios, conhecidas como pesos sinápticos, as quais são utilizadas para armazenar conhecimento.

Conforme Jain apud Gangasani (2016), quando se trabalha com a área agrícola, especialmente com atributos físico-hídricos do solo, as Redes Neurais Artificiais (RNA) são consideradas mais relevantes e úteis que outros métodos de inteligência artificial, como os Algoritmos Genéticos e a Lógica Fuzzy.

Desta forma trabalhos estão sendo desenvolvidos no sentido de comparar as FPT baseadas em RNA e baseadas em regressão (SOARES, 2013; PEREIRA, 2017; MERDUN, 2005; NGUYEN, 2017; CORNELIS, 2001; JAFARZADEH, 2016; TOMASELLA, 2003).

Segundo JOE e PRASANNA (2016), Rede Neural Artificial (RNA) é uma tentativa para desenvolver um modelo que funciona de forma semelhante ao cérebro humano e é análoga à função biológica de aprendizagem e memorização, compreendendo uma rede densa de conexões entre os dados de entrada, os neurônios dispostos em diferentes camadas escondidas com parâmetros, e os dados de saída.

Ainda conforme JOE e PRASANNA (2016), um modelo de Rede Neural Artificial consiste geralmente em várias camadas (entrada, oculta e saída), ligadas por meio de parâmetros, em analogia com as redes neurais do cérebro humano. Depois de ter sido devidamente submetida a um processo de treinamento, a RNA é capaz de generalizar a relação à qual aprendeu, a outras amostras no mesmo domínio. O número de camadas escondidas em uma rede neural de múltiplas camadas pode variar, dependendo da complexidade e da natureza do problema a ser modelado. A principal função desta camada é permitir que a rede possa capturar ambos os relacionamentos não-lineares fracos e fortes entre entradas e saídas.

Uma vantagem das RNA, em comparação com FPT estatísticas, é que as redes neurais não requerem um conhecimento prévio das relações entre os dados de entrada e saída, não necessitando assim de um modelo conceitual. Estas relações são obtidas e implementadas num procedimento de calibração iterativo. Desta forma, os modelos de redes neurais extraem a máxima quantidade de informação a partir dos dados fornecidos (PATIL E SINGH ,2016).

Com a implementação das redes neurais, a CRAS também pode ser estimada através de algoritmos de inteligência artificial utilizando bancos de dados disponíveis (PACHEPSKY et al., 1996; KOEKKOEK E BOOLTINK, 1999; JOHARI et al., 2006).

Soares (2013) trabalhando com geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul afirma que as funções de pedotransferência geradas por Redes Neurais Artificiais apresentaram capacidade preditiva superiores a análise de Regressão Linear Múltipla, nas diferentes classes texturas e potenciais matriciais estudados.

Braga (2014), trabalhando com estimativa dos parâmetros da resistência do solo ao cisalhamento através de pedotransferência, concluiu que apesar das funções de pedotransferência geradas por Regressão Linear Múltipla obterem um desempenho insatisfatório para estimativa dos parâmetros cisalhantes do solo para todos os conjuntos de dados utilizados, as Redes Neurais Artificiais apresentaram capacidade preditiva superior.

Pereira (2017) concluiu que as Redes Neurais Artificiais apresentaram capacidade preditiva superior aos demais modelos para estimativa da resistência do solo à penetração para dados de solos de mesma classe textural e mesmo manejo agrícola.

## 1.5 MATERIAIS E MÉTODOS

Este tópico objetiva apresentar o desenvolvimento do presente trabalho.

### 1.5.1 Bases de dados: obtenção e caracterização

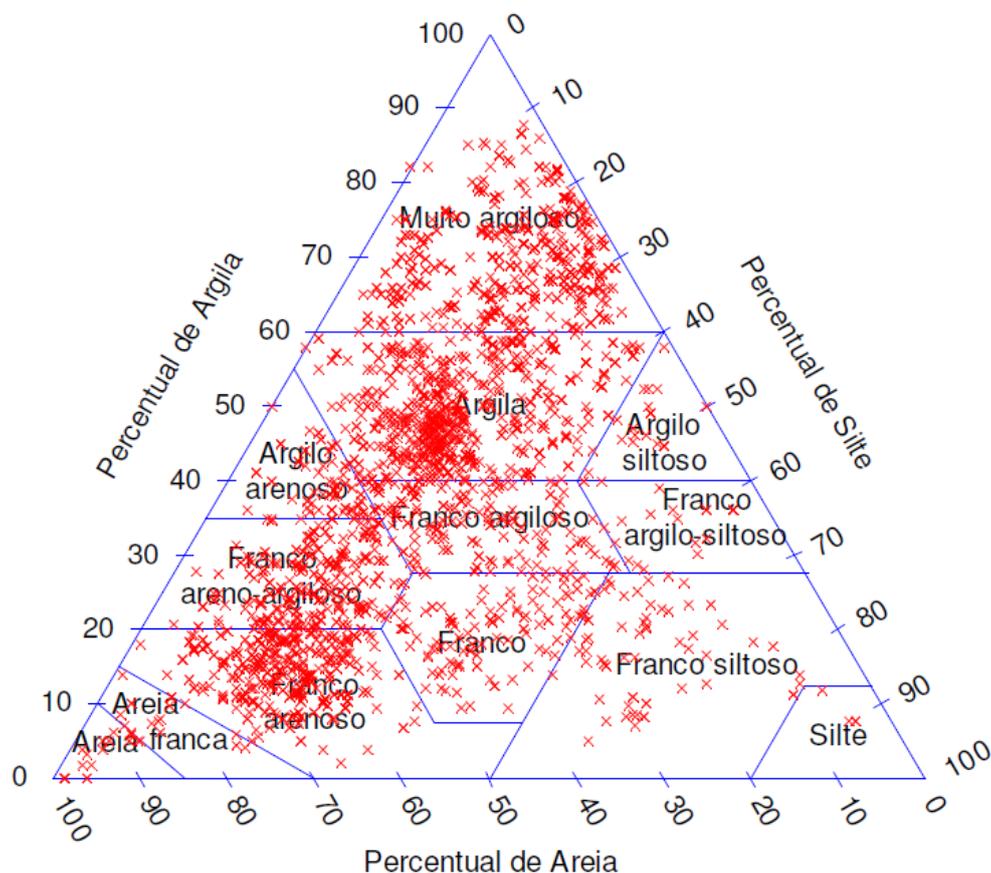
Os dados que foram utilizados no desenvolvimento deste trabalho foram obtidos da tese de doutorado de Soares (2013), os quais foram coletados na literatura e apresentam valores das características físico-hídricas e químicas de solos do Rio Grande do Sul (RS).

À base de dados inicial foram acrescentados os parâmetros do modelo estudo, que foram utilizados para as estimativas, os quais foram gerados através de ajustamento. Após foi realizado um procedimento de filtragem desta base utilizando o coeficiente de determinação como critério. Só foram utilizados os dados cujo  $R^2$  ficou acima de 0,9.

A utilização destes dados visa o desenvolvimento de funções de pedotransferência (FPT), para estimar os valores dos parâmetros da equação de Van Genuchten. Estes dados foram armazenados em uma base de dados armazenada em planilha eletrônica (Microsoft Excel).

Abaixo observa-se os dados dispostos em um triângulo textural (figura 1), no qual pode-se constatar uma predominância de solos com característica argilosa.

Figura 1 - Variabilidade textural dos solos do Estado do Rio Grande do Sul disponíveis na base de dados



Fonte: Soares (2013)

Destes dados, inicialmente, foram geradas oito tabelas na base de dados contendo valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis coletadas. Estas tabelas foram organizadas da seguinte forma: uma tabela contendo todos os dados, a qual denomina-se de dados gerais, e sete tabelas contendo os dados separados por classe textural, as quais foram nomeadas pela sua classe textural. Na Tabela 1 pode-se observar os dados estatísticos.

Tabela 1 - Valores mínimos, médios, máximos, desvio padrão e coeficiente de variação (CV)

Variável	Mínimo	Média	Máximo	Desvio Padrão	CV (%)
Argila (%)	5,00	38,38	86,70	20,48	53,35
Silte (%)	0,00	23,39	79,30	11,46	49,00
Areia (%)	1,01	38,24	80,00	20,69	54,10
Densidade do solo ( $\text{Mg m}^{-3}$ )	0,50	1,41	1,92	0,19	13,73
Dens. de partículas ( $\text{Mg m}^{-3}$ )	1,85	2,68	3,27	0,17	6,26
Matéria Orgânica (%)	0,00	0,02	0,98	0,08	353,87

Fonte: do autor

### 1.5.2 Desenvolvimento das Funções de Pedotransferência

Para estimar os parâmetros da equação de Van Genuchten, foram utilizados valores de propriedades físico-hídricas do solo, através de duas metodologias: Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA). Os parâmetros que foram utilizados para a validação dos resultados foram gerados através de um software desenvolvido especificamente para isso.

O conjunto de dados foi dividido aleatoriamente em 60% das amostras para a treinamento da rede e 20% para testes e 20% para a sua validação. Esta divisão se deu em função do grande número de dados.

Na Tabela 2 são apresentados os números de dados utilizados em cada fase do processo, para obtenção das FPT, nas distintas classes texturais.

Tabela 2 - Número de amostras utilizadas para treinamento, testes e validação nas distintas classes texturais

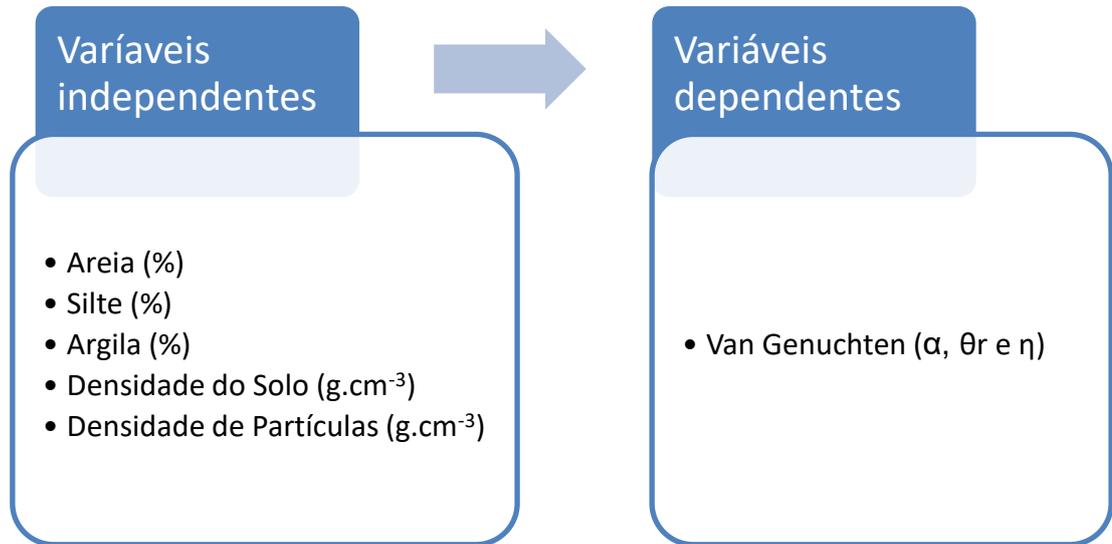
	Total	Treinamento	Testes	Validação
Geral	1067	639	214	214
Argilo arenoso	65	39	13	13
Argiloso	225	135	45	45
Franco	125	75	25	25
Franco arenoso	280	168	56	56
Franco argilo arenoso	230	138	46	46
Franco argiloso	114	68	23	23
Franco siltoso	28	16	6	6

Fonte: do autor

### 1.5.3 FPT geradas por regressão linear múltipla

Para as análises de regressão linear múltipla foi utilizado o procedimento *stepwise* do software IBM SPSS Statistics 25 tendo como variáveis independentes os seguintes dados: teores de areia, silte, argila e Matéria Orgânica, densidade do solo, densidade de partículas. As variáveis dependentes foram os parâmetros da equação de Van Genuchten. A Figura 2 mostra graficamente as entradas e saídas.

Figura 2 – Variáveis independentes e dependentes da RLM



Fonte: do autor

Primeiramente a base de dados foi submetida a uma análise de correlação, objetivando-se a identificação das variáveis que possuem maior efeito sobre os parâmetros a serem estimados.

Ao realizar as Regressões Lineares Múltiplas foi adotado o seguinte modus operandi: em cada passo, a variável independente fora da equação que tiver a menor probabilidade de F foi inserida, se essa probabilidade for suficientemente pequena. As variáveis que já estavam na equação de regressão foram removidas se a probabilidade de F foi suficientemente grande. O método finalizou quando não houve mais variáveis elegíveis para inclusão ou remoção. Todas as variáveis devem transmitir o critério de tolerância para serem inseridas na equação, independentemente do método de entrada especificado. O nível de tolerância padrão foi de 0,0001.

#### 1.5.4 FPT geradas a partir de Redes Neurais Artificiais

A segunda metodologia empregada foi a Inteligência Artificial (IA) através da técnica computacional de Redes Neurais Artificiais (RNA), que simulou uma estrutura

neural de organismos inteligentes para estimar os parâmetros da equação de Van Genuchten.

Para o desenvolvimento desta etapa foi utilizado o software IBM SPSS Statistics 25. As RNA do tipo *Perceptron* e foram treinadas através do algoritmo *backpropagation*.

#### 1.5.4.1 Definição da entrada e saída das RNA

As variáveis de entrada desta técnica foram as mesmas seis variáveis utilizadas como variáveis independentes na Regressão Múltipla Linear, ou seja, teores de argila, silte, areia e Matéria Orgânica, densidade de solo, densidade de partícula. As saídas da rede foram os parâmetros que deseja-se estimar, ou seja,  $\alpha$ ,  $\theta$  e  $n$  da equação de Van Genuchten.

#### 1.5.4.2 Treinamento e validação da RNA

A RNA foi treinada com 60% dos dados, utilizando o algoritmo de aprendizado de Retropropagação do Erro, que é um algoritmo iterativo para minimizar o erro quadrático médio entre o valor simulado e o valor esperado, dos parâmetros das equações nos dados de treinamento. Em cada iteração, os parâmetros  $W$  (pesos) e  $B$  (*bias* ou *viés*) da RNA foram atualizados por meio da regra de treinamento.

O procedimento de treinamento foi realizado mantendo constante o número de camadas (camada de entrada, oculta e saída), variando-se: o número de neurônios na camada oculta de forma automática, ou seja, deixando que o software escolhesse a melhor arquitetura. Desta forma a arquitetura da Rede Neural Artificial pode ser descrita com a seguinte notação:  $6 - n - 1$ .

Desta forma as redes neurais artificiais foram construídas com uma arquitetura fixa em relação ao número de camadas, perfazendo três camadas (entrada, oculta e saída). Os neurônios das camadas de entrada e oculta também não variaram, deixando a variação apenas na camada oculta.

Foi preestabelecido um número de rodadas fixas para o treinamento, neste caso, foram 10 rodadas. Este procedimento se deu em função dos pesos sinápticos serem inicializados a cada rodada, sendo obtidos resultados diferentes a cada rodada.

A RNA escolhida como melhor resultado foi a que obteve o maior  $R^2$  em relação aos dados de validação. Havendo resultados próximos na escolha da arquitetura, selecionou-se aquela com o menor número de neurônios na camada oculta. Sendo assim, foram desenvolvidas oito arquiteturas de redes neurais artificiais, uma para a base de dados geral (sem separação por classes texturais) e uma para cada base separada por classes texturais, totalizando sete arquiteturas.

### 1.5.5 Análise dos dados

Para medir a eficiência da estimativa dos parâmetros das equações, a partir do uso de RLM e RNA, utilizou-se o gráfico de relação 1:1, entre os dados estimados versus os dados ajustados, juntamente com o coeficiente de correlação ( $r$ ), para quantificar o grau de associação entre as duas variáveis envolvidas na análise; o coeficiente de determinação ( $R^2$ ) e a raiz do erro médio quadrado (RMSE), para medir o grau de ajuste do modelo proposto.

O coeficiente de correlação ( $r$ ) foi estimado pela equação 4.

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

Onde  $E_i$  são os valores estimados,  $O_i$  os valores observados,  $E$  a média dos valores estimados e  $O$  a média dos valores observados.

O coeficiente de determinação ( $R^2$ ) foi calculado pela equação 5:

$$R^2 = \frac{\sum(\hat{y}_i - \bar{y})^2}{\sum(y_i - \bar{y})^2} \quad (5)$$

Sendo  $\sum(\hat{y}_i - \bar{y})^2$ , a variação explicada pelo modelo e  $\sum(y_i - \bar{y})^2$ , a variação total.

A raiz do erro médio quadrado (RMSE), foi calculada conforme a equação 6

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2}$$

Onde  $n$  é o número de amostras,  $f$  são as previsões e  $o$  os valores observados

Os resultados foram analisados comparando os dados gerais ajustados com os dados gerais estimados por RLM e por RNA e levando-se em conta as classes texturais (dados ajustados x dados estimados para cada classe).

Um outro estudo foi a comparação dos parâmetros ajustados de cada classe textural com os parâmetros estimados, através de RLM e por RNA, para a base de dados geral, verificando assim se existe a possibilidade de substituir, com certo grau de acurácia, o parâmetro estimado para cada classe por um parâmetro estimado para o conjunto de dados geral.

Uma última análise, tem por finalidade avaliar qual metodologia apresentou maior capacidade preditiva: RLM ou RNA. Para isto foram utilizado os mesmos indicadores estatísticos das análises anteriores.

## 2 ARTIGO 1 – ESTIMATIVA DOS PARÂMETROS DO MODELO DE VAN GENUCHTEN VIA REGRESSÃO LINEAR MÚLTIPLA

Revista Agriambi

### Estimativa dos parâmetros do modelo de Van Genuchten via regressão linear múltipla

**Resumo:** A curva de retenção de água no solo é uma informação importante para o manejo racional da irrigação. Devido a dificuldade na geração da mesma através de métodos tradicionais, existe a necessidade da criação de métodos alternativos, como as funções de pedotransferência, que geram a curva de forma indireta, utilizando dados que podem ser adquiridos de forma mais fácil e rápida. Neste contexto, o presente trabalho objetiva estimar os parâmetros do modelo de Van Genuchten através de funções de pedotransferência com dados físico-hídricos para solos do estado do Rio Grande do Sul utilizando Regressão Linear Múltipla. Para estimar os parâmetros  $\theta_r$ ,  $\alpha$  e  $n$  da equação de Van Genuchten, foram utilizados os teores de areia, silte, argila, densidade do solo, densidade de partículas e Matéria Orgânica como variáveis independentes. As análises de regressão linear múltipla foram realizadas utilizando o procedimento stepwise (Forward) do software IBM SPSS Statistics 25. Os resultados obtidos na estimativa dos parâmetros  $\alpha$ ,  $\theta_r$  e  $n$  podem ser considerados excelentes, já que os valores do coeficiente de determinação foram superiores a 0,9 na maioria dos modelos propostos, e a raiz do erro médio quadrado apresentou valores inferiores a 0,008. Com isto, podemos afirmar que o uso de Regressão Linear Múltipla se mostrou eficiente em gerar Funções de Pedotransferência, para a base de dados utilizada, estimando os parâmetros da equação de Van Genuchten com alta capacidade preditiva dos modelos propostos.

**Palavras chave:** curva de retenção de água no solo, irrigação, atributos físico-hídricos do solo, Van Genuchten

## **Estimation of the parameters of the Van Genuchten model using multiple linear regression**

**Abstract:** The soil water retention curve is an important information for the rational management of irrigation. Due to the difficulty in generating it through traditional methods, there is a need to create alternative methods, such as pedotransfer functions, that generate the curve indirectly, using data that can be acquired more easily and quickly. In this context, the present work aims to estimate the parameters of the Van Genuchten model through pedotransfer functions with physical-hydro data for soils of the state of Rio Grande do Sul using Multiple Linear Regression. To estimate the parameters  $\theta_r$ ,  $\alpha$  and  $n$  of the Van Genuchten equation, the levels of sand, silt, clay, soil density, particle density and organic matter were used as independent variables. The multiple linear regression analyzes were performed using the stepwise (Forward) procedure of the IBM SPSS Statistics 25 software. The results obtained in the estimation of the parameters  $\alpha$ ,  $\theta_r$  and  $n$  can be considered excellent, since the values of the coefficient of determination were higher than 0,9 in most of the proposed models, and the root mean square error presented values lower than 0.008. With this, we can affirm that the use of Multiple Linear Regression was efficient in generating Pedotransfer Functions for the database used, estimating the parameters of the Van Genuchten equation with high predictive capacity of the proposed models.

**Key words:** soil water retention curve, irrigation, soil physical-water attributes, Van Genuchten

## INTRODUÇÃO

A compreensão da retenção de água é uma condição essencial para descrever detalhadamente o solo (GRIGOLON, 2013). Uma das formas de compreender esta característica é através da curva de retenção de água no solo (CRAS) que nada mais é do que a relação entre a quantidade de água em um volume de solo (DALMAGO et al., 2009).

Existem vários métodos experimentais para a determinação da curva de retenção da água no solo, cada um com suas peculiaridades, vantagens e limitações. Muitas vezes é necessário o uso de mais de um método para obter uma faixa mais ampla dos valores de umidade (SOARES, 2013). Esta determinação pode deprender tempo e ser onerosa no que tange ao custo do processo.

Desta forma, existe a necessidade da criação de métodos alternativos, que se caracterizam pela estimativa indireta de propriedades físico-hídricas do solo, chamados de funções de pedotransferência (FPT), conforme mencionado por Bouma e Lamén (1987). Estes métodos permitem a estimativa das propriedades hidráulicas a partir de informações facilmente mensuradas ou prontamente disponíveis (RAJKAI et al., 2004).

O desenvolvimento e uso de funções de pedotransferência para estabelecer a relação entre as características do solo facilmente mensuráveis ou prontamente disponíveis e os parâmetros de entrada de modelos mais complexos vem aumentando. As FPT podem ser obtidas por vários métodos matemáticos, sendo que, a maioria delas foi derivada através de métodos de regressão (NGUYEN et al., 2015).

Neste contexto, o presente trabalho objetiva estimar os parâmetros do modelo de Van Genuchten através de funções de pedotransferência com dados físico-hídricos para solos do estado do Rio Grande do Sul utilizando Regressão Linear Múltipla.

## MATERIAL E MÉTODOS

Os dados que foram utilizados no desenvolvimento deste trabalho foram obtidos da tese de doutorado de Soares (2013), e apresentam valores das características físico-hídricas e químicas de solos do Rio Grande do Sul (RS). A utilização destes dados visou o desenvolvimento de funções de pedotransferência (FPT), para estimar os valores dos parâmetros da equação de Van Genuchten.

Inicialmente, foram geradas oito tabelas na base de dados contendo valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis coletadas. Estas tabelas foram organizadas da seguinte forma: uma tabela contendo todos os dados, a qual denominamos de dados gerais, e sete tabelas contendo os dados separados por classe textural, as quais foram nomeadas pela sua classe textural.

Para estimar os parâmetros da equação de Van Genuchten, foram utilizados valores de propriedades físico-hídricas do solo, através de Regressão Linear Múltipla (RLM). Os parâmetros que foram utilizados para a regressão e posterior validação dos resultados foram gerados através de um software desenvolvido especificamente para isso.

O conjunto de dados foi inicialmente dividido aleatoriamente em 60% das amostras para realizar o procedimento de regressão, 20% para possíveis testes e 20% para a sua validação. Na Tabela 1 são apresentados os números de dados utilizados em cada fase do processo, para obtenção das FPT, nas distintas classes texturais.

Tabela 1. Número de amostras utilizadas, para geração e validação das FPT

	Total	Treinamento	Testes	Validação
Geral	1067	639	214	214
Arenoso	1	1	0	0
Argilo-arenoso	65	39	13	13
Argiloso	225	135	45	45
Franco	125	75	25	25
Franco Arenoso	280	168	56	56
Franco Argilo Arenoso	230	138	46	46
Franco Argiloso	114	68	23	23
Franco Siltoso	28	16	6	6

Para as análises de regressão linear múltipla foi utilizado o procedimento stepwise (Forward) do software IBM SPSS Statistics 25 tendo como variáveis independentes os seguintes dados: teores de areia, silte, argila, densidade do solo ( $\rho_s$ ), densidade de partículas ( $\rho_p$ ) e Matéria Orgânica (Mo). As variáveis dependentes são os parâmetros,  $\theta_r$ ,  $\alpha$  e  $n$  da equação de Van Genuchten, conforme Eq. 1.

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{[1 + (\alpha\Psi)^n]^m} \quad (1)$$

Sendo:

$\theta$  - é o teor de água no potencial matricial ( $\Psi$ ),  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$\theta_s$  - teor de água saturado,  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$\theta_r$  - teor de água residual,  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$n$  - fator de forma curva que controla o grau de inclinação da curva de retenção em forma de S;

$m$  - fator de forma empírica relacionada com  $n$  através de  $m = 1 - (1/n)$ ;

$\alpha$  - parâmetro empírico de escala relacionado com o inverso da função de aspiração de entrada de ar,  $\text{cm}^{-1}$ .

Primeiramente a base de dados foi submetida a uma análise de correlação, objetivando-se a identificação das variáveis que possuem maior efeito sobre os parâmetros a serem estimados.

Ao realizar as Regressões Lineares Múltiplas foi adotado o seguinte modus operandi: em cada passo, a variável independente fora da equação que tiver a menor probabilidade de F foi inserida, se essa probabilidade for suficientemente pequena. As variáveis que já estavam na equação de regressão foram removidas se a probabilidade de F foi suficientemente grande. O método finalizou quando não houve mais variáveis elegíveis para inclusão ou remoção. Todas as variáveis devem transmitir o critério de tolerância para serem inseridas na equação, independentemente do método de entrada especificado. O nível de tolerância padrão foi de 0,0001.

Para medir a eficiência da estimativa dos parâmetros das equações, a partir do uso de RLM, usou-se o gráfico de relação 1:1, entre os dados estimados versus os dados ajustados. Além deste, utilizou-se o coeficiente de correlação ( $r$ ), para quantificar o grau de associação entre as duas variáveis envolvidas na análise; coeficiente de determinação ( $R^2$ ), coeficiente de determinação ajustado ( $R^2$  Ajust) e a raiz do erro médio quadrado, para medir o grau de ajuste do modelo proposto.

## **RESULTADOS E DISCUSSÃO**

Analisando as variáveis independentes (Areia, Silte, Argila, Densidade do Solo, Densidade de Partícula e Matéria Orgânica) e os parâmetros ajustados utilizados para a validação dos dados como variáveis dependentes, pode-se afirmar que, com exceção da Matéria Orgânica, os dados apresentam uma distribuição normal, conforme demonstrado pelos coeficientes de assimetria e curtose (Tabela 2). Destaca-se a Densidade de Partícula que possui o menor coeficiente de

variação com 1,1%, variando de 2,62 g cm<sup>-3</sup> a 2,76 g cm<sup>-3</sup>. Em contrapartida, a Matéria Orgânica, apresenta o maior coeficiente de variação com uma amplitude de 0 até 0,98 %. A Matéria Orgânica, possui uma distribuição assimétrica positiva, com um coeficiente de assimetria de 8,27 e um coeficiente de curtose de 76,01, o que demonstra uma distribuição leptocúrtica à esquerda, corroborando com Carvalho et al. (2003) e Mello et al. (2005).

Tabela 2. Estatística descritiva da base de dados

	Argila (%)	Silte (%)	Areia (%)	MO (%)	ds (g cm <sup>-3</sup> )	dp (g cm <sup>-3</sup> )
N	1067	1067	1067	1067	1067	1067
Média	27,854	23,478	48,614	0,022	1,406	2,697
Erro de média padrão	0,377	0,360	0,404	0,002	0,002	0,001
Mediana	25,400	21,200	48,400	0,007	1,398	2,701
Modo	10,300	22,000	39,000	0,000	1,374	2,713
Erro Desvio	12,314	11,749	13,200	0,078	0,063	0,030
Variância	151,635	138,033	174,235	0,006	0,004	0,001
Assimetria	0,350	1,194	-0,084	8,265	0,182	-0,182
Curtose	-1,011	1,537	-1,286	76,013	-0,813	-0,813
Intervalo	55,200	67,700	54,900	0,976	0,297	0,140
Mínimo	3,800	1,000	18,400	0,000	1,271	2,621
Máximo	59,000	68,700	73,300	0,976	1,568	2,761
CV	44,209	50,042	27,152	353,873	4,474	1,104

Considerando o conjunto como um todo, ou seja, sem separação por classes, pode-se observar que a argila foi a variável com a maior correlação com o parâmetro  $\alpha$ , com uma correlação positiva (Tabela 3). Observa-se também que a maior correlação para o parâmetro  $n$  foi com as variáveis de densidade do solo e densidade de partícula, sendo que a densidade do solo com uma correlação positiva e a densidade de partículas com uma correlação negativa. Quanto ao parâmetro  $\theta_r$ , pode-se afirmar que o mesmo possui melhor correlação com a areia e com a argila, com valores de -0,910 e 0,851, respectivamente.

Os dados, quando separados, foram dispostos em sete classes texturais variando de argilo arenoso até franco argiloso, classes estas que representam os solos mais utilizados na agricultura conforme relatado também por Hodnett e Tomasella (2002). As classes com o maior número de amostras foram a franco argilo arenosa, franco arenosa e a argilosa (Tabela 1).

A argila foi a variável de maior correlação com o parâmetro  $\alpha$  nas classes argilo arenoso, franco e argiloso, sendo a segunda variável de maior correlação nas classes franco siltoso e franco arenoso, não sendo muito representativa apenas nas classes franco argilo arenoso e franco argiloso. O silte também possui correlação com o parâmetro  $\alpha$  nas classes argilo arenoso, franco argilo arenoso, argiloso e franco arenoso, sendo que nesta última é a variável de maior correlação. Wang et al. (2015) estudaram a variabilidade espacial dos parâmetros do solo do modelo de Van Genuchten em escala regional e encontraram forte correlação da argila com os parâmetros da equação de Van Genuchten, ao contrário de Carducci et al. (2011), que trabalharam com modelagem da curva de retenção de água de latossolos utilizando a equação duplo Van Genuchten e não obtiveram qualquer evidência de relação linear entre a argila e os parâmetros empíricos de ajuste do modelo.

Já o parâmetro  $n$ , em todas as classes texturais, obteve uma maior correlação com a densidade do solo e a densidade de partícula, sendo que a primeira uma correlação positiva e a segunda uma correlação negativa, o que vai ao encontro do trabalho realizado por Tormena e Silva (2002), que pesquisaram a incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo e encontraram relação da densidade do solo com o parâmetro  $n$ . Grego e Vieira (2005), que trabalharam com variabilidade espacial de propriedades físicas do solo em uma parcela experimental e também afirmaram que há correlação positiva entre retenção de água e densidade do solo.

Tabela 3. Correlação das variáveis independentes com as variáveis dependentes

Variável	Classe Textural	$\alpha$	n	$\theta_r$	Classe Textural	$\alpha$	n	$\theta_r$
Argila	Argilo Arenoso	0,889	0,324	0,787	Argiloso	0,859	0,458	0,780
Silte		-0,789	-0,292	0,009		-0,744	-0,422	-0,560
Areia		0,095	0,044	-0,781		0,122	0,134	-0,241
MO		0,089	-0,046	-0,328		0,019	0,169	0,049
ds		-0,270	0,939	0,197		-0,418	0,886	-0,084
dp		0,270	-0,939	-0,197		0,418	-0,886	0,084
Argila	Franco	0,882	-0,083	0,752	Franco Arenoso	0,714	-0,023	0,612
Silte		0,101	-0,485	0,527		-0,890	-0,072	0,259
Areia		-0,671	0,470	-0,948		0,569	0,106	-0,775
MO		0,300	-0,264	0,299		-0,191	0,027	-0,016
ds		-0,139	0,779	0,086		-0,452	0,967	0,235
dp		0,139	-0,779	-0,086		0,452	-0,967	-0,235
Argila	Franco Argilo Arenoso	0,527	0,021	0,838	Franco Argiloso	0,475	0,224	0,284
Silte		-0,714	-0,095	0,376		0,392	-0,361	0,653
Areia		0,250	0,067	-0,899		-0,734	0,296	-0,932
MO		0,232	-0,346	0,138		0,125	-0,075	0,078
ds		-0,582	0,984	0,112		-0,447	0,963	-0,179
dp		0,582	-0,984	-0,112		0,447	-0,963	0,179
Argila	Franco Siltoso	0,736	0,017	0,734	Geral	0,889	0,408	0,851
Silte		0,395	0,010	0,517		-0,397	-0,481	0,120
Areia		-0,860	-0,016	-0,958		-0,492	0,036	-0,910
MO		0,365	-0,387	0,234		0,013	-0,191	0,147
ds		-0,560	0,935	-0,344		-0,037	0,861	0,230
dp		0,560	-0,935	0,344		0,037	-0,861	-0,230

Em relação ao parâmetro  $\theta_r$  pode-se observar que a areia e argila são as variáveis que possuem maior correlação em todas as classes. A areia possui a correlação nas classes franco, franco argilo arenoso, franco siltoso, franco arenoso e franco argiloso, todas com correlações negativas, sendo a segunda variável de maior correlação nas classes argilo arenoso, e argiloso. A argila possui correlação positiva e foi a variável de maior correlação nas classes argilo arenoso, e argiloso, ficando em segundo lugar nas demais classes. Toth (2015) em seu trabalho sobre Nova geração de funções de pedotransferência hidráulicos para a Europa também encontrou uma forte correlação entre  $\theta_r$  e a areia.

É importante salientar que, uma variável, mesmo com uma correlação alta, poderá não ser incorporada ao modelo se a inserção dela causar a perda de performance do modelo conforme

(FIELD, 2013). Isto ocorreu em diversos modelos, como por exemplo, nas estimativas do parâmetro  $n$ , onde pode-se observar que a densidade do solo e densidade de partícula não foram utilizadas em conjunto, mesmo as duas possuindo alta correlação. Neste caso alguns modelos optaram por utilizar a variável densidade do solo e outros a variável densidade de partícula.

Como pode-se observar na Figura 1 que a estimativa do parâmetro  $\alpha$  apresentou um  $R^2$  superior a 0,9 na maioria das classes, com exceção da textura franco e franco argilosa, que apresentaram respectivamente 0,8150 e 0,7606. Quanto ao RMSE, observa-se que, mesmo as classes que obtiveram o  $R^2$  menor, possuem um valor de RMSE baixo. Sem a separação por classes, o  $R^2$  se manteve em 0,8533 e o RMSE em 0,00426. Wang et al. (2017), ao estimar curvas de retenção de água e propriedades de resistência de solos arenosos insaturados a partir de parâmetros básicos de gradação do solo, encontraram um  $R^2$  de 0,5762

A Figura 2 apresenta os valores de  $R^2$  e RMSE para a estimativa do parâmetro  $n$ . Ao contrário do parâmetro  $\alpha$ , os dados estimados para o parâmetro  $n$  apresentam um  $R^2$  superior a 0,9 em todas as classes, sendo que o menor valor deste indicador estatístico foi 0,9228 na classe franco siltosa. Da mesma forma, os valores de RMSE foram muito baixos em todas as classes texturais. Os dados, sem separação por classes, também apresentaram um menor  $R^2$  e um maior RMSE, 0,9202 e 0,007784, assim como aconteceu com o parâmetro  $\alpha$ . Valores de  $R^2$  maiores e RMSE menores que o encontrado por Qiao (2018) que desenvolveu funções de pedotransferência para propriedades hidráulicas do solo.

A Figura 3, contém os valores de  $R^2$  e RMSE para o parâmetro  $\theta_r$ , que, assim como o parâmetro  $n$ , obteve um coeficiente de determinação superior a 0,9 em todas as classes, sendo que, para este parâmetro, a classe franco argilosa foi a que apresentou um menor valor, 0,9510. Novamente, assim como nos parâmetros anteriores, os valores do RMSE foram muito baixos. No conjunto geral, sem separação por classes, pode-se observar que o valor do  $R^2$ , de 0,9737, é maior apenas do que o valor do mesmo indicador para a classe franco argilosa, mas o seu

RMSE foi o maior encontrado na estimativa deste parâmetro, com o valor de 0,005857. Valores de  $R^2$  maiores ao encontrado por Shwetha e Varija (2013), trabalharam com predição de retenção de água no solo a partir de funções de pedotransferência.

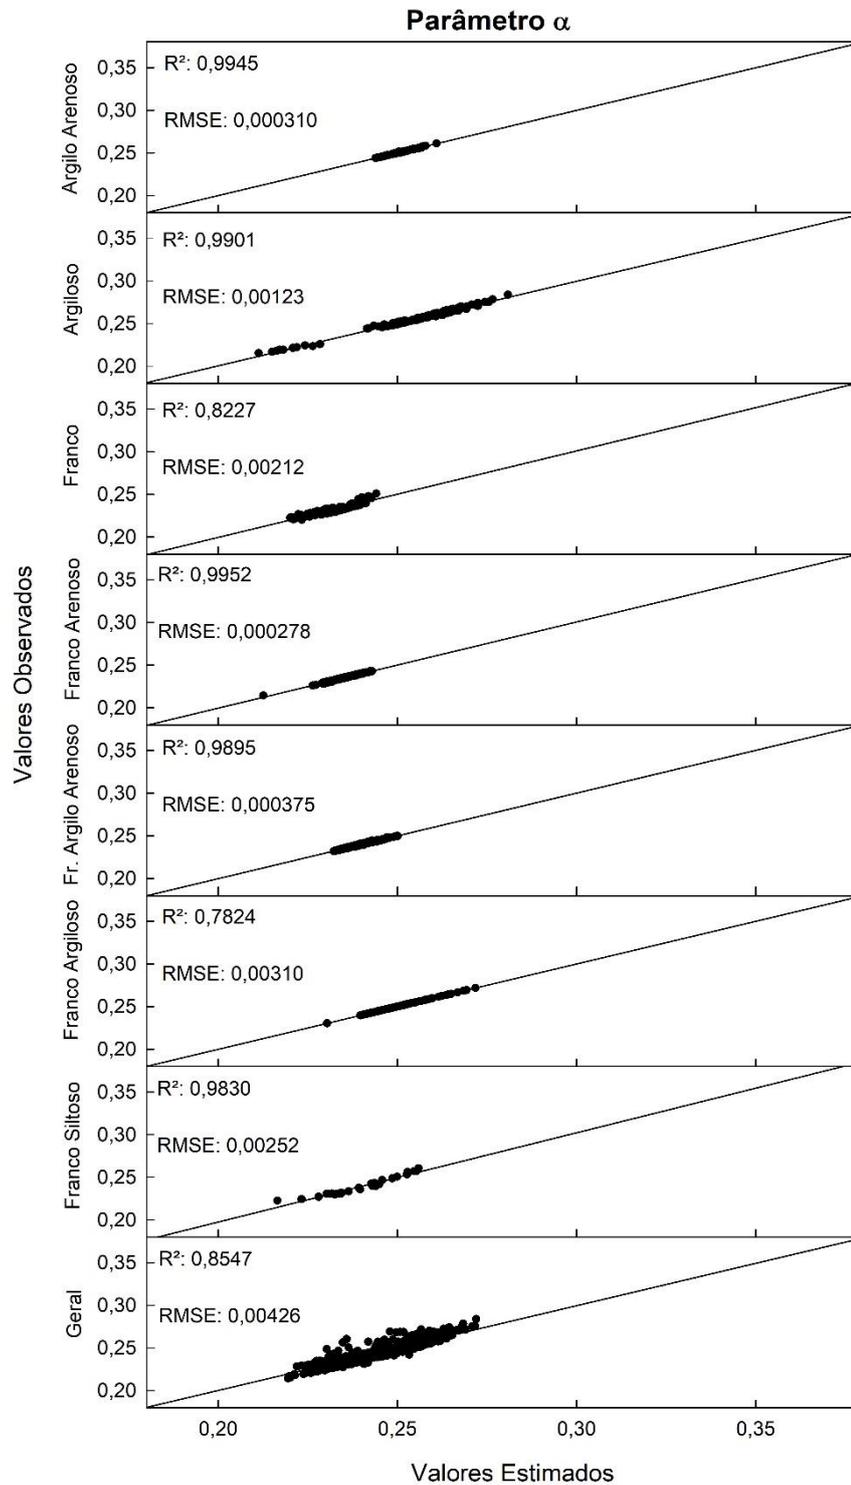


Figura 1. Gráficos valores estimados x valores observados para o parâmetro  $\alpha$

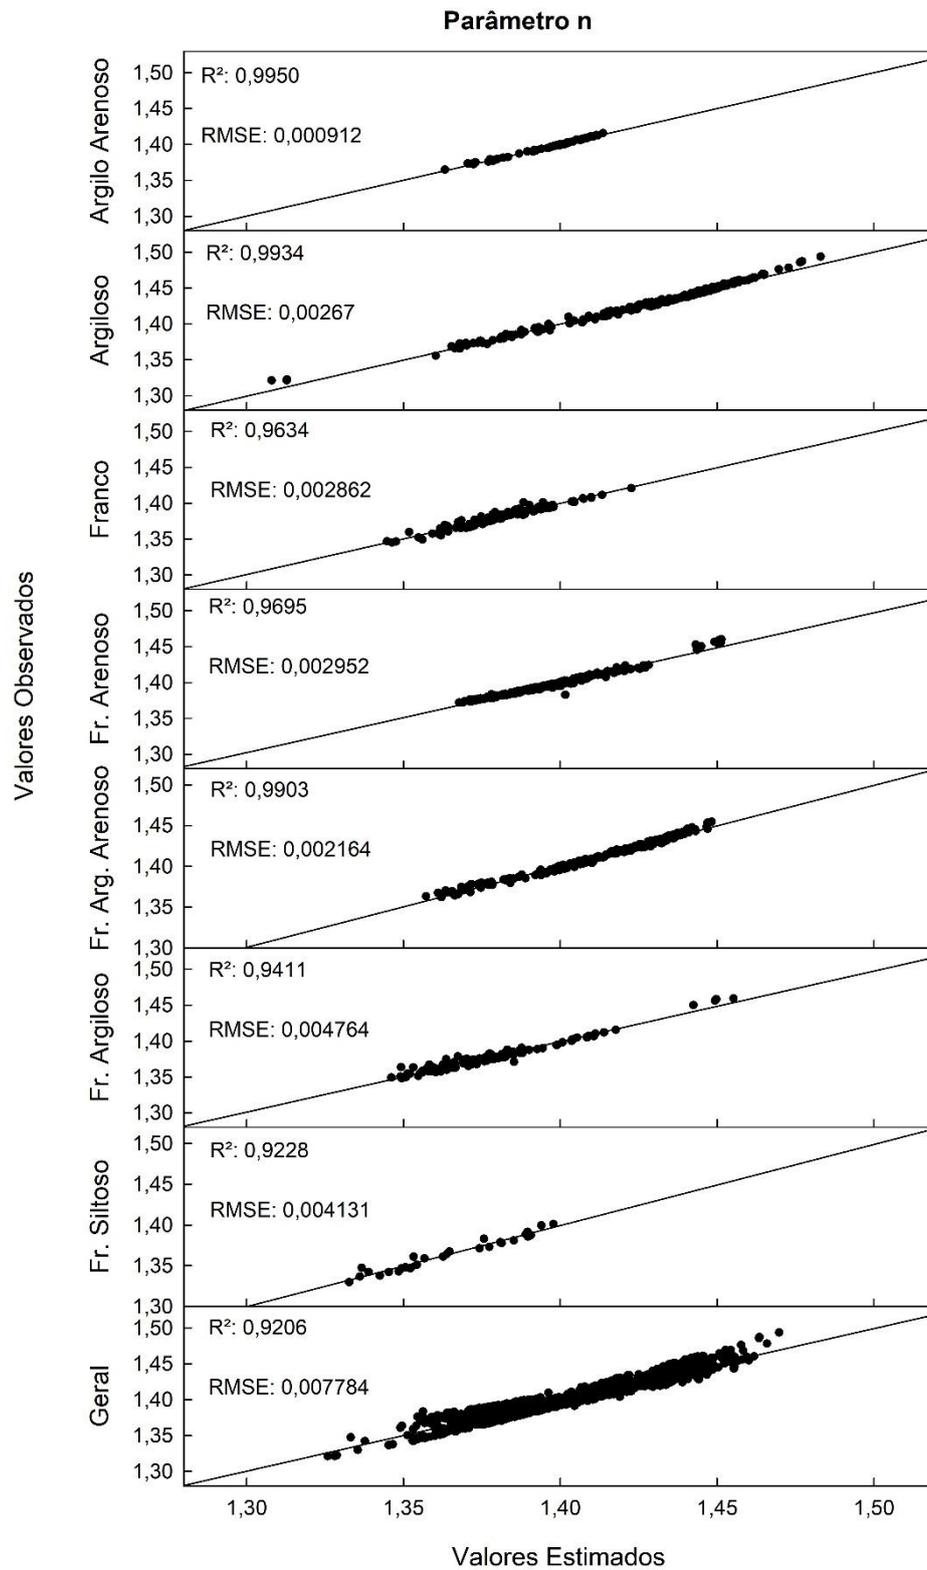


Figura 2. Gráficos valores estimados x valores observados para o parâmetro n

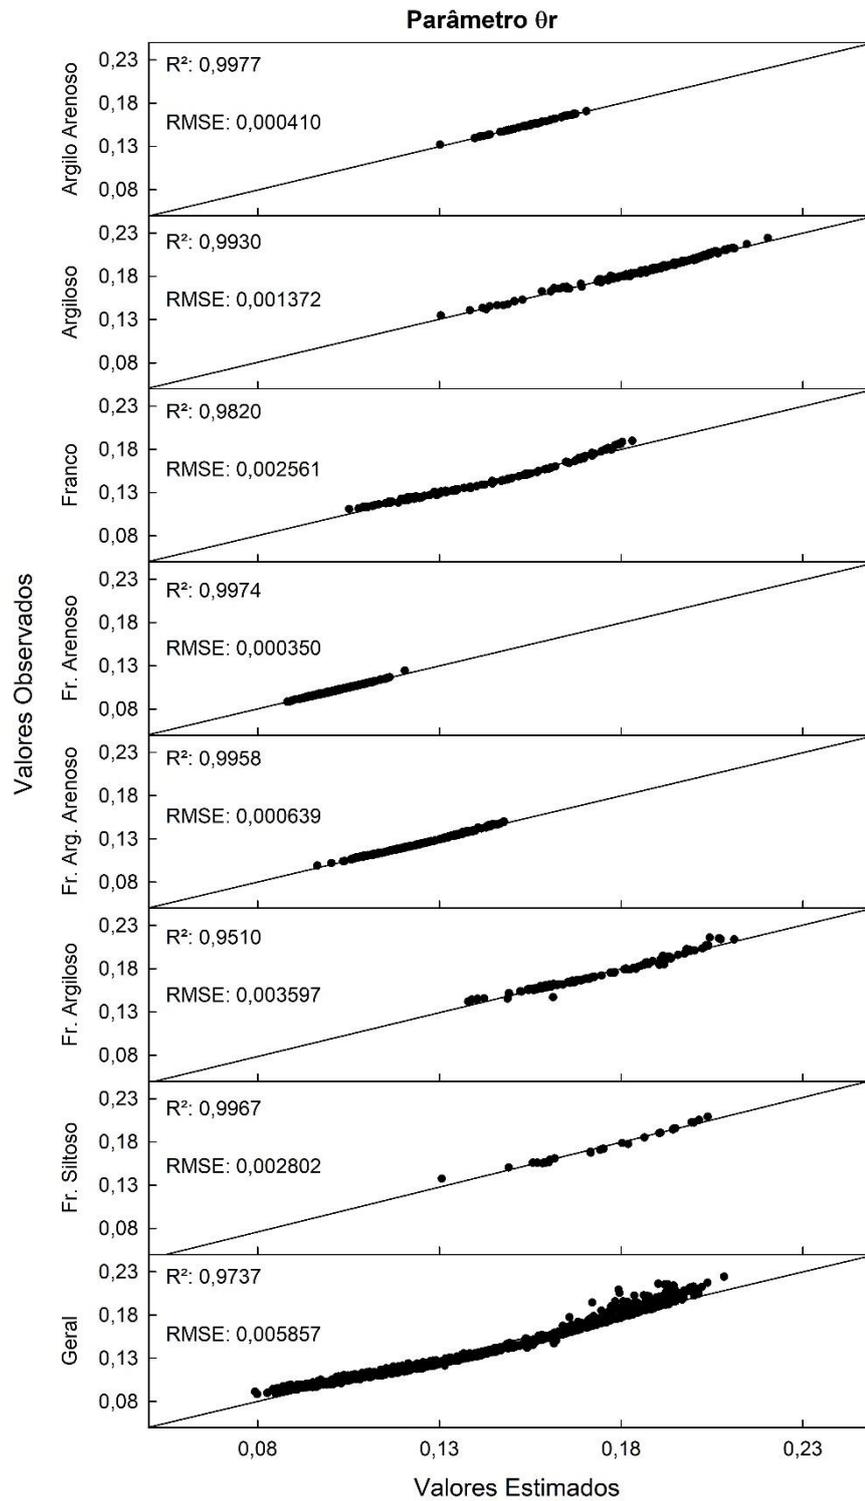


Figura 3. Gráficos valores estimados x valores observados amostrados para o parâmetro  $\theta r$

Considerando-se os indicadores propostos é possível afirmar que os modelos apresentados são muito eficientes em estimar os parâmetros  $\alpha$ ,  $\theta r$  e  $n$ , encontrando resultados muito próximos

aos obtidos por Yang e You (2013) em seu trabalho sobre a estimativa de parâmetros do modelo de Van Genuchten utilizando algoritmos inteligentes, e um coeficiente de determinação maior que Babaeian (2015) que realizou um estudo comparativo de múltiplas abordagens para prever a curva de retenção de água no solo, que comparou informações hyperspectrais e propriedades básicas no solo.

Os resultados também demonstram que a separação por classes texturais, revelou melhorar a capacidade preditiva dos modelos, como pode-se observar através do  $R^2$  e da RMSE, efeito similar ao apresentado por Soares (2013) e Nguyen et al.(2015) e em contrapartida ao encontrado por Barros et al. (2013). Esta melhoria nos resultados se dá porque segundo Wang et al. (2015) o grau de variação dos parâmetros é altamente dependente da textura do solo e estrutura, já que os mesmos são obtidos em função de características que possuem relação direta com a granulometria do solo, como porosidade e pressão de borbulhamento.

## CONCLUSÕES

1. Ao final deste trabalho pode-se concluir que o uso de Regressão Linear Múltipla se mostrou eficiente em gerar Funções de Pedotransferência paramétricas, para a base de dados utilizada. Sendo que os resultados obtidos com este trabalho denotam a qualidade da base de dados utilizada e retratam a realidade dos solos, cujas informações estão armazenadas na mesma.
2. A estimativa dos parâmetros da equação de Van Genuchten obteve um excelente coeficiente de determinação e uma raiz do erro médio baixa, o que demonstra um alto grau de ajuste do modelo, atingindo o seu objetivo.
3. Observou-se ainda que se obtém um resultado mais acurado quando se estima os parâmetros por classe textural.

4. Pode-se afirmar que a argila foi a variável mais utilizada nas estimativas, demonstrando a alta correlação entre a Curva de Retenção de Água no Solo e a textura do mesmo.

### LITERATURA CITADA

BABAEIAN, Ebrahim et al. A comparative study of multiple approaches for predicting the soil–water retention curve: Hyperspectral information vs. basic soil properties. *Soil Science Society of America Journal*, v. 79, n. 4, p. 1043-1058, 2015.

BARROS, Alexandre Hugo Cezar e cols. Funções de pedotransferência para estimar parâmetros de retenção de água em solos no nordeste do Brasil. *Revista Brasileira de Ciência do Solo*, v. 37, n. 2, p. 379-391, 2013.

BOUMA, J.; VAN LANEN, H. A. J. Transfer functions and threshold values: from soil characteristics to land qualities. 1987.

CARDUCCI, Carla Eloize et al. Modelagem da curva de retenção de água de Latossolos utilizando a equação duplo van Genuchten. *Revista Brasileira de Ciência do Solo*, v. 35, n. 1, p. 77-86, 2011.

CARVALHO, M. P.; TAKEDA, E. Y.; FREDDI, O. S. Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP). *Revista Brasileira de Ciência do Solo*, p. 695-703, 2003.

DALMAGO, Genei Antonio et al. Retenção e disponibilidade de água às plantas, em solo sob plantio direto e preparo convencional. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande. Vol. 13, supl.,(out. 2009), p. 855-864, 2009.

FIELD, Andy. *Discovering statistics using IBM SPSS statistics*. sage, 2013.

- GREGO, Celia Regina; VIEIRA, Sidney Rosa. Variabilidade espacial de propriedades físicas do solo em uma parcela experimental. *Revista Brasileira de Ciência do Solo*, v. 29, n. 2, p. 169-177, 2005.
- GRIGOLON, Gilmar Batista. Curva de retenção de água no solo determinada a partir de um número mínimo de pares de umidade e tensão na câmara de Richards. 2013. Tese de Doutorado. Universidade de São Paulo.
- HODNETT, M. G.; TOMASELLA, J. Marked differences between van Genuchten soil water-retention parameters for temperate and tropical soils: a new water-retention pedo-transfer functions developed for tropical soils. *Geoderma*, v. 108, n. 3-4, p. 155-180, 2002.
- MELLO, Carlos R. de et al. Modelos para determinação dos parâmetros da equação de van Genuchten para um Cambissolo. *Revista brasileira de engenharia agrícola e ambiental*, 2005.
- NGUYEN, Phuong Minh et al. Impact of regression methods on improved effects of soil structure on soil water retention estimates. *Journal of Hydrology*, v. 525, p. 598-606, 2015.
- QIAO, Jiangbo et al. Development of pedotransfer functions for soil hydraulic properties in the critical zone on the Loess Plateau, China. *Hydrological Processes*, v. 32, n. 18, p. 2915-2921, 2018.
- RAJKAI, Kálmán; KABOS, Sándor; VAN GENUCHTEN, M. Th. Estimating the water retention curve from soil properties: comparison of linear, nonlinear and concomitant variable methods. *Soil and Tillage Research*, v. 79, n. 2, p. 145-152, 2004.
- SHWETHA, P.; VARIJA, K. Soil water-retention prediction from pedotransfer functions for some Indian soils. *Archives of Agronomy and Soil Science*, v. 59, n. 11, p. 1529-1543, 2013.
- SOARES, Fátima Cibele. USO DE DIFERENTES METODOLOGIAS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERENCIA PARA A RETENÇÃO DE ÁGUA EM SOLOS

DO RIO GRANDE DO SUL. 2013. Tese de Doutorado. Universidade Federal de Santa Maria.

SOARES, Fátima Cibele, et al. Redes neurais artificiais na estimativa da retenção de água do solo. *Ciência Rural*, v. 44, n. 2, 2014.

TORMENA, C. A.; SILVA, AP da. Incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo. *Revista brasileira de ciência do solo*, v. 26, n. 2, 2002.

TÓTH, B. et al. New generation of hydraulic pedotransfer functions for Europe. *European journal of soil science*, v. 66, n. 1, p. 226-238, 2015.

WANG, Yunqiang et al. Spatial variability of soil parameters of the van Genuchten model at a regional scale. *CLEAN–Soil, Air, Water*, v. 43, n. 2, p. 271-278, 2015.

WANG, Ji-Peng et al. Estimating water retention curves and strength properties of unsaturated sandy soils from basic soil gradation parameters. *Water Resources Research*, v. 53, n. 7, p. 6069-6088, 2017.

YANG, Xu; YOU, Xueyi. Estimating parameters of van Genuchten model for soil water retention curve by intelligent algorithms. *Applied Mathematics & Information Sciences*, v. 7, n. 5, p. 1977, 2013.

### **3 ARTIGO 2 – ESTIMATIVA DOS PARÂMETROS DO MODELO DE VAN GENUCHTEN VIA REDES NEURAIIS ARTIFICIAIS**

Revista Engenharia Agrícola

#### **ESTIMATIVA DOS PARÂMETROS DO MODELO DE VAN GENUCHTEN VIA REDES NEURAIIS ARTIFICIAIS**

#### **RESUMO**

A curva de retenção de água no solo é uma informação importante para o manejo racional da irrigação. Devido a dificuldade na geração da mesma através de métodos tradicionais, existe a necessidade da criação de métodos alternativos e indiretos, como as funções de pedotransferência,. Neste contexto, o presente trabalho objetiva estimar os parâmetros do modelo de Van Genuchten através de funções de pedotransferência com dados físico-hídricos para solos do estado do Rio Grande do Sul utilizando Redes Neurais Artificiais. Para estimar os os parâmetros  $\theta_r$ ,  $\alpha$  e  $n$  da equação de Van Genuchten, foram utilizados os teores de areia, silte, argila, densidade do solo ( $d_s$ ), densidade de partículas ( $d_p$ ) e Matéria Orgânica (MO) como variáveis independentes. As Redes Neurais Artificiais foram geradas utilizando a função perceptron múltipla camada do software IBM SPSS Statistics 25. Os resultados obtidos na estimativa dos parâmetros  $\alpha$ ,  $\theta_r$  e  $n$  podem ser considerados excelentes, já que os valores do coeficiente de determinação foram superiores a 0,9 em todos os modelos propostos, e a raiz do erro médio quadrado apresentou valores inferiores a 0,0012. Com isto, podemos afirmar que o uso de Redes Neurais Artificiais se mostrou eficiente em estimar os parâmetros da equação de Van Genuchten com alta capacidade preditiva dos modelos propostos.

Palavras Chave: Inteligência artificial, Curva de retenção de água no solo, Funções de pedotransferência, Van Genuchten

## ESTIMATION OF PARAMETERS OF VAN GENUCHTEN'S MODEL BY ARTIFICIAL NEURAL NETWORKS

### ABSTRACT

The soil water retention curve is an important information for the rational management of irrigation. Due to the difficulty in generating it through traditional methods, there is a need to create alternative and indirect methods, such as pedotransfer functions. In this context, the present work aims to estimate the parameters of the Van Genuchten model through pedotransfer functions with physical-hydro data for soils of the State of Rio Grande do Sul using Artificial Neural Networks. To estimate the parameters  $\theta_r$ ,  $\alpha$  and  $n$  of the Van Genuchten equation, the levels of sand, silt, clay, soil density ( $d_s$ ), particle density ( $d_p$ ) and organic matter ( $M_o$ ) were used as independent variables. Artificial Neural Networks were generated using the multilayer perceptron function of the IBM SPSS Statistics 25 software. The results obtained in the estimation of the parameters  $\alpha$ ,  $\theta_r$  and  $n$  can be considered excellent since the coefficient of determination values were higher than 0.9 in all proposed models, and the root mean square error presented values lower than 0.0012. With this, we can say that the use of Artificial Neural Networks was efficient in estimating the parameters of the Van Genuchten equation with high predictive capacity of the proposed models.

Keywords: Artificial intelligence, Soil water retention curve, Pedotransfer functions, Van Genuchten

## INTRODUÇÃO

A curva de retenção de água no solo permite o conhecimento da relação entre o teor de água e a energia com a qual ela está retida, é essencial no estudo das relações solo-água (Da Silva et al., 2006). Desta forma, possui uma grande importância na agricultura irrigada, tanto no que se refere ao dimensionamento de sistemas de irrigação como ao manejo desses sistemas (Otto e Alcaide, 2001). A sua determinação por métodos diretos requer uso de equipamentos de alto custo e tempo elevado para a sua geração (Soares, 2013) e (Souza et Al., 2017).

Segundo Sattari e Toker (2016), vêm surgindo métodos de estimação a fim de reduzir o custo e o tempo necessários para análises de laboratório. Para Rajkai et al. (2004). estes métodos permitem a estimativa das propriedades hidráulicas a partir de informações facilmente mensuradas ou prontamente disponíveis e foram chamados de funções de pedotransferência (FPT) por Bouma e Lanen (1987).

Estas funções são oriundas de vários métodos matemáticos, sendo a maioria delas, obtida através de métodos de regressão (Nguyen et al., 2015). Com a evolução computacional, muitos destes trabalhos estão utilizando técnicas de Inteligência Artificial no desenvolvimento destas FPT, como as Redes Neurais Artificiais (RNA). Ao longo dos anos vários trabalhos foram desenvolvidos na tentativa de estimar o conteúdo de água no solo utilizando-se dados físico-hídricos, alguns deles fazendo uso de RNA como Moosavizadeh-Mojarrad e Sepaskhah (2011), Soares (2014) e Ebrahimi et al. (2014).

Mais recentemente destaca-se a contribuição de D’Emilio et al. (2018), que, estimaram os parâmetros da equação de Van Genuchten (1980), através de Redes Neurais Artificiais, utilizando um banco de dados sobre características físico-hídricas do solo.

D’Emilio et al. (2018) relataram que a escolha do modelo de Van Genuchten se deu em razão do mesmo ser o mais utilizado para este fim, pois a inclinação da curva de retenção de água no solo é contínua, evitando assim problemas de convergência numérica entre as umidades saturadas e residuais. Outros pontos que também podem ser levantados para esta escolha são a flexibilidade para o uso em vários tipos de solo, formação de uma curva suave, e por ser o mais utilizado tornou-se quase que um padrão mundial para modelos desse fim.

No entanto, FPT desenvolvidas a partir de bancos de dados com alguns tipos de condições regionais do solo podem não ser diretamente aplicável a outros solos cujas condições são diferentes daqueles usados no estabelecimento de FPT. (Yao et al., 2015).

Neste contexto, o presente trabalho objetiva estimar os parâmetros do modelo de Van Genuchten através de funções de pedotransferência com dados físico-hídricos para solos do estado do Rio Grande do Sul utilizando Redes Neurais Artificiais.

## MATERIAL E MÉTODOS

Os dados que foram utilizados no desenvolvimento deste trabalho foram obtidos da tese de doutorado de Soares (2013), e apresentam valores das características físico-hídricas e químicas de solos do Rio Grande do Sul (RS). A utilização destes dados visou o desenvolvimento de funções de pedotransferência (FPT), para estimar os valores dos parâmetros da equação de Van Genuchten (1), através de Redes Neurais Artificiais (RNA).

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{[1 + (\alpha\Psi)^n]^m} \quad (1)$$

Sendo:

$\theta$  - é o teor de água no potencial matricial ( $\Psi$ ),  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$\theta_s$  - teor de água saturado,  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$\theta_r$  - teor de água residual,  $\text{cm}^3 \cdot \text{cm}^{-3}$ ;

$n$  - fator de forma curva que controla o grau de inclinação da curva de retenção em forma de S;

$m$  - fator de forma empírica relacionada com  $n$  através de  $m = 1 - (1/n)$ ;

$\alpha$  - parâmetro empírico de escala relacionado com o inverso da função de aspiração de entrada de ar,  $\text{cm}^{-1}$ .

Inicialmente, foram geradas oito tabelas na base de dados contendo as variáveis coletadas. Estas tabelas foram organizadas da seguinte forma: uma tabela contendo todos os dados, a qual denominamos de dados gerais, e sete tabelas contendo os dados separados por classe textural, as quais foram nomeadas pela sua classe textural.

Posteriormente, através dos dados já armazenados na tabela, foram gerados os parâmetros da equação 1, que foram utilizados para o treinamento e posterior validação dos resultados. Estes parâmetros foram gerados por ajustamento através de um software desenvolvido especificamente para isso.

O conjunto de dados foi inicialmente dividido aleatoriamente em 60% das amostras para treinamento, 20% para possíveis testes e 20% para a sua validação. Na Tabela 1 são apresentados os números de dados utilizados em cada fase do processo, para obtenção das FPT, nas distintas classes texturais.

TABELA 1. Número de amostras utilizadas, para geração e validação das FPT, nas distintas classes texturais

Classes Texturais	Total	Treinamento	Testes	Validação
Geral	1067	639	214	214
Argilo-arenoso	65	39	13	13
Argiloso	225	135	45	45
Franco	125	75	25	25
Franco-arenoso	280	168	56	56
Franco-argilo-arenoso	230	138	46	46
Franco-argiloso	114	68	23	23
Franco-siltoso	28	16	6	6

Para o desenvolvimento das Redes Neurais Artificiais foi utilizado o procedimento Neural Network do software IBM SPSS Statistics 25. Estas foram do tipo Perceptron, e foi utilizado o algoritmo de treinamento backpropagation. Na estimativa dos parâmetros da equação de Van Genuchten ( $\theta_r$ ,  $\alpha$  e  $n$ ) aqui chamados de dados de saída, foram utilizados valores de propriedades físico-hídricas do solo, as quais foram chamadas de dados de entrada: teores de areia, silte, argila, densidade do solo ( $d_s$ ), densidade de partículas ( $d_p$ ) e Matéria Orgânica (MO).

O procedimento de treinamento foi realizado mantendo constante o número de camadas (camada de entrada, oculta e saída), variando-se: o número de neurônios na camada oculta de forma automática, ou seja, deixando que o software escolhesse a melhor arquitetura.

Desta forma as redes neurais artificiais foram construídas com uma arquitetura fixa em relação ao número de camadas, perfazendo três camadas (entrada, oculta e saída). Os neurônios das camadas de entrada e oculta também não variaram, deixando a variação apenas na camada oculta.

Foi preestabelecido um número de rodadas fixas para o treinamento, neste caso, foram 10 rodadas. Este procedimento se deu em função dos pesos sinápticos serem inicializados a cada rodada, sendo obtidos resultados diferentes a cada rodada.

A RNA escolhida como melhor resultado foi a que obteve o menor  $R^2$  em relação aos dados de validação. Havendo resultados próximos na escolha da arquitetura, selecionar-se-á aquela com o menor número de neurônios na camada oculta. Sendo assim, foram desenvolvidas oito arquiteturas de redes neurais artificiais, uma para a base de dados geral (sem separação por classes texturais) e uma para cada base separada por classes texturais, totalizando sete arquiteturas.

Após a geração das funções, testou-se a equação gerada com a base de dados geral, nas demais bases de dados, para verificar se é possível estimar os parâmetros de determinada classe textural com a equação da base de dados geral.

Para medir a eficiência da estimativa dos parâmetros das equações, a partir do uso de RNA, utilizou-se o coeficiente de determinação ( $R^2$ ) e a raiz do erro médio quadrado (RMSE), para medir o grau de ajuste do modelo proposto.

## **RESULTADOS E DISCUSSÃO**

A Figura 1 apresenta o percentual de contribuição das variáveis de entrada no modelo proposto para a estimativa do parâmetro  $\alpha$ . Observa-se que a argila foi a variável que mais contribuiu, tanto utilizando a base de dados geral, ou seja, sem separação, como nas bases de dados separadas por classes texturais. Em seis classes a argila obteve um grau de importância para a estimativa entre 0,299 e 0,389. Apenas a classe franco e a classe franco arenoso

apresentaram outras variáveis com maior importância nas suas estimativas, respectivamente a densidade de partícula e o teor de silte. Wang et al. (2015) estudando a variabilidade espacial dos parâmetros do solo do modelo de Van Genuchten encontrou correlação de 0,131 da argila com o parâmetro  $\alpha$ .

Na Figura 2, apresenta-se o percentual de contribuição das variáveis de entrada no modelo proposto para a estimativa do parâmetro  $n$ , e consta-se que a densidade de partícula foi a variável de entrada de maior contribuição na estimativa do parâmetro  $n$  utilizando-se a base de dados geral, com valores de 0,344. Quando a estimativa foi realizada com separação por classes texturais, observou-se que a densidade de partícula e a densidade do solo foram as variáveis mais importantes neste processo, variando entre 0,322 a 0,510. As exceções ficaram por conta das classes argiloso e franco, que para estimar o parâmetro  $n$ , tiveram uma contribuição de maior relevância dos teores de argila e areia, respectivamente. Tormena e Silva (2002), pesquisando sobre a incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo encontraram relação da densidade do solo com o parâmetro  $n$ , sendo responsável por 85 % da variação da retenção de água no solo.

A Figura 3 apresenta o percentual de contribuição das variáveis de entrada no modelo proposto para a estimativa do parâmetro  $\theta_r$ , onde percebe-se que o teor de areia e argila foram as variáveis de entrada mais significativas, variando entre 0,289 e 0,480 a sua participação na estimativa, tanto com ou sem separação por classes. Somente a classe argilo arenoso atribuiu maior importância a outra variável, neste caso, a densidade do solo. Bahmani e Palangi (2016) avaliando funções de pedotransferência para estimar os pontos da curva de retenção de água no solo encontrou correlação entre  $\theta_r$  e a areia, com um coeficiente de 0,117.

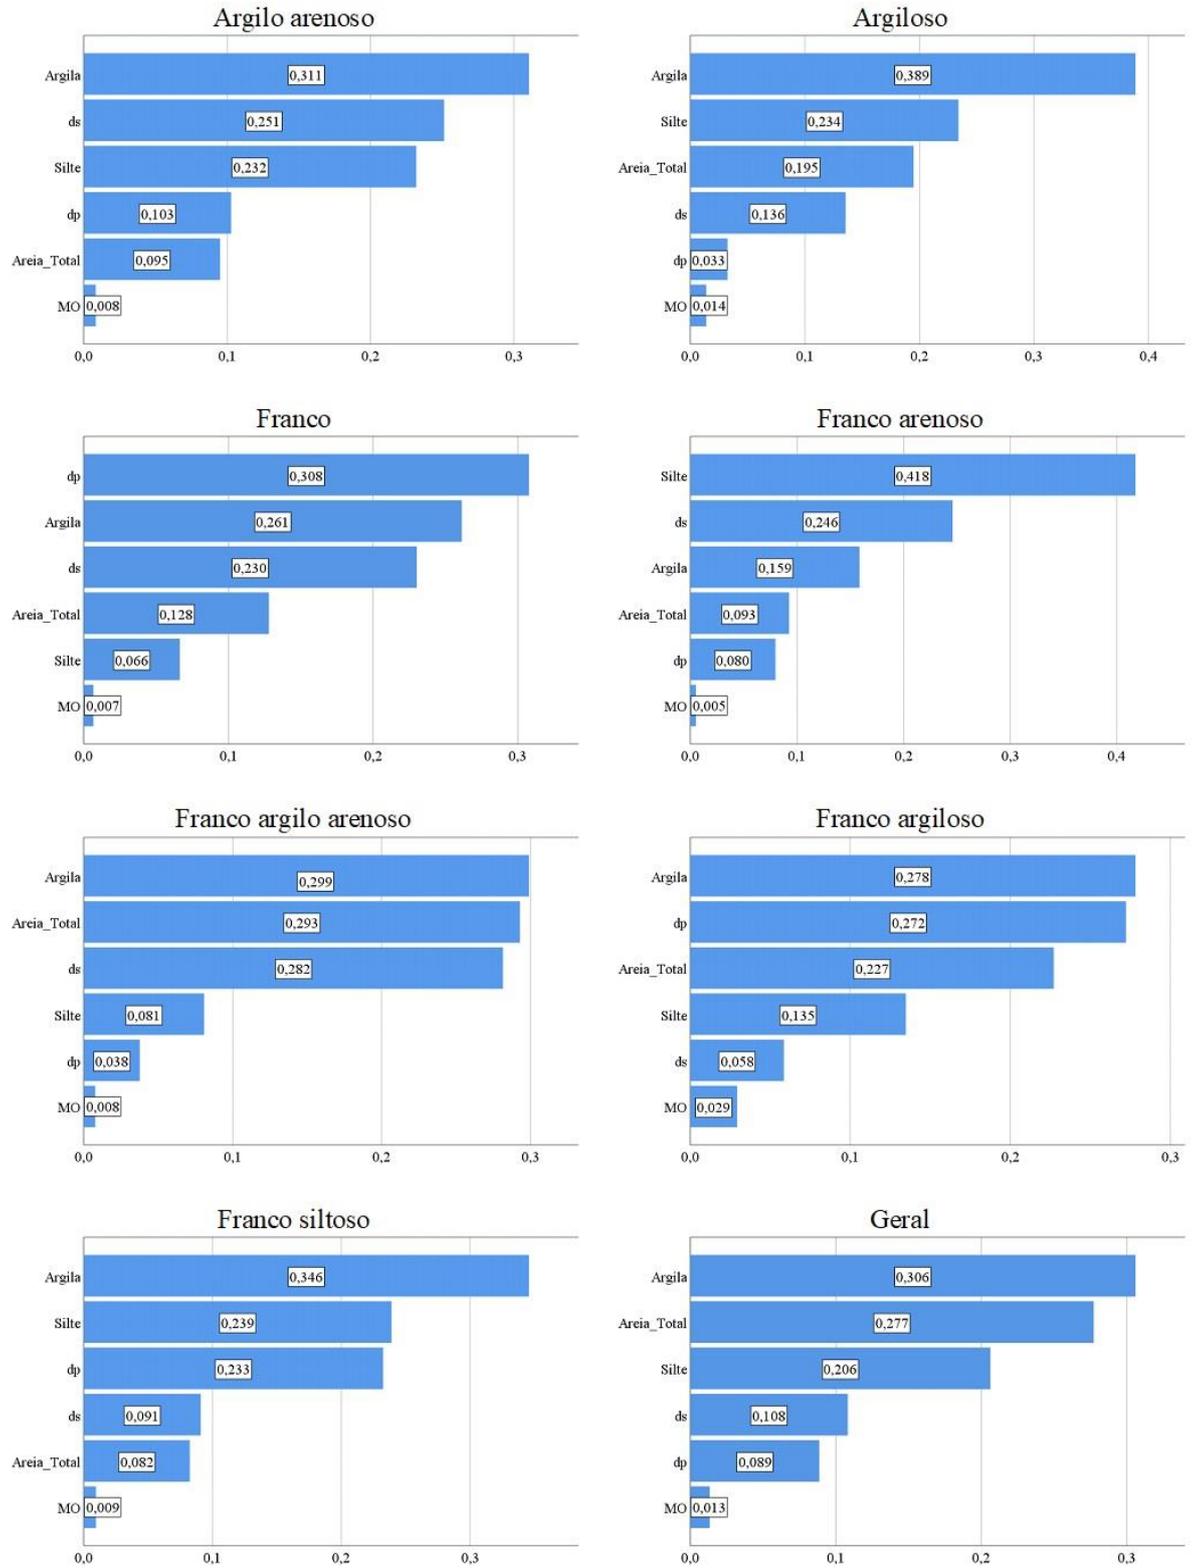


FIGURA 1. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro  $\alpha$

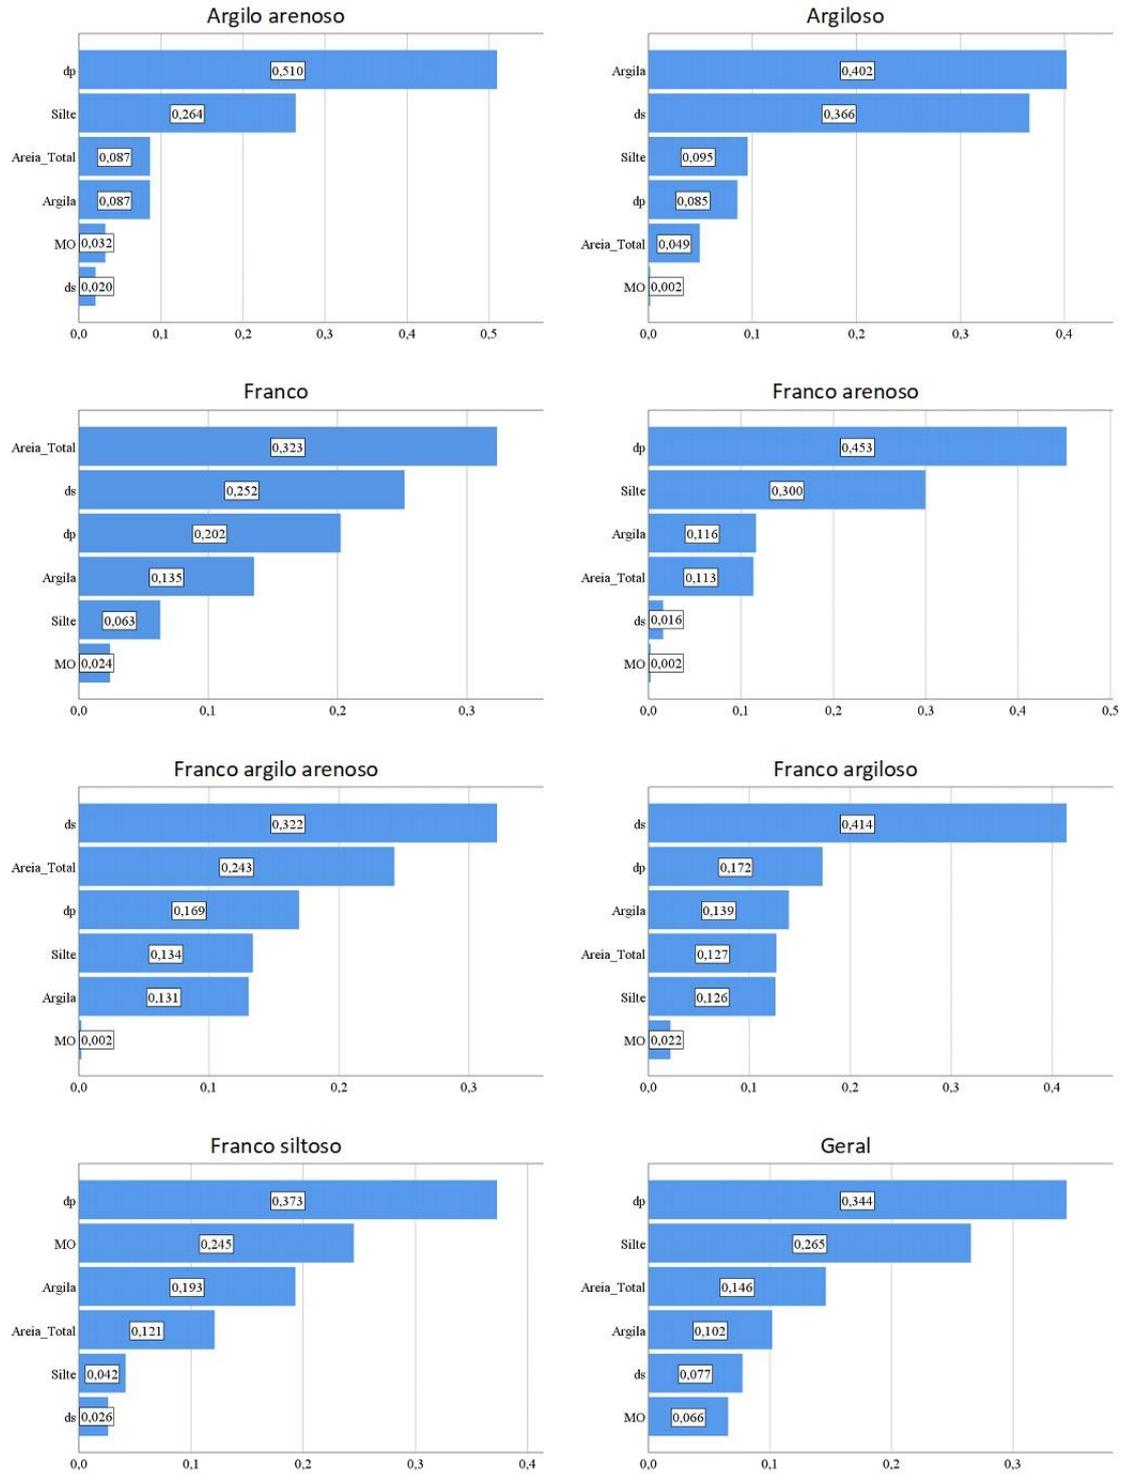


FIGURA 2. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro n

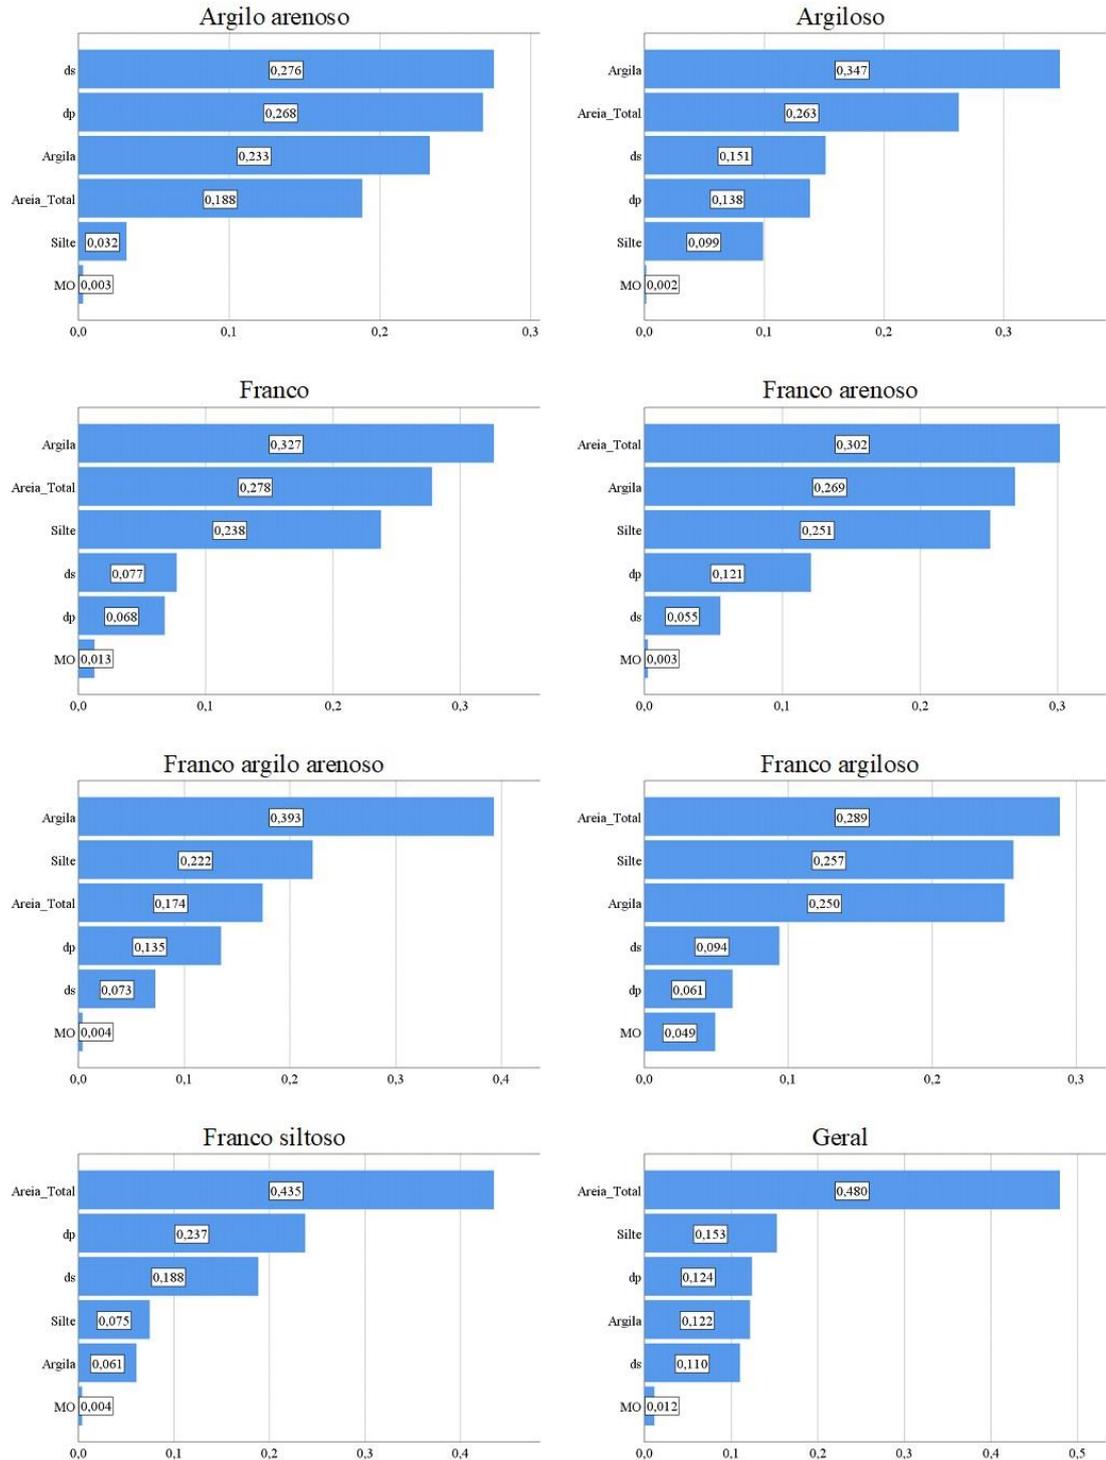


FIGURA 3. Percentual de contribuição das variáveis de entrada no modelo de estimativa para o parâmetro  $\theta_r$

A Tabela 2 apresenta o número de neurônios na camada oculta das oito redes neurais artificiais utilizadas para estimar os parâmetros. As arquiteturas com os melhores resultados para a estimativa do parâmetro  $\alpha$ , em sua maioria, apresentaram uma formação com três ou

quatro neurônios na camada oculta, a exceção ficou por conta da classe franco siltoso, que apresentou apenas dois neurônios nesta camada.

TABELA 2. Número de neurônios na camada oculta

Classe textural	Parâmetro $\alpha$	Parâmetro n	Parâmetro $\theta_r$
Argilo arenoso	4	3	2
Argiloso	3	3	4
Franco	3	3	2
Franco arenoso	4	4	2
Franco argilo arenoso	4	3	2
Franco argiloso	3	3	3
Franco siltoso	2	2	3
Geral	3	5	2

Para a estimativa do parâmetro n, verificou-se a predominância da arquitetura com três neurônios em sua camada oculta, com cinco redes nesta condição, mas três redes exigiram arquiteturas com dois, quatro e cinco neurônios em sua formação.

Já para a estimativa da umidade residual, a formação que apresentou melhor resultado foi composta por dois neurônios na camada oculta, com cinco redes, sendo que apenas duas formações apresentaram três neurônios, e uma apresentou quatro neurônios nesta camada.

As arquiteturas das redes neurais artificiais descritas na Tabela 2, apresentam um número de neurônios em sua camada oculta muito menor do que o encontrado por Ebrahimi et al. (2014) que apresentaram de 6 a 25 neurônios nas camadas ocultas em suas redes neurais artificiais quando trabalharam com capacidade de predição de diferentes modelos de curva de retenção

de água no solo utilizando redes neurais artificiais. Moosavizadeh-Mojarrad e Sepaskhah (2011) pesquisando redes neurais artificiais para previsão da curva de retenção de água no solo utilizaram de 5 a 13 neurônios nas camadas ocultas. Este resultado demonstra que as redes desenvolvidas nesta pesquisa, estimaram com maior facilidade os parâmetros, muito provavelmente devido a base de dados utilizada.

A Tabela 3 apresenta os indicadores de desempenho para a estimativa dos parâmetros  $\alpha$ ,  $n$  e  $\theta_r$ . Analisando os modelos de estimativa do parâmetro  $\alpha$  pode-se notar, devido ao seu índice de desempenho, uma alta capacidade de previsão, com valores de  $R^2$  entre 0,9922 e 0,9988 para as sete classes de solo utilizadas neste estudo. Desempenho este, que é corroborado pela raiz quadrada do erro médio, cujos valores ficaram entre 0,001 e 0,000099. Merdun et al. (2006), comparando funções de pedotransferência geradas por redes neurais artificiais e regressão, obtiveram valores de  $R^2$  abaixo de 0,5 e valores de RMSE acima de 0,1, resultados claramente menores em relação ao  $R^2$  e maiores quando toma-se por base o RMSE. Yang e You (2013), trabalhando com estimativa de parâmetros do modelo de Van Genuchten para a curva de retenção de água do solo através de algoritmos inteligentes, obtiveram  $R^2$  superior a 0,96 e RMSE entre 0,00618 a 0,03596, o que vai ao encontro do presente estudo.

Ao examinar-se o desempenho da estimativa para o parâmetro  $n$  constata-se que o  $R^2$  ficou acima de 0,99 em seis classes, ficando abaixo deste valor apenas na classe franco siltoso, com um valor de 0,9509. Mesmo assim, pode-se considerar que os resultados obtidos, quanto a este indicador, são bons, principalmente quando analisados em conjunto com o RMSE, cujos valores ficaram entre 0,00616 e 0,000532. Zou et al. (2015), trabalharam com estimativa de propriedades hidráulicas e encontraram valores de  $R^2$  e RMSE em torno de 0,55 e 0,03 respectivamente.

O parâmetro  $\theta_r$ , obteve uma estimativa, em termos de índice de desempenho, muito próxima ao parâmetro  $n$ . Os valores de  $R^2$  ficaram acima de 0,99 na grande maioria das classes,

ficando abaixo deste valor apenas na classe franco argiloso, com um valor de 0,9842. Os valores do RMSE variaram de 0,00212 a 0,00018, demonstrando, assim como nas estimativas dos parâmetros anteriores um alto grau de previsão. Este resultado foi melhor que o obtido por D’Emilio et al. (2018), que em sua pesquisa sobre redes neurais artificiais para prever a curva de retenção de água no solo, encontraram valores de RMSE acima de 0,06.

Em relação as estimativas utilizando a base de dados geral, pode-se perceber, analisando o  $R^2$  e a RMSE, que os três parâmetros foram estimados com valores superiores a 0,99 de  $R^2$ , o que demonstra um alto poder de determinação das redes neurais artificiais, o que pode ser corroborado através da análise da RMSE, que foi inferior a 0,003. Valores de  $R^2$  maiores que o encontrado por Haghverdi (2012) e Zhang e Schaap (2017) que estimaram os parâmetros do modelo de Van Genuchten através de propriedades físico-hidráulicas do solo.

TABELA 3. Indicadores de desempenho das estimativas dos parâmetros  $\alpha$ ,  $n$  e  $\theta_r$

Classe Textural	Parâmetro $\alpha$		Parâmetro $n$		Parâmetro $\theta_r$	
	$R^2$	RMSE	$R^2$	RMSE	$R^2$	RMSE
Argilo Arenoso	0,9988	0,000099	0,9984	0,000532	0,9990	0,000249
Argiloso	0,9976	0,000624	0,9992	0,000951	0,9988	0,000580
Franco	0,9974	0,000262	0,9946	0,001193	0,9993	0,000474
Franco Arenoso	0,9967	0,000211	0,9981	0,000685	0,9992	0,000185
Franco Argilo Arenoso	0,9971	0,000194	0,9990	0,000710	0,9995	0,000219
Franco Argiloso	0,9969	0,000365	0,9917	0,001622	0,9842	0,002119
Franco Siltoso	0,9922	0,00100	0,9509	0,00616	0,9990	0,00126
Geral	0,9973	0,000577	0,9943	0,002076	0,9988	0,001232

Os resultados também demonstram que a separação por classes texturais, revelou não melhorar a capacidade preditiva dos modelos, como pode-se observar através do  $R^2$  e da RMSE. Efeito similar ao encontrado por Barros et al. (2013) e em contrapartida ao apresentado por Soares (2013) e Nguyen et al. (2015). Este fato pode ser explicado pela alta capacidade de previsão das redes neurais artificiais D'Emilio et al. (2018).

## CONCLUSÕES

Ao final deste trabalho pode-se concluir que o uso de Redes Neurais Artificiais se mostrou eficiente em gerar funções de pedotransferência paramétricas, para a base de dados utilizada, ressaltando que os resultados obtidos com este trabalho denotam a realidade da base de dados utilizada.

A estimativa dos parâmetros da equação de Van Genuchten obteve um excelente coeficiente de determinação e uma raiz do erro médio baixa, o que demonstra um alto grau de ajuste do modelo, atingindo o seu objetivo;

Observou-se ainda que a separação da base de dados por classe textural, não obteve melhora significativa no resultado das estimativas dos parâmetros estudados;

Pode-se afirmar que a argila foi a variável mais utilizada nas estimativas, demonstrando a alta correlação entre a Curva de Retenção de Água no Solo e a textura do mesmo;

## REFERÊNCIAS

- Bahmani, Omid; Palangi, Sahar. Evaluation of pedotransfer functions for estimating the soil water retention points. *Eurasian soil science*, v. 49, n. 6, p. 652-660, 2016.
- Bouma, J.; Van Lanen, H. A. J. Transfer functions and threshold values: from soil characteristics to land qualities. 1987.
- Da Silva, Euzebio Medrado et al. Valores de tensão na determinação da curva de retenção de água de solos do Cerrado. *Pesquisa Agropecuária Brasileira*, v. 41, n. 2, p. 323-330, 2006.
- D'Emilio, Alessandro et al. Artificial Neural Networks for Predicting the Water Retention Curve of Sicilian Agricultural Soils. *Water*, v. 10, n. 10, p. 1431, 2018.
- Ebrahimi, Eisa et al. Prediction capability of different soil water retention curve models using artificial neural networks. *Archives of Agronomy and Soil Science*, v. 60, n. 6, p. 859-879, 2014.
- Haghverdi, Amir; Cornelis, W. M.; Ghahraman, Bijan. A pseudo-continuous neural network approach for developing water retention pedotransfer functions with limited data. *Journal of Hydrology*, v. 442, p. 46-54, 2012.
- Merdun, Hasan et al. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, v. 90, n. 1-2, p. 108-116, 2006.
- Moosavizadeh-Mojarrad, Rayhaneh; Sepaskhah, Ali Reza. Predicting soil water retention curve by artificial neural networks. *Archives of Agronomy and Soil Science*, v. 57, n. 1, p. 3-13, 2011.

Nguyen, Phuong Minh et al. Impact of regression methods on improved effects of soil structure on soil water retention estimates. *Journal of Hydrology*, v. 525, p. 598-606, 2015.

Otto, Sérgio RL; Alcaide, Miguel. Utilização do método TDR-tensiômetro na obtenção da curva de retenção de água no solo. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 5, n. 2, p. 265-269, 2001.

Rajkai, Kálmán; Kabos, Sándor; Van Genuchten, M. Th. Estimating the water retention curve from soil properties: comparison of linear, nonlinear and concomitant variable methods. *Soil and Tillage Research*, v. 79, n. 2, p. 145-152, 2004.

Sattari, A. Shoarian; Toker, N. K. Obtaining soil–water characteristic curves by numerical modeling of drainage in particulate media. *Computers and Geotechnics*, v. 74, p. 196-210, 2016.

Soares, Fátima Cibele. Uso de diferentes metodologias na geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul. 2013. Tese de Doutorado. Universidade Federal de Santa Maria.

Soares, Fátima Cibele, et al. Redes neurais artificiais na estimativa da retenção de água do solo. *Ciência Rural*, v. 44, n. 2, 2014.

Souza, Philipe Guilherme Corcino; Júnior, João Carlos Ferreira Borges; Viana, João Herbert Moreira. Curva de retenção e disponibilidade total de água em latossolos empregando funções de pedotransferência. *Revista Engenharia na Agricultura*, v. 25, n. 5, p. 417-427, 2017.

Tormena, C. A.; Silva, AP da. Incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo. *Revista brasileira de ciência do solo*, v. 26, n. 2, 2002.

Van Genuchten, M. Th. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil science society of America journal*, v. 44, n. 5, p. 892-898, 1980.

Wang, Yunqiang et al. Spatial variability of soil parameters of the van Genuchten model at a regional scale. *Clean–Soil, Air, Water*, v. 43, n. 2, p. 271-278, 2015.

Yang, Xu; You, Xueyi. Estimating parameters of van Genuchten model for soil water retention curve by intelligent algorithms. *Applied Mathematics & Information Sciences*, v. 7, n. 5, p. 1977, 2013.

Yao, Rong-Jiang et al. Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt-affected mud farmland. *Journal of Soils and Sediments*, v. 15, n. 4, p. 902-916, 2015.

Zhang, Yonggen; Schaap, Marcel G. Weighted recalibration of the Rosetta pedotransfer model with improved estimates of hydraulic parameter distributions and summary statistics (Rosetta3). *Journal of Hydrology*, v. 547, p. 39-53, 2017.

Zou, Ganghua et al. Pedo-transfer functions for estimating the hydraulic properties of paddy soils in subtropical central China. *Archives of Agronomy and Soil Science*, v. 62, n. 7, p. 982-993, 2016.

## 4 DISCUSSÃO

### 4.1 COMPARAÇÃO ENTRE AS FPT DESENVOLVIDAS POR RLM E RNA

Este capítulo tem por objetivo comparar as estimativas realizadas por Regressão Linear Múltipla e Redes Neurais Artificiais. Os resultados foram avaliados a partir do coeficiente de determinação ( $R^2$ ) e da raiz quadrada do erro médio (RMSE).

Na Tabela 3 são apresentados os valores de  $R^2$  e RMSE para a estimativa do parâmetro  $\alpha$  através de RLM e RNA. A análise dos dados indica que os dois métodos de estimativa apresentam resultados muito bons. As estimativas realizadas com RLM obtiveram valores de  $R^2$  acima de 0,98 em cinco classes das seis utilizadas neste estudo, com exceção da classe franco argiloso e do conjunto geral, o qual exibiu um  $R^2$  de 0,8547, enquanto que a RMSE ficou entre 0,000310 e 0,003099. Wang et al. (2017), estimaram curvas de retenção de água e propriedades de resistência de solos arenosos insaturados a partir de parâmetros básicos do solo e encontraram valores de  $R^2$  menores, em torno de 0,5762 para este parâmetro.

Tomando-se por base as estimativas geradas através de RNA, nota-se que os valores de  $R^2$  para o parâmetro  $\alpha$  permaneceram acima de 0,99 em todas as classes, inclusive nos dados gerais. Com relação ao RMSE verificou-se valores abaixo de 0,001 em seis classes, exceção feita para a estimativa da classe franco siltoso apresentou um valor de 0,001005. FERESHTE (2014), avaliando estimativa de parâmetros hidráulicos do solo através de RNA e RLM, obteve um  $R^2$  de 0,726 e a RMSE de 0,0123 para o parâmetro  $\alpha$ .

A Tabela 4 apresenta os valores de  $R^2$  e RMSE para a estimativa do parâmetro  $n$  através de RLM e RNA. Da mesma forma como a análise de  $\alpha$ , a estimativa do parâmetro  $n$  foi bem-sucedida com ambas técnicas. Para este parâmetro os valores de  $R^2$  da estimativa com RLM são um pouco menores do que os valores da estimativa obtida para o parâmetro anterior, mas são mais homogêneos, de 0,9206 a 0,9950. A RMSE permaneceu abaixo de 0,007784. Resultado superior ao encontrado por Babaeian et al. (2015) que trabalharam com múltiplas abordagens para a estimativa da curva de retenção de água no solo, e relataram valores de 0,44 e 0,0253 para o  $R^2$  e RMSE, respectivamente para  $n$ .

Tabela 3 - Indicadores de desempenho da estimativa do parâmetro  $\alpha$ 

Classe Textural	RLM		RNA	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
Argilo Arenoso	0,9945	0,000310	0,9988	0,000099
Argiloso	0,9901	0,001226	0,9976	0,000624
Franco	0,8227	0,002124	0,9974	0,000262
Franco Arenoso	0,9952	0,000278	0,9967	0,000211
Franco Argilo Arenoso	0,9895	0,000375	0,9971	0,000194
Franco Argiloso	0,7824	0,003099	0,9969	0,000365
Franco Siltoso	0,9830	0,002523	0,9922	0,001005
Geral	0,8547	0,004261	0,9973	0,000577

Fonte: do autor

Ao estimar o parâmetro  $n$  as Redes Neurais Artificiais apresentaram um R<sup>2</sup> acima de 0,99 e RMSE abaixo de 0,001193 em seis classes. A classe franco siltoso foi a exceção, com valores de 0,9509 para R<sup>2</sup> e e 0,006156, para RMSE. Zou et al. (2015), trabalhando com estimativa de propriedades hidráulicas, encontraram valores de R<sup>2</sup> e RMSE para  $n$  em torno de 0,55 e 0,03 respectivamente.

Tabela 4 - Indicadores de desempenho da estimativa do parâmetro  $n$ 

Classe Textural	RLM		RNA	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE
Argilo Arenoso	0,9950	0,000912	0,9984	0,000532
Argiloso	0,9934	0,002673	0,9992	0,000951
Franco	0,9634	0,002862	0,9946	0,001193
Franco Arenoso	0,9695	0,002952	0,9981	0,000685
Franco Argilo Arenoso	0,9903	0,002164	0,9990	0,000710
Franco Argiloso	0,9411	0,004764	0,9917	0,001622
Franco Siltoso	0,9228	0,004131	0,9509	0,006156
Geral	0,9206	0,007784	0,9943	0,002076

Fonte: do autor

Os indicadores para as estimativas da umidade residual estão dispostos na Tabela 5. A estimativa deste parâmetro apresentou comportamento similar ao parâmetro  $\alpha$ . Os valores de R<sup>2</sup> da RLM se mantiveram acima de 0,9800 exceto para a classe franco argiloso, que apresentou um valor de 0,9510 e para os dados gerais com 0,9737. Quando se analisa a RMSE percebe-se que este indicador ficou com valores abaixo de 0,003597 para as classes e 0,005857 para o conjunto geral.

Puhlmann e Wilpert (2012) trabalhando com funções de pedotransferência para retenção de água e condutividade hidráulica relataram valores de  $R^2$  abaixo de 0,6.

A estimativa de  $\theta_r$  através de RNA retratou valores de  $R^2$  acima de 0,9900 em todas as classes, incluindo os dados gerais, com exceção da classe franco argiloso com valores de  $R^2$  e RMSE de 0,9842 e 0,002119, respectivamente. Bayat et al. (2011), que utilizaram em sua pesquisa redes neurais artificiais para predizer a retenção de água no solo, encontraram valores de RMSE acima de 0,025.

Tabela 5 - Indicadores de desempenho da estimativa do parâmetro  $\theta_r$

Classe Textural	RLM		RNA	
	$R^2$	RMSE	$R^2$	RMSE
Argilo Arenoso	0,9977	0,000410	0,9990	0,000249
Argiloso	0,9930	0,001372	0,9988	0,000580
Franco	0,9820	0,002561	0,9993	0,000474
Franco Arenoso	0,9974	0,000350	0,9992	0,000185
Franco Argilo Arenoso	0,9958	0,000639	0,9995	0,000219
Franco Argiloso	0,9510	0,003597	0,9842	0,002119
Franco Siltoso	0,9967	0,002802	0,9990	0,001262
Geral	0,9737	0,005857	0,9988	0,001232

Fonte: do autor

Ao comparar os indicadores para os dois métodos de estimativa utilizados para os parâmetros da equação de Van Genuchten percebe-se que a estimativa por RNA apresentou valores de  $R^2$  maiores e de RMSE menores que os encontrados utilizando-se RLM em todas as situações, sendo que os resultados mais expressivos ocorreram quando a base de dados não estava separada por classes texturais.

Os resultados indicam que a estimativa por RNA possui uma maior percepção de correlação entre os dados de entrada e os respectivos dados de saída, ou seja, uma capacidade de previsão superior a RLM. Este fato pode ser explicado porque as RNA, ao contrário das técnicas de regressão, que definem relações de propriedades do solo usando funções matemáticas, a habilidade bem definida da técnica de RNA na interpretação da relação de entrada e saída de sistemas complexos de água no solo explica seu desempenho (D'Emilio et al., 2018).

Pachepsky et al. (1996) ao estimar a retenção de água no solo a partir de dados facilmente mensuráveis, concluíram que o desempenho das RNA foi comparável ao da RLM quando estimaram os parâmetros de Van Genuchten, e melhor quando a estimativa foi o teor de água em determinados níveis do potencial matricial.

Merdum et al. (2006) ao comparar funções de pedotransferência geradas por redes neurais artificiais e regressão, relatam que o desempenho geral da regressão foi um pouco melhor do que a RNA, mas esta diferença foi estatisticamente não significativa. Os autores ainda comentam que apesar disso, as RNA possuem vantagens, como o relacionamento de grandes quantidades de dados de entrada e saída de uma vez, portanto, economizando tempo e energia, e novas pesquisas devem ser feitas, continuando o avanço desta técnica.

Por fim, D'Emilio et al. (2018) em seu trabalho de previsão da curva de retenção de água no solo através de Redes Neurais Artificiais, relataram que as redes neurais artificiais são estruturas matemáticas flexíveis que são capazes de identificar relações não lineares complexas entre conjuntos de dados de entrada e saída. Afirmando ainda que os resultados indicaram que as RNA, relacionando parâmetros hidráulicos do solo com propriedades básicas, servem como uma alternativa para a regressão, usada mais usualmente.

#### 4.2 ESTIMATIVA DAS UMIDADES ATRAVÉS DA EQUAÇÃO DE VAN GENUCHTEN

Este item analisará a estimativa da umidade nos potenciais de -6 kPa, -10 kPa, -33 kPa, -100 kPa, -500 kPa e -1500 kPa, obtidos através da equação de Van Genuchten usando os parâmetros  $\alpha$ ,  $n$  e  $\theta_r$  estimados através dos métodos de Regressão Linear Múltipla e Redes Neurais Artificiais.

A Figura 3 apresenta os gráficos 1:1 das umidades em cada potencial para as metodologias de estimativa utilizadas no presente trabalho. Os gráficos foram construídos utilizando-se a base de dados geral, ou seja, sem separação por classe textural. Percebe-se que os indicadores, assim como aconteceu na estimativa dos

parâmetros, permaneceram bons, tanto para a Regressão Linear Múltipla, como para as Redes Neurais Artificiais.

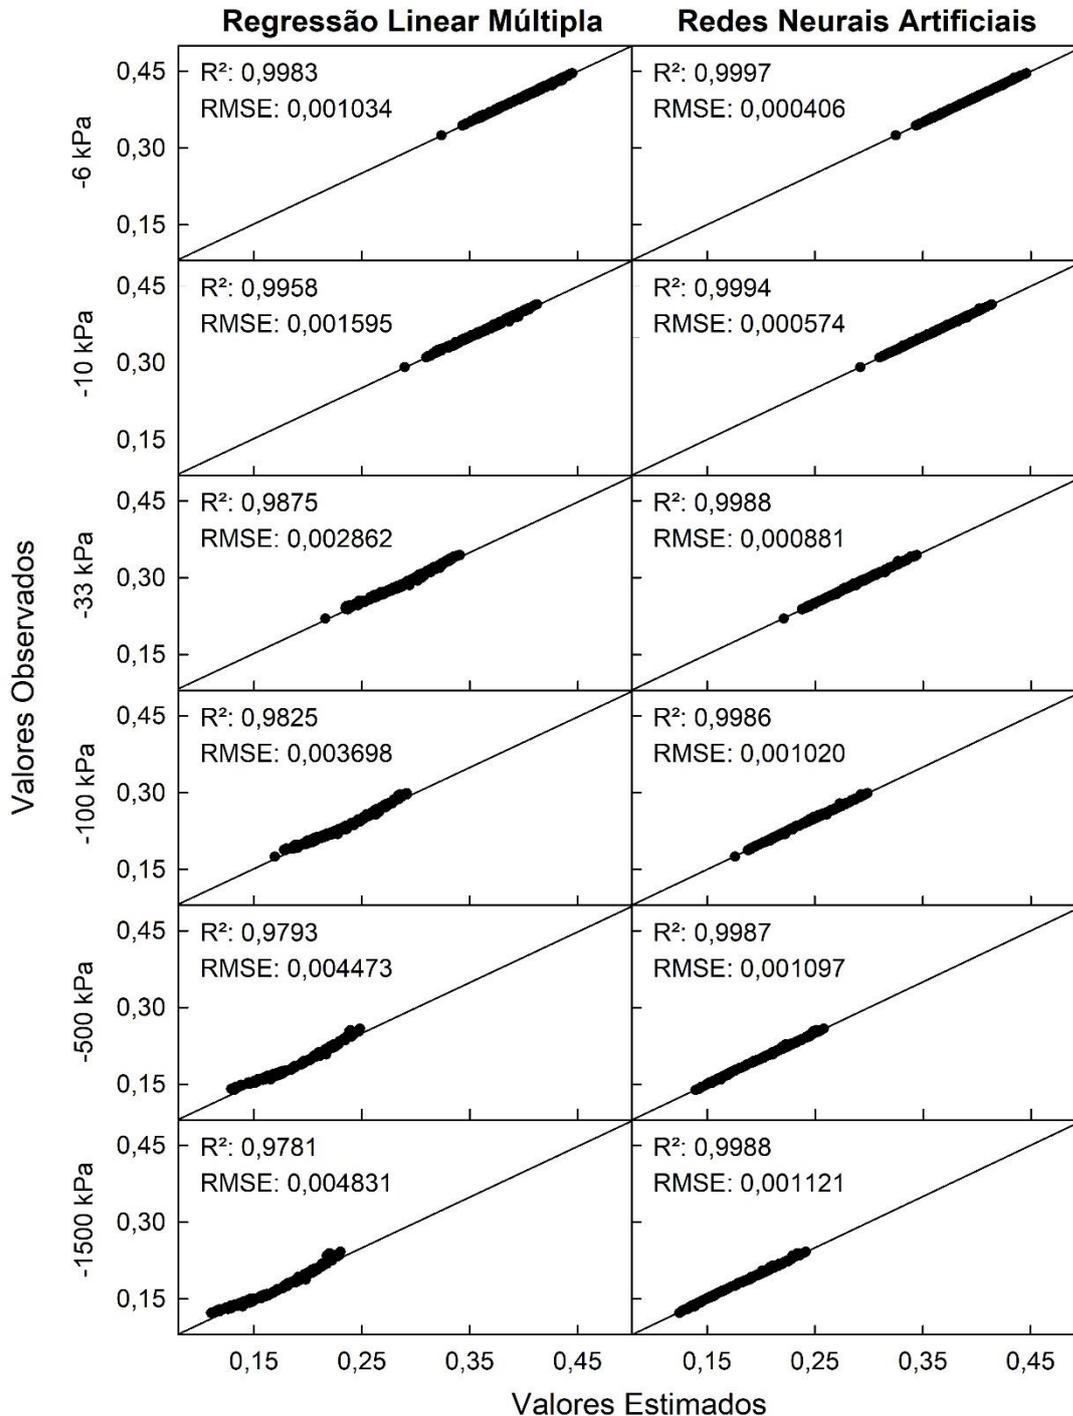
As estimativas realizadas através de RLM apresentaram valores de  $R^2$  acima de 0,97 e a RMSE abaixo de 0,0049. Varija e Shweth (2011) estimando os pontos da curva de retenção de água no solo para diversos potenciais através de RLM encontraram valores para  $R^2$  entre 0,6180 e 0,9960. De Souza et al. (2014) pesquisaram sobre funções de pedotransferência para retenção de água para os mesmos potenciais em áreas de cultivo de café e apresentaram valores de  $R^2$  de 0,76 a 0,98 na linha de plantio e 0,49 a 0,63 na entrelinha.

Quanto as estimativas por RNA, pode-se notar que o  $R^2$  ficou acima de 0,99 e a RMSE abaixo de 0,0012. Soares et al. (2014) estimaram a retenção de água no solo através de RNA e encontraram valores de  $R^2$  entre 0,7111 e 0,8991 para diferentes potenciais concluindo que as RNA podem estimar com alta capacidade preditiva a curva de retenção de água no solo. Moreira de Melo e Pedrollo (2015) utilizando RNA para estimativa da curva de retenção de água do solo obtiveram valores de  $R^2$  de 0,433 a 0,818.

Comparando-se os dois métodos de estimativa pode-se afirmar que as RNA foram superiores a RLM em todos os potenciais, obtendo valores de  $R^2$  maiores e RMSE menores. Percebe-se ainda que, usando a RLM, quanto maior o potencial menor o  $R^2$  e maior a RMSE, fazendo com que a eficiência da estimativa seja reduzida em relação aos indicadores estatísticos que constituem a acurácia. Esse fato não ocorre na mesma proporção com as RNA, pois mesmo a RMSE aumentando o  $R^2$  se mantém quase constante para os potenciais de -33 kPa, -100 kPa, -500 kPa e -1500 kPa, mostrando dessa forma que as RNA são mais precisas que a RLM.

Nguyen et al. (2017) ao comparar as capacidades preditivas de PTFs pontuais usando várias técnicas de estimativa para a retenção de água no solo afirmaram que os resultados da avaliação confirmam a superioridade das abordagens de RNA na modelagem da relação solo/água como um sistema complexo, mesmo quando se tem disponível um conjunto de dados limitado.

Figura 3 - Comparação das umidades estimadas por RLM e RNA nos diversos potenciais para os dados gerais



Fonte: do autor

Yi et al. (2013) usaram RLM, RNA e o Software Rosetta para o desenvolvimento de funções de pedotransferência e afirmaram que a RNA foi o melhor dos métodos avaliados porque obteve o menor RMSE e o maior R<sup>2</sup>. Os autores relataram porém,

que apesar disso, a RLM ainda é um bom método para prever a retenção de água no solo partir de propriedades facilmente disponíveis.

Utilizando-se a base de dados separada por classes observou-se que houve uma melhora nos resultados estimados por RLM, onde os valores de  $R^2$  ficaram acima de 0,99. Com exceção da estimativa para o potencial 1500 kPa da classe franco e franco argilosa que obtiveram valores de  $R^2$  de 0,9730 e 0,9797, respectivamente. As estimativas pontuais realizadas com RNA se mantiveram acima de 0,99 nas sete classes estudadas em todos os potenciais, não havendo ganho de desempenho com a separação por classes. Soares (2013) relatou que a separação dos dados por classe produziu melhorias nas estimativas realizadas por RLM e RNA.

## 5 CONCLUSÃO

Ao final deste trabalho pode-se concluir que o uso de Regressão Linear Múltipla e Redes Neurais Artificiais se mostraram eficientes em gerar Funções de Pedotransferência, para a base de dados utilizada nas duas situações propostas: com e sem separação por classes texturais.

A estimativa dos parâmetros da equação de Van Genuchten, com os dois métodos obteve um excelente coeficiente de determinação, o que demonstra um alto grau de ajuste do modelo, atingindo o seu objetivo.

A metodologia de estimativa de Regressão Linear Múltipla, se obtém um resultado mais acurado quando se estima os parâmetros por classe textural. O mesmo não ocorrendo com a estimativa por Redes Neurais Artificiais, em que a separação da base de dados por classe textural, não obteve melhora significativa no resultado das estimativas dos parâmetros estudados.

A metodologia baseada em RNA mostrou-se precisa e acurada em suas estimativas, apresentando em todas as situações valores de  $R^2$  maiores e RMSE menores em comparação com a RLM. Sendo que, quando utilizou-se a base de dados separada por classes texturais, esta superioridade foi atenuada, e ressaltada ao não realizar esta separação.

Pode-se afirmar que, nas duas metodologias de estimativa propostas, a argila foi a variável mais utilizada nas estimativas, demonstrando a alta correlação entre a Curva de Retenção de Água no Solo e a textura do mesmo.

## REFERÊNCIAS

- ACUTIS, Marco; DONATELLI, Marcello. SOILPAR 2.00: software to estimate soil hydrological parameters and functions. **European Journal of Agronomy**, v. 18, n. 3, p. 373-377, 2003.
- ANDRADE, Rui da S.; STONE, Luís F. Estimativa da umidade na capacidade de campo em solos sob Cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, v. 15, n. 2, 2011.
- ANDRADE, C. et al. Parâmetros de solo-água para a engenharia de irrigação e ambiental. In: **Embrapa Milho e Sorgo-Artigo em anais de congresso**. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 27., 1998, Poços de Caldas, MG. Manejo de irrigação. Lavras: UFLA/SBEA, 1998. cap. 1, p. 1-45., 1998.
- ARYA, Lalit M.; PARIS, Jack F. A physicoempirical model to predict the soil moisture characteristic from particle-size distribution and bulk density data. **Soil Science Society of America Journal**, v. 45, n. 6, p. 1023-1030, 1981.
- BABAEIAN, Ebrahim et al. A comparative study of multiple approaches for predicting the soil–water retention curve: Hyperspectral information vs. basic soil properties. **Soil Science Society of America Journal**, v. 79, n. 4, p. 1043-1058, 2015.
- BARR A; FEIGENBAUM E.A.. **The Handbook of Artificial Intelligence**, volume I-II. Willian Kaufmann Inc., Los Altos, California, 1981.
- BAYAT, H. et al. Estimating water retention with pedotransfer functions using multi-objective group method of data handling and ANNs. **Pedosphere**, v. 21, n. 1, p. 107-114, 2011.
- BAYAT, Hossein; EBRAHIMI, Eisa. Effects of various input levels and different soil water retention curve models on water content estimation using different statistical methods. **Hydrology Research**, v. 47, n. 2, p. 312-332, 2016.
- BEUTLER, A. N. et al. Retenção de água em dois tipos de Latossolos sob diferentes usos. **Revista Brasileira de Ciência do Solo**, p. 829-834, 2002.
- BOUMA, J.; VAN LANEN, H. A. J. Transfer functions and threshold values: from soil characteristics to land qualities. 1987.
- BOUMA, J. Using soil survey data for quantitative land evaluation. **Advances in soil science**, v. 9, n. 1989, p. 177-213, 1989.
- BRAGA, Fabiano de Vargas Arigony. **Estimativa dos parâmetros da resistência do solo ao cisalhamento através de pedotransferência**. 2014. Tese de Doutorado. Universidade Federal de Santa Maria.
- BROOKS, Royal H.; COREY, Arthur T. Properties of porous media affecting fluid flow. **Journal of the Irrigation and Drainage Division**, v. 92, n. 2, p. 61-90, 1966.

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

CAMPBELL, Gaylon S. A simple method for determining unsaturated conductivity from moisture retention data. **Soil science**, v. 117, n. 6, p. 311-314, 1974.

CINTRA, Fernando Luis Dutra; LIBARDI, Paulo Leonel; SAAD, Antonio Melhem. Balanço hídrico no solo para porta-enxertos de citros em ecossistema de Tabuleiro Costeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 4, n. 1, p. 23-28, 2000.

CORNELIS, Wim M. et al. Evaluation of pedotransfer functions for predicting the soil moisture retention curve. **Soil Science Society of America Journal**, v. 65, n. 3, p. 638-648, 2001.

COSTA, Wanderley Andrade; DA SILVA OLIVEIRA, Carlos Alberto; KATO, Eiyti. MODELOS DE AJUSTE E MÉTODOS PARA A DETERMINAÇÃO DA CURVA DE RETENÇÃO DE ÁGUA DE UM LATOSSOLOVERMELHO-AMARELO. **Revista Brasileira de Ciência do Solo**, v. 32, n. 2, p. 515-523, 2008.

DA SILVA, Euzébio Medrado et al. Valores de tensão na determinação da curva de retenção de água de solos do Cerrado. **Pesquisa Agropecuária Brasileira**, v. 41, n. 2, p. 323-330, 2006.

DABRAL, P. P.; PANDEY, Pankaj Kumar. MODELS TO ESTIMATE SOIL MOISTURE RETENTION LIMITS AND SATURATED HYDRAULIC CONDUCTIVITY. **J. Indian Water Resour. Soc**, v. 36, n. 1, 2016.

DALMAGO, Genei Antonio et al. Retenção e disponibilidade de água às plantas, em solo sob plantio direto e preparo convencional. **Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande. Vol. 13, supl.,(out. 2009), p. 855-864, 2009.**

D'EMILIO, Alessandro et al. Artificial Neural Networks for Predicting the Water Retention Curve of Sicilian Agricultural Soils. **Water**, v. 10, n. 10, p. 1431, 2018.

DE FREITAS JÚNIOR, Elias; DA SILVA, Euzébio Medrado. Uso da centrífuga para determinação da curva de retenção de água do solo, em uma única operação. **Pesquisa Agropecuária Brasileira**, v. 19, n. 11, p. 1423-1428, 1984.

DE SOUZA, Joabe M. et al. Funções de pedotransferência para retenção de água e condutividade hidráulica em solo submetido a subsolagem. **Revista Brasileira de Ciências Agrárias**, v. 9, n. 4, 2014.

DIAS JUNIOR, M. de S.; ESTANISLAU, W. T. Grau de compactação e retenção de água de Latossolos submetidos a diferentes sistemas de manejo. **Revista Brasileira de Ciência do Solo**, v. 23, n. 1, 1999.

DIEUDONNE, Anne-Catherine; DELLA VECCHIA, Gabriele; CHARLIER, Robert. Water retention model for compacted bentonites. **Canadian Geotechnical Journal**, n. 999, p. 1-11, 2017.

DONAGEMA, G. K. et al. Manual de métodos de análise de solo. **Embrapa Solos-Documentos (INFOTECA-E)**, 2011.

EBRAHIMI, Eisa et al. Prediction capability of different soil water retention curve models using artificial neural networks. **Archives of Agronomy and Soil Science**, v. 60, n. 6, p. 859-879, 2014.

EBRAHIM-ZADEH, Golnaz et al. Investigating the correlation between soil tensile strength curve and soil water retention curve via modeling. **Soil and Tillage Research**, v. 167, p. 9-29, 2017.

FERESHTE, Fashi Haghghi. Evaluation of artificial neural network and regression PTFS in estimating some soil hydraulic parameters. **ProEnvironment Promediu**, v. 7, n. 17, 2014.

FERRAZ, Rafael Camargo. **SISTEMA WEB E MOBILE PARA ESTIMATIVA DE EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO REDES NEURAIS ARTIFICIAIS**. 2013. Tese de Doutorado. Universidade Federal de Santa Maria.

FRANZMEIER, D. P. Estimation of hydraulic conductivity from effective porosity data for some Indiana soils. **Soil Science Society of America Journal**, v. 55, n. 6, p. 1801-1803, 1991.

FREDLUND, Murray D.; FREDLUND, Delwyn G.; WILSON, G. W. Prediction of the soil-water characteristic curve from grain-size distribution and volume-mass properties. In: **Proc., 3rd Brazilian Symp. on Unsaturated Soils**. Rio de Janeiro, 1997. p. 13-23.

GANGASANI, Jayachander R. **Soil moisture modeling using artificial neural network**. 2016. Tese de Doutorado. Alabama Agricultural and Mechanical University.

GHANBARIAN, Behzad; TASLIMITEHRANI, Vahid; PACHEPSKY, Yakov A. Accuracy of sample dimension-dependent pedotransfer functions in estimation of soil saturated hydraulic conductivity. **Catena**, v. 149, p. 374-380, 2017.

GRIGOLON, Gilmar Batista. **Curva de retenção de água no solo determinada a partir de um número mínimo de pares de umidade e tensão na câmara de Richards**. 2013. Tese de Doutorado. Universidade de São Paulo.

JAFARZADEH, A. A. et al. Comparative analysis of support vector machine and artificial neural network models for soil cation exchange capacity prediction. **International Journal of Environmental Science and Technology**, v. 13, n. 1, p. 87-96, 2016.

JOE, M. Adams; PRASANNA, P. Rajesh. Simulation of Soil Water Retention Curve using Artificial Neural Networks with Pseudocontinuous Pedotransfer Functions.

**International Journal of Applied Engineering Research**, v. 11, n. 7, p. 4700-4706, 2016.

JOHARI, A.; HABIBAGAH, G.; GHAHRAMANI, A. Prediction of soil–water characteristic curve using genetic programming. **Journal of Geotechnical and Geoenvironmental Engineering**, v. 132, n. 5, p. 661-665, 2006.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2007.

HUSE, Katia. **Estudo da Influência da Adição de Bentonita em um Solo Arenoso-Siltoso para Uso como Cobertura de Aterros**. 2007. Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

KLEIN, Vilson Antonio et al. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. **Ciência Rural**, v. 40, n. 7, 2010.

KLEIN, V. A.; LIBARDI, P. L. Densidade e distribuição do diâmetro dos poros de um Latossolo Vermelho, sob diferentes sistemas de uso e manejo. **Revista Brasileira de Ciência do solo**, v. 26, n. 4, 2002.

KLEIN, Vilson Antonio; LIBARDI, Paulo Leonel. Faixa de umidade menos limitante ao crescimento vegetal e sua relação com a densidade do solo ao longo do perfil de um Latossolo Roxo. **Ciência Rural**, v. 30, n. 6, 2000.

KOEKKOEK, E. J. W.; BOOLTINK, H. Neural network models to predict soil water retention. **European Journal of Soil Science**, v. 50, n. 3, p. 489-495, 1999.

LIANG, Xi et al. Agendamento de irrigação utilizando uma abordagem baseada no modelo de van Genuchten. **Agricultural Water Management**

LIBARDI, Paulo Leonel. **Dinâmica da Água no Solo Vol. 61**. Edusp, 2005.

LIN, H. S. et al. Effects of soil morphology on hydraulic properties I. Quantification of soil morphology. **Soil Science Society of America Journal**, v. 63, n. 4, p. 948-954, 1999.

LUSTOSA, Volney Gadelha. O estado da arte em inteligência artificial. **Colabor@-A Revista Digital da CVA-RICESU**, v. 2, n. 8, 2010.

MACEDO, A. et al. Calibração e uso de uma sonda combinada tensiômetro/TDR. **Embrapa Instrumentação Agropecuária-Comunicado Técnico (INFOTECA-E)**, 2000.

MATULA, Svatopluk et al. Estimation of the soil water retention curve (SWRC) using pedotransfer functions (PTFs). **Soil and Water Research**, v. 2, n. 4, p. 113-122, 2007.

MERDUN, Hasan et al. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. **Soil and Tillage Research**, v. 90, n. 1, p. 108-116, 2006.

MOOSAVIZADEH-MOJARRAD, Rayhaneh; SEPASKHAH, Ali Reza. Predicting soil water retention curve by artificial neural networks. **Archives of Agronomy and Soil Science**, v. 57, n. 1, p. 3-13, 2011.

MOREIRA DE MELO, Tirzah; PEDROLLO, Olavo Correa. Artificial neural networks for estimating soil water retention curve using fitted and measured data. **Applied and Environmental Soil Science**, v. 2015, 2015.

MORETTI DE SOUZA FILHO, Jorge Luiz; GOMES, Siguifrid. Avaliação e desempenho de equações de estimativa do armazenamento de água no solo em um balanço hídrico climatológico decendial irrigacionista. **Acta Scientiarum. Agronomy**, v. 29, n. 4, 2007.

MEIRA CÁSSARO, Fabio Augusto et al. Funil de Haines modificado: curvas de retenção de solos próximos à saturação. **Revista Brasileira de Ciência do Solo**, v. 32, n. 6, 2008.

NGUYEN, Phuong M. et al. Comparison of statistical regression and data-mining techniques in estimating soil water retention of tropical delta soils. **Biosystems Engineering**, v. 153, p. 12-27, 2017.

NUNES, José Nilton Vieira et al. Avaliação da qualidade física de solos irrigados do Rio Grande do Sul e de funções de pedotransferência para a estimativa da retenção de água. 2016.

NUTH, Mathieu; LALOUI, Lyesse. Advances in modelling hysteretic water retention curve in deformable soils. **Computers and Geotechnics**, v. 35, n. 6, p. 835-844, 2008.

OLIVEIRA, Orlando Martini de. **Estudo sobre a resistência ao cisalhamento de um solo residual compactado não saturado**. 2004. Tese de Doutorado. Universidade de São Paulo.

OTTO, Sérgio RL; ALCAIDE, Miguel. Utilização do método TDR-tensiômetro TDR-tensiômetro na obtenção da curva de retenção de água no solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 5, n. 2, p. 265-269, 2001.

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

PARASURAMAN, Kamban; ELSHORBAGY, Amin; SI, Bing Cheng. Estimating saturated hydraulic conductivity in spatially variable fields using neural network ensembles. **Soil Science Society of America Journal**, v. 70, n. 6, p. 1851-1859, 2006.

PATIL, Nitin Gorakh; SINGH, Surendra Kumar. Pedotransfer functions for estimating soil hydraulic properties: A review. **Pedosphere**, v. 26, n. 4, p. 417-430, 2016.

PEREIRA, Tonismar dos Santos. **Uso de inteligência artificial para estimativa da capacidade de suporte de carga do solo**. 2017. Tese de Doutorado. Universidade Federal de Santa Maria.

PUHLMANN, Heike; VON WILPERT, Klaus. Pedotransfer functions for water retention and unsaturated hydraulic conductivity of forest soils. **Journal of Plant Nutrition and Soil Science**, v. 175, n. 2, p. 221-235, 2012.

RAJKAI, Kálmán; KABOS, Sándor; VAN GENUCHTEN, M. Th. Estimating the water retention curve from soil properties: comparison of linear, nonlinear and concomitant variable methods. **Soil and Tillage Research**, v. 79, n. 2, p. 145-152, 2004.

REICHARDT, Klaus. **Dinâmica da matéria e da energia em ecossistemas**. USP-ESALQ, 1996.

RICHARDS, L. A.; FIREMAN, Milton. PRESSURE-PLATE APPARATUS FOR MEASURING MOISTURE SORPTION AND TRANSMISSION BY SOILS. **Soil Science**, v. 56, n. 6, p. 395-404, 1943.

SALES, Marcos Adriano Marques Pessôa et al. UMIDADE DO SOLO SOB USO DA MESA DE TENSÃO E DO FUNIL DE HAINES, 2013.

SATTARI, A. Shoarian; TOKER, N. K. Obtaining soil–water characteristic curves by numerical modeling of drainage in particulate media. **Computers and Geotechnics**, v. 74, p. 196-210, 2016.

SCHAAP, Marcel G.; LEIJ, Feike J.; VAN GENUCHTEN, Martinus Th. ROSETTA: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. **Journal of hydrology**, v. 251, n. 3, p. 163-176, 2001.

SILVA, João Pedro Bento Clemente da. **Modelos de regressão linear e logística utilizando o software R**. 2017. Tese de Doutorado.

SOARES, Fátima Cibele. **USO DE DIFERENTES METODOLOGIAS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERENCIA PARA A RETENÇÃO DE ÁGUA EM SOLOS DO RIO GRANDE DO SUL**. 2013. Tese de Doutorado. Universidade Federal de Santa Maria.

SOARES, Fátima Cibele et al. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, v. 44, n. 2, 2014.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2007.

TAVARES, Maria Hermínia Ferreira; FELICIANO, J. J.; VAZ, C. M. P. Análise comparativa de métodos para determinação da curva de retenção de água em solos. In: **Embrapa Instrumentação-Artigo em anais de congresso (ALICE)**. In: CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO, 31., 2007, Gramado, RS. Conquistas e desafios da ciência do solo brasileira. Anais... Porto Alegre: SBCS, 2007. não paginado. 1 CD-ROM., 2008.

TOMASELLA, Javier et al. Comparison of two techniques to develop pedotransfer functions for water retention. **Soil Science Society of America Journal**, v. 67, n. 4, p. 1085-1092, 2003.

TORMENA, C. A.; SILVA, A. P. Incorporação da densidade no ajuste de dois modelos à curva de retenção de água no solo. **Revista brasileira de ciência do solo**, v. 26, n. 2, 2002.

VAN GENUCHTEN, M. Th. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil science society of America journal**, v. 44, n. 5, p. 892-898, 1980.

VAN GENUCHTEN, MT van et al. The RETC code for quantifying the hydraulic functions of unsaturated soils. 1991.

VARIJA, K.; SHWETHA, P. Estimation of the soil moisture retention curve in costal Karnataka using pedotransfer function. In: **Proceedings of Indian Geotechnical Conference**. 2011. p. 145-148.

VERECKEN, H. et al. Estimating the soil moisture retention characteristic from texture, bulk density, and carbon content. **Soil science**, v. 148, n. 6, p. 389-403, 1989.

VERAS DE LIMA, Herdjanía; PIRES DA SILVA, Álvaro. Mesa de tensão com areia: procedimentos para montagem e validação. **Revista Brasileira de Ciência do Solo**, v. 32, n. 5, 2008.

WANG, Ji-Peng et al. Estimating water retention curves and strength properties of unsaturated sandy soils from basic soil gradation parameters. **Water Resources Research**, v. 53, n. 7, p. 6069-6088, 2017.

YAO, Rong-Jiang et al. Evaluation of pedotransfer functions for estimating saturated hydraulic conductivity in coastal salt-affected mud farmland. **Journal of Soils and Sediments**, v. 15, n. 4, p. 902-916, 2015.

YI, Xiangsheng; LI, Guosheng; YIN, Yanyu. Comparison of three methods to develop pedotransfer functions for the saturated water content and field water capacity in permafrost region. **Cold Regions Science and Technology**, v. 88, p. 10-16, 2013.

ZOU, Ganghua et al. Pedo-transfer functions for estimating the hydraulic properties of paddy soils in subtropical central China. **Archives of Agronomy and Soil Science**, v. 62, n. 7, p. 982-993, 2016.