

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

**USO DE DIFERENTES METODOLOGIAS NA
GERAÇÃO DE FUNÇÕES DE
PEDOTRANSFERENCIA PARA A RETENÇÃO DE
ÁGUA EM SOLOS DO RIO GRANDE DO SUL**

TESE DE DOUTORADO

Fátima Cibele Soares

**Santa Maria, RS, Brasil
2013**

USO DE DIFERENTES METODOLOGIAS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERENCIA PARA A RETENÇÃO DE ÁGUA EM SOLOS DO RIO GRANDE DO SUL

Fátima Cibele Soares

Tese apresentada ao Curso de Doutorado do Programa de Pós Graduação em Engenharia Agrícola, Área de Concentração Engenharia de Água e Solos, da Universidade Federal de Santa Maria (UFSM, RS).

**Orientador: Prof. Adroaldo Dias Robaina
Coorientador: Prof. Marcia Xavier Peiter**

**Santa Maria, RS, Brasil
2013**

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

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 / Fátima Cibele Soares.-2013.

200 p.; 30cm

Orientador: Adroaldo Dias Robaina

Coorientadora: Marcia Xavier Peiter

Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, RS, 2013

1. Pedofunções 2. Umidade do solo 3. Potencial matricial 4. Inteligência artificial I. Dias Robaina, Adroaldo II. Xavier Peiter, Marcia III. Título.

**Universidade Federal de Santa Maria
Centro de Ciências Rurais
Programa de Pós-Graduação em Engenharia Agrícola**

A Comissão Examinadora, abaixo assinada,
aprova a Tese de Doutorado

**USO DE DIFERENTES METODOLOGIAS NA GERAÇÃO DE
FUNÇÕES DE PEDOTRANSFERENCIA PARA A RETENÇÃO
DE ÁGUA EM SOLOS DO RIO GRANDE DO SUL**

elaborada por
Fátima Cibele Soares

Como requisito parcial para obtenção do grau de
Doutor em Engenharia Agrícola

Comissão Examinadora

Adroaldo Dias Robaina, Dr.,
(Presidente/Orientador)

Marcia Xavier Peiter, Dra.,
(Coorientadora/UFSM)

Ana Carla dos Santos Gomes, Dra.,
(IF - Farroupilha)

Ana Rita Costenaro Parizi, Dra.,
(IF - Farroupilha)

João Fernando Zamberlan Dr.,
(UFSM)

Ricardo Luis Schons, Dr.,
(UFPEL)

Santa Maria, 1 de fevereiro de 2013.

Ofereço

Aos meus pais, Antonio e Clenir, minha avó, Faustina (*in memoriam*) pelo apoio incondicional durante toda esta caminhada.

Por terem me ensinado o verdadeiro sentido da vida.

Aos meus irmãos, pelo apoio nos momentos mais difíceis desta jornada, muito obrigado por terem acreditado em mim.

Vocês foram maravilhosos Fica aqui a minha gratidão, meu carinho e amor que sinto por vocês!

AGRADECIMENTOS

À Deus que está sempre comigo dando coragem, força, saúde e inteligência para tomar as decisões corretas.

Ao meu orientador, professor Adroaldo Dias Robaina, pela orientação, dedicação, amizade, ensinamentos e pronta colaboração na realização deste trabalho.

À minha co-orientadora, professora Márcia Xavier Peiter, pela orientação, dedicação, alegria e ensinamentos para a minha formação e realização deste trabalho.

À Universidade Federal de Santa Maria e ao Programa de Pós-Graduação em Engenharia Agrícola pela oportunidade de realização do curso de doutorado.

À direção da Universidade Federal do Pampa/Campus de Alegrete pelo incentivo à conclusão do curso de doutorado.

Aos meus pais, pelo amor e dedicação incondicional para que este meu sonho se tornasse possível.

Aos meus irmãos Herton e Daniele, pelo amor, carinho e compreensão, durante esta caminhada.

Aos colegas e amigos do PPGEA e do laboratório de Engenharia de Irrigação, pela amizade e contribuição.

Aos colegas e amigos Taíse Buske, Gisele Vivan e Fabrício Barboza pelos momentos de alegria que juntos compartilhamos.

À minha irmã de coração, Ana Rita Costenaro Parizi, pela contribuição, amizade e carinho.

Ao meu namorado, amigo e companheiro, de todas as horas, Jumar Russi, pelo carinho, amor e dedicação. Pelas horas que juntos compartilhamos nesta jornada, pela compreensão nos momentos de ausência. Obrigada, querido.

A todos os meus amigos, que estiveram ao meu lado durante esta jornada, pelo carinho, amizade, força e presença.

Muito Obrigada.

Uma noite eu tive um sonho...

Sonhei que estava andando na praia
com o Senhor
e no céu passavam cenas de minha vida.
Para cada cena que passava,
percebi que eram deixados dois pares
de pegadas na areia:
um era meu e o outro do Senhor.
Quando a última cena da minha vida
passou diante de nós, olhei para trás,
para as pegadas na areia,
e notei que muitas vezes,
no caminho da minha vida,
havia apenas um par de pegadas na areia.
Notei também que isso aconteceu
nos momentos mais difíceis
e angustiantes da minha vida.
Isso aborreceu-me deveras
e perguntei então ao meu Senhor:
- Senhor, tu não me disseste que,
tendo eu resolvido te seguir,
tu andarias sempre comigo,
em todo o caminho?
Contudo, notei que durante
as maiores tribulações do meu viver,
havia apenas um par de pegadas na areia.
Não compreendo por que nas horas
em que eu mais necessitava de ti,
tu me deixaste sozinho.
O Senhor me respondeu:
- Meu querido filho.
Jamais te deixaria nas horas
de prova e de sofrimento.
Quando viste na areia,
apenas um par de pegadas,
eram as minhas.
Foi exatamente aí,
que te carreguei nos braços.

Mary Stevenson

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Engenharia Agrícola
Universidade Federal de Santa Maria, RS, Brasil

USO DE DIFERENTES METODOLOGIAS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERENCIA PARA A RETENÇÃO DE ÁGUA EM SOLOS DO RIO GRANDE DO SUL

Autora: Fátima Cibele Soares
Orientador: Adroaldo Dias Robaina
Santa Maria, 1 de fevereiro de 2013

Estudos que envolvem a dinâmica da água no sistema solo-planta-atmosfera tais como disponibilidade de água as culturas, infiltração, drenagem e movimento de solutos no solo, necessitam do conhecimento da relação entre o conteúdo de água no solo e o potencial matricial, representada pela curva de retenção de água. No entanto, sua execução é laboriosa, demanda considerável tempo e custos. Uma alternativa é sua estimativa através de equações estatísticas denominadas Funções de Pedotransferência (FPTs). O objetivo deste estudo foi gerar FPTs para as diferentes classes de solos do Estado do Rio Grande do Sul, por meio de metodologias de predição. Para desenvolver o trabalho foram utilizados dados, disponíveis na literatura, com valores de características físico-hídricas e mineralógicas, de solos do Estado, para estimar valores de umidade de solo, sob diferentes tensões. De posse do banco de dados foi realizada a subdivisão do mesmo, nas diferentes classes texturais identificada no Estado, na tentativa de melhorar a capacidade preditiva das pedofunções, formando subconjuntos mais homogêneos. O desenvolvimento das FPTs foi a partir de dois métodos de modelagem: (i) regressão linear múltipla (RLM) e (ii) redes neurais artificiais (RNAs). Para o desenvolvimento das FPTs pela primeira metodologia, foi utilizada a opção “*stepwise*” (SAS, 1997). As FPTs geradas a partir de RNAs, foram implementadas através do *perceptron* multicamadas com algoritmo *backpropagation* e otimização *Levenberg-Marquardt*. As redes foram treinadas variando-se o número de neurônios na camada de entrada e número de neurônios na camada escondida. A variável de saída foi conteúdo de água no solo nos potenciais matriciais de 0, -6, -10, -33, -100, -500 e -1500 kPa. Para cada arquitetura, a rede foi treinada diversas vezes, escolhendo-se no final do treinamento a arquitetura com menor erro relativo médio e menor variância em relação aos dados de validação. A eficiência das FPTs foram analisadas graficamente pela relação 1:1, entre os dados estimados versus os observados e, por meio dos seguintes indicadores estatísticos: coeficiente de correlação (r); índice de concordância de Wilcoxon (c); coeficiente de determinação (R^2) e índice de desempenho (id). Os resultados mostraram que quanto mais homogêneos são os dados das variáveis que compõem as FPTs, maior é a precisão na estimativa da retenção de água no solo, pelas mesmas. As redes de arquitetura formada por 4 entradas, apresentaram elevada precisão na estimativa das variáveis. As FPTs desenvolvidas por RNAs superaram a capacidade preditiva do método padrão (RLM). Deste modo, a estimativa da curva de retenção de água no solo, por meio das RNAs treinadas por classes texturais, apresenta-se como um subsídio as técnicas adotadas na agricultura irrigada.

Palavras-chave: Pedofunções. Umidade do solo. Potencial matricial. Inteligência artificial

ABSTRACT

Doctorate Thesis
Graduate Program in Agricultural Engineering
Federal University of Santa Maria, RS, Brazil

USE OF DIFFERENT METHODOLOGIES IN GENERATION PEDOTRANSFER FUNCTIONS FOR WATER RETENTION IN SOILS OF RIO GRANDE DO SUL

Author: Fátima Cibele Soares
Advisor: Adroaldo Dias Robaina
Santa Maria, February 1st

Studies on the dynamics of water in the soil-plant-atmosphere such as water availability, infiltration, drainage and movement of solutes into the soil, require knowledge of the relation between the water content in soil matric potential and represented by retention curve water. However, its implementation is laborious, requires considerable time and cost. An alternative is your estimate through statistical equations called pedotransfer functions (PTFs). The aim of this study was to generate PTFs for the different soil classes in the state of Rio Grande do Sul, through prediction methodologies. To develop the work we used data available in the literature, with values of hydro-physical characteristics and mineralogical characteristics of soils of the State, to estimate values of soil unit under different stresses. In possession of the database was conducted subdivision thereof, in different textural classes identified in the state in an attempt to improve the predictive ability of pedofunctions, forming more homogeneous subsets. The development of PTFs was from two modeling methods: (i) multiple linear regression (MLR) and (ii) artificial neural networks (ANNs). For the development of PTFs first methodology was used the "stepwise" (SAS, 1997). The PTFs generated from ANNs were implemented through the multilayer perceptron with backpropagation algorithm and Levenberg-Marquardt optimization. Each network is trained by varying the number of neurons in the input layer and the number of neurons in the hidden layer. The output variable was water content in soil matric potentials of 0, -6, -10, -33, -100, -500 and -1500 kPa. For each architecture, the network was trained several times, picking up training at the end of the architecture with lower mean relative error and lower variance in relation to the validation data. The efficiency of PTFs were analyzed graphically by the ratio 1:1 between data versus the observed and estimated by means of the following statistical indicators: correlation coefficient (r); concordance index Wilcoxon (c); coefficient of determination (R^2) and performance index (id). The results showed that the more homogeneous is the data of the variables that compose the PTFs, the greater the precision in estimating the water retention in the soil, for the same. The network architecture consists of 4 inputs, showed high accuracy in the estimation of variables. The PTFs developed by ANNs outperformed the predictive ability of the standard method (MLR). Thus, the estimate of the retention curve of soil water by means of ANNs trained by classes textures, presents itself as a subsidy techniques adopted in irrigated agriculture.

Keywords: Pedofunctions. Soil Moisture. Potential matrix. Artificial Intelligence

LISTA DE FIGURAS

Figura 1 - Modelo matemático de um neurônio biológico.....	48
Figura 2 – Modelo de neurônio base para projetos de RNAs.....	48
Figura 3 – Exemplos de arquiteturas de RNAs	51
Figura 4 - Estrutura topológica da rede neural <i>MLP</i>	56
Figura 5 - Fluxo do algoritmo <i>backpropagation</i>	58
Figura 6 - Variabilidade textural dos solos do Estado do Rio Grande do Sul disponíveis no banco de dados utilizado para desenvolver as FPTs.....	64
Figura 7 - Arquitetura da rede neural	75
Figura 8 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural arenoso.....	87
Figura 9 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural arenoso franco.....	90
Figura 10 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argilo arenoso	92
Figura 11 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argilo siltoso	93
Figura 12 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argiloso	95
Figura 13 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco	97
Figura 14 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco arenoso	99
Figura 15 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argilo arenoso	101
Figura 16 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argilo siltoso ...	104
Figura 17 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argiloso	106
Figura 18 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco siltoso.....	108
Figura 19 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural muito argiloso.....	109
Figura 20 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para o banco de dados geral	113
Figura 21 - Valores de umidade volumétrica observados na literatura e preditos com a rede2.....	116
Figura 22 - Valores de umidade volumétrica observados na literatura e preditos com a rede3.....	117

Figura 23 - Valores de umidade volumétrica observados na literatura e preditos com a rede4.....	118
Figura 24 - Valores de umidade volumétrica observados na literatura e preditos com a rede5.....	119
Figura 25 - Valores de umidade volumétrica observados na literatura e preditos com a rede6.....	120
Figura 26 - Valores de umidade volumétrica observados na literatura e preditos com a rede7.....	121
Figura 27 - Valores de umidade volumétrica observados na literatura e preditos com a rede8.....	122
Figura 28 - Valores de umidade volumétrica observados na literatura e preditos com a rede9.....	123
Figura 29 - Valores de umidade volumétrica observados na literatura e preditos com a rede10.....	124
Figura 30 - Valores de umidade volumétrica observados na literatura e preditos com a rede11.....	125
Figura 31 - Valores de umidade volumétrica observados na literatura e preditos com a rede12.....	126
Figura 32 - Valores de umidade volumétrica observados na literatura e preditos com a rede13.....	127
Figura 33 - Valores de umidade volumétrica observados na literatura e preditos com a rede1.....	128
Figura 34 - Comparação entre valores de umidade do solo observados, na classe Are, e estimados pelas FPTs geral e FPTs Are.....	133
Figura 35 - Comparação entre valores de umidade do solo observados, na classe AF, e estimados pelas FPTs geral e FPTs AF.....	134
Figura 36 - Comparação entre valores de umidade do solo observados, na classe ArgAre, e estimados pelas FPTs geral e FPTs ArgAre.....	134
Figura 37 - Comparação entre valores de umidade do solo observados, na classe ArgS, e estimados pelas FPTs geral e FPTs ArgS.....	135
Figura 38 - Comparação entre valores de umidade do solo observados, na classe Arg, e estimados pelas FPTs geral e FPTs Arg.....	135
Figura 39 - Comparação entre valores de umidade do solo observados, na classe F, e estimados pelas FPTs geral e FPTs F.....	136
Figura 40 - Comparação entre valores de umidade do solo observados, na classe FAre, e estimados pelas FPTs geral e FPTs FAre.....	136
Figura 41 - Comparação entre valores de umidade do solo observados, na classe FArgAre, e estimados pelas FPTs geral e FPTs FArgAre.....	137
Figura 42 - Comparação entre valores de umidade do solo observados, na classe FArgS, e estimados pelas FPTs geral e FPTs FArgS.....	137
Figura 43 - Comparação entre valores de umidade do solo observados, na classe FArg, e estimados pelas FPTs geral e FPTs FArg.....	138

Figura 44 - Comparação entre valores de umidade do solo observados, na classe FS, e estimados pelas FPTs geral e FPTs FS.....	138
Figura 45 - Comparação entre valores de umidade do solo observados, na classe MArg, e estimados pelas FPTs geral e FPTs MArg.....	139
Figura 46 - Comparação entre valores de umidade do solo observados, na classe Are, e estimados pela rede 1 e rede 2.....	142
Figura 47 - Comparação entre valores de umidade do solo observados, na classe AreF, e estimados pela rede 1 e rede 3.....	142
Figura 48 - Comparação entre valores de umidade do solo observados, na classe ArgAre, e estimados pela rede 1 e rede 4.....	143
Figura 49 - Comparação entre valores de umidade do solo observados, na classe ArgS, e estimados pela rede 1 e rede 5.....	143
Figura 50 - Comparação entre valores de umidade do solo observados, na classe Arg, e estimados pela rede 1 e rede 6.....	144
Figura 51 - Comparação entre valores de umidade do solo observados, na classe F, e estimados pela rede 1 e rede 7.....	144
Figura 52 - Comparação entre valores de umidade do solo observados, na classe FAre, e estimados pela rede 1 e rede 8.....	145
Figura 53 - Comparação entre valores de umidade do solo observados, na classe FArgAre, e estimados pela rede1 e rede9.....	145
Figura 54 - Comparação entre valores de umidade do solo observados, na classe FArgS, e estimados pela rede 1 e rede 10.....	146
Figura 55 - Comparação entre valores de umidade do solo observados, na classe FArg, e estimados pela rede 1 e rede 11.....	146
Figura 56 - Comparação entre valores de umidade do solo observados, na classe FS, e estimados pela rede 1 e rede 12.....	147
Figura 57 - Comparação entre valores de umidade do solo observados, na classe MArg, e estimados pela rede 1 e rede 13.....	147

LISTA DE TABELAS

Tabela 1 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs do Banco de dados geral	65
Tabela 2 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural arenoso	66
Tabela 3 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural arenoso franco	66
Tabela 4 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argilo arenoso	67
Tabela 5 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argilo siltoso	67
Tabela 6 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argiloso.....	68
Tabela 7 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco	68
Tabela 8 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco arenoso	69
Tabela 9 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argilo arenoso.....	69
Tabela 10 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argilo siltoso	70
Tabela 11 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argiloso.....	70
Tabela 12 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco siltoso	71
Tabela 13 – Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural muito argiloso	71
Tabela 14 – Número de amostras utilizadas, para geração e validação das FPTs, nas distintas classes texturais.....	73

Tabela 15 – Classe textural do solo e número de amostras totais utilizadas em cada rede	75
Tabela 16 – Classificação para o índice de desempenho (id) do método proposto. .	79
Tabela 17 – Coeficiente de correlação (r) entre as variáveis e a umidade retida a diferentes potenciais dos dados utilizados para gerar as funções de pedotransferência das diferentes classes de solo, de solos do RS.....	83
Tabela 18 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe arenoso e respectivo coeficiente de determinação...	86
Tabela 19 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural arenoso franco e respectivo coeficiente de determinação.....	89
Tabela 20 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argilo arenoso e respectivo coeficiente de determinação.....	91
Tabela 21 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argilo siltoso e respectivo coeficiente de determinação.....	94
Tabela 22 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argiloso e respectivo coeficiente de determinação.....	96
Tabela 23 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe franco e respectivo coeficiente de determinação.....	98
Tabela 24 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco arenoso e respectivo coeficiente de determinação.....	100
Tabela 25 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argilo arenoso e respectivo coeficiente de determinação.....	102
Tabela 26 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argilo siltoso e respectivo coeficiente de determinação.....	103
Tabela 27 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argiloso e respectivo coeficiente de determinação.....	105

Tabela 28 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco siltoso e respectivo coeficiente de determinação.....	107
Tabela 29 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural muito argiloso e respectivo coeficiente de determinação.....	110
Tabela 30 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados geral e respectivo coeficiente de determinação.....	112
Tabela 31 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, nos diferentes métodos de estimativa da retenção de água no solo.	132
Tabela 32 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, nos diferentes métodos de estimativa da retenção de água no solo.	140
Tabela 33 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, entre os diferentes métodos de estimativa da retenção de água no solo	149

LISTA DE SÍMBOLOS

FPT – Função de pedotransferência

RLM – Regressão linear múltipla

RNA – Rede neural artificial

MO – matéria orgânica

Ds - densidade do solo

Dp - densidade de partículas

η - porosidade total;

Are – Solo arenoso

AF – Solo arenoso franco

ArgAre – Solo argilo arenoso

ArgS – Solo argilo siltoso

Arg – Solo argiloso

F – Solo franco

FAre – Solo franco arenoso

FArgAre – Solo franco argilo arenoso

FArgS - Solo franco argilo siltoso

FArg – Solo franco argiloso

FS – Solo franco siltoso

MArg - Solo muito argiloso

Geral - Todos os dados de solos, independentes da classe

FPTs geral – Equações de RLM geradas no banco de dados geral

FPTs Are – Equações de RLM geradas no banco de dados Arenoso

FPTs AF - Equações de RLM geradas no banco de dados arenoso franco

FPTs ArgAre - Equações de RLM geradas no banco de dados argilo arenoso

FPTs ArgS - Equações de RLM geradas no banco de dados argilo siltoso

FPTs Arg - Equações de RLM geradas no banco de dados argiloso

FPTs F - Equações de RLM geradas no banco de dados franco

FPTs FAre - Equações de RLM geradas no banco de dados franco arenoso

FPTs FArgAre - Equações de RLM geradas no banco de dados franco argilo arenoso

FPTs FArgS - Equações de RLM geradas no banco de dados franco argilo siltoso

FPTs FArg - Equações de RLM geradas no banco de dados franco argiloso

FPTs FS - Equações de RLM geradas no banco de dados franco siltoso

FPTs MArg - Equações de RLM geradas no banco de dados muito argiloso

Rede 1 - rede treinada para o banco de dados geral

Rede 2 – rede treinada para a classe textural arenosa

Rede 2 – rede treinada para a classe textural arenoso franco

Rede 4 – rede treinada para a classe textural argilo arenoso

Rede 5 - rede treinada para a classe textural argilo siltoso

Rede 6 - rede treinada para a classe textural argiloso

Rede 7 - rede treinada para a classe textural franco

Rede 8 - rede treinada para a classe textural franco arenoso

Rede 9 - rede treinada para a classe textural franco argilo arenoso

Rede 10 - rede treinada para a classe textural franco argilo siltoso

Rede 11 - rede treinada para a classe textural franco argiloso

Rede 12 - rede treinada para a classe textural franco siltoso

Rede 13 - rede treinada para a classe textural muito argiloso

R^2 – Coeficiente de determinação

LISTA DE APÊNDICES

Apêndice A – Treinamento de diferentes arquiteturas para estimativa da umidade do solo arenoso nos diferentes potenciais.	186
Apêndice B – Treinamento de diferentes arquiteturas para estimativa da umidade do solo arenoso franco nos diferentes potenciais.	187
Apêndice C – Treinamento de diferentes arquiteturas para estimativa da umidade do solo argiloso nos diferentes potenciais.	188
Apêndice D – Treinamento de diferentes arquiteturas para estimativa da umidade do solo franco nos diferentes potenciais.	189
Apêndice E – Treinamento de diferentes arquiteturas para estimativa da umidade do solo franco siltoso nos diferentes potenciais.	190
Apêndice F – Treinamento de diferentes arquiteturas para estimativa da umidade do solo muito argiloso nos diferentes potenciais.	191
Apêndice G – Resultados da rede-2, para estimativa da umidade do solo arenoso nos diferentes potenciais.	192
Apêndice H – Resultados da rede-3, para estimativa da umidade do solo arenoso franco nos diferentes potenciais.	192
Apêndice I – Resultados da rede-4, para estimativa da umidade do solo argiloso arenoso nos diferentes potenciais.	193
Apêndice J – Resultados da rede-5, para estimativa da umidade do solo argiloso siltoso nos diferentes potenciais.	193
Apêndice K – Resultados da rede-6, para estimativa da umidade do solo argiloso nos diferentes potenciais.	194
Apêndice L – Resultados da rede-7, para estimativa da umidade do solo franco nos diferentes potenciais.	194
Apêndice M – Resultados da rede-8, para estimativa da umidade do solo franco arenoso nos diferentes potenciais.	195
Apêndice N – Resultados da rede-9, para estimativa da umidade do solo franco argilo arenoso nos diferentes potenciais.	195
Apêndice O – Resultados da rede-10, para estimativa da umidade do solo franco argilo siltoso nos diferentes potenciais.	196
Apêndice P – Resultados da rede-11, para estimativa da umidade do solo franco argiloso nos diferentes potenciais.	196
Apêndice Q – Resultados da rede-12, para estimativa da umidade do solo franco siltoso nos diferentes potenciais.	197
Apêndice R – Resultados da rede-13, para estimativa da umidade do solo muito argiloso nos diferentes potenciais.	197
Apêndice S – Resultados da rede-1, para estimativa da umidade do solo para o banco de dados geral, nos diferentes potenciais.	198

SUMÁRIO

1 INTRODUÇÃO	19
2 REVISÃO DE LITERATURA	23
2.1 Curva característica de água no solo.....	24
2.1.1 Fatores que influenciam a curva de água no solo	26
2.1.2 A importância da curva de retenção da água no solo	30
2.1.3 Métodos para obtenção da curva de retenção da água no solo.....	31
2.1.3.1 Métodos diretos	32
2.1.3.2 Métodos indiretos	36
2.1.3.2.1 Funções de pedotransferência	36
2.1.3.2.1.1 Regressão Linear Múltipla.....	42
2.1.3.2.1.2 Redes Neurais Artificiais	43
2.1.3.2.1.2.1 Histórico	45
2.1.3.2.1.2.2 O neurônio artificial e a rede neural.....	47
2.1.3.2.1.2.3 Arquitetura da rede neural artificial.....	49
2.1.3.2.1.2.4 Treinamento das redes neurais artificiais	52
2.1.3.2.1.2.5 Modelos de aprendizagem	54
2.1.3.2.1.2.6 Redes do tipo <i>Perceptron</i> de Múltiplas Camadas.....	55
2.1.3.2.1.2.7 Aplicações de redes neurais na área agrícola.....	58
3 MATERIAL E MÉTODOS	63
3.1 Bancos de Dados: obtenção e caracterização	63
3.2 Desenvolvimento das Funções de Pedotransferência.....	72
3.2.1 FPTs geradas por regressão linear múltipla.....	72
3.2.2 FPTs geradas a partir de Redes Neurais Artificiais.....	73
3.2.2.1 Definição da entrada e saída das RNAs.....	74
3.2.2.2 Treinamento e validação da rede	76
3.2.3 Análise dos dados	77
4 RESULTADOS E DISCUSSÃO	80
4.1 Correlações entre as variáveis e a retenção de água	80
4.2 FPTs pontuais obtidas por regressão linear múltipla	85
4.2.1. Estimativa da retenção de água para classe de solo arenoso	85
4.2.2 Estimativa da retenção de água para classe de solo arenoso franco	87
4.2.3 Estimativa da retenção de água para classe de solo argilo arenoso.....	90
4.2.4 Estimativa da retenção de água para classe de solo argilo siltoso	93

4.2.5 Estimativa da retenção de água para classe de solo argiloso.....	95
4.2.6 Estimativa da retenção de água para classe de solo franco	97
4.2.7 Estimativa da retenção de água para classe de solo franco arenoso	99
4.2.8 Estimativa da retenção de água para classe de solo franco argilo arenoso...	101
4.2.9 Estimativa da retenção de água para classe de solo franco argilo siltoso	103
4.2.10 Estimativa da retenção de água para classe de solo franco argiloso	104
4.2.11 Estimativa da retenção de água para classe de solo franco siltoso	106
4.2.12 Estimativa da retenção de água para classe de solo muito argiloso	108
4.2.13 Estimativa da retenção de água para classe de solo geral	111
4.3 FPTs pontuais obtidas por redes neurais artificiais	114
4.3.1 Estimativa da retenção de água para classe de solo arenoso	115
4.3.2 Estimativa da retenção de água para classe de solo arenoso franco	116
4.3.3 Estimativa da retenção de água para classe de solo argilo arenoso.....	117
4.3.4 Estimativa da retenção de água para classe de solo argilo siltoso	118
4.3.5 Estimativa da retenção de água para classe de solo argiloso.....	119
4.3.6 Estimativa da retenção de água para classe de solo franco	120
4.3.7 Estimativa da retenção de água para classe de solo franco arenoso	121
4.3.8 Estimativa da retenção de água para classe de solo franco argilo arenoso...	122
4.3.9 Estimativa da retenção de água para classe de solo franco argilo siltoso	123
4.3.10 Estimativa da retenção de água para classe de solo franco argiloso	124
4.3.11 Estimativa da retenção de água para classe de solo franco siltoso	125
4.3.12 Estimativa da retenção de água para classe de solo muito argiloso	126
4.3.13 Estimativa da retenção de água para o banco de dados geral.....	127
4.4 Desempenho das FPTs geradas por classes texturais.....	130
4.4.1 FPTs por classes, obtidas por RLM	131
4.4.2 FPTs por classes, obtidas por RNAs.....	140
4.5 Comparação entre as FPTs desenvolvidas por RLM e RNAs	148
5 CONCLUSÃO	153
6 REFERÊNCIAS BIBLIOGRÁFICAS	154

1 INTRODUÇÃO

Diversos estudos, sobre as perspectivas do mercado agrícola futuro, destacam que a irrigação será a grande responsável pelo aumento na produtividade das culturas em nível mundial. A previsão é que as áreas irrigadas nos países em desenvolvimento devam aumentar em torno de 20%. No entanto, há uma estimativa de que um em cada cinco países em desenvolvimento sofrerá com a escassez de água, além de que a disponibilidade e o acesso aos recursos hídricos são os elementos decisivos para a agricultura e o abastecimento alimentar no futuro. Nesse sentido, o uso racional dos recursos hídricos, visando à conservação da água, constitui um aspecto de grande relevância para uma produção mais sustentável. Assim, a busca de tecnologias e informações que contribuam para um adequado manejo do solo, e o uso da água se faz cada vez mais necessária.

O conhecimento das propriedades hídricas do solo é fundamental para o estabelecimento de boas práticas agrícolas, bem como de técnicas de irrigação e drenagem. Dentre as propriedades físico-hídricas, uma de difícil caracterização tanto pelo tempo que se consome nas análises, quanto pela mão de obra qualificada, destaca-se a curva de retenção da água no solo, abreviadamente conhecida por curva de retenção ou curva característica de água no solo. Esta curva expressa a relação entre a umidade do solo, a base de massa ou volume, e o potencial mátrico, correspondente, a qual é extremamente importante em quaisquer estudos que envolvem água no solo.

Descrições da curva de retenção são necessários para muitos estudos e aplicações relacionadas com o movimento da água e, transporte de solutos na zona não saturada ou quanto ao cálculo da água disponível para as culturas. Por meio da curva de retenção, determinada experimentalmente para cada horizonte e solo, é possível obter modelos de transporte de solutos na região não saturada do solo, permitindo monitorar a qualidade do ambiente na subsuperfície.

Muitos fatores afetam a retenção de água em um solo, sendo a textura um dos principais, pois ela, diretamente, determina a área de contato entre as partículas sólidas e a água e, as proporções de poros de diferentes tamanhos. A estrutura

também afeta a retenção de água, pois esta determina o arranjo das partículas, que, por sua vez, vai determinar a distribuição de poros.

Os métodos para elaboração de curvas de retenção de água no solo podem ser classificados em métodos diretos e indiretos. Os métodos diretos caracterizam-se por apresentar procedimentos que medem os valores de umidade e potencial de água no solo, a partir de amostras deformadas ou indeformadas, determinadas em laboratórios ou a campo (métodos *in situ*). Estes procedimentos permitem a coleta de medidas que poderão gerar a relação funcional da curva característica. Estes métodos têm como principal vantagem a precisão e a exatidão dos resultados. Em contrapartida caracterizam-se por apresentar alto custo e mão de obra onerosa, bem como elevado tempo para análises das amostras. Estas características, custo-mão de obra-tempo, atrelados, trazem como principal consequência o seu reduzido uso, para o manejo da irrigação, realizado pelo setor produtivo. Sendo assim, na conjuntura atual observa-se que o manejo dos sistemas irrigados é realizado sem consideração de um dos principais elementos do manejo racional, que é a curva característica.

Ao observar o reduzido uso da curva característica em projetos de manejo de irrigação, pesquisadores da área de engenharia de água e solos, consideraram a possibilidade da determinação destas curvas por metodologias indiretas, ou seja, métodos preditivos. Assim, nas últimas décadas surgiram modelos matemáticos para estimar a retenção da água no solo, a partir de outras características físicas do solo de fácil determinação. Esses modelos são conhecidos como funções de pedotransferência (FPTs), e se caracterizam pela sua capacidade de estimar atributos de difícil determinação, como o conteúdo de água no solo sob uma determinada tensão, a partir de atributos facilmente obtidos em análises de laboratório, como frações granulométricas, densidade do solo, entre outros.

Existem vários métodos para determinação das FPTs, variando de regressão linear múltipla, modelos lineares generalizados, modelos aditivos generalizados, árvore de regressão, redes neurais, sistemas de lógica difusa entre outros. Porém, devido há facilidade na lógica matemática e a obtenção de resultados aceitáveis, grande maioria das equações hoje desenvolvidas, para estimativa da curva de retenção de água no solo, são geradas a partir de simples regressão linear múltipla, o que, no entanto, não condiz com a realidade, uma vez que não há uma relação linear entre esta propriedade do solo e suas variáveis preditoras. Todavia, vários

autores na literatura indicam as redes neurais artificiais (RNAs), como excelente ferramenta na predição de parâmetros que envolvem dados com tais características. Essas têm sido desenvolvidas por serem mais precisas que as regressões estatísticas tradicionais, na estimativa da retenção de água.

Uma rede neural artificial é um conjunto de elementos processadores (neurônios) interligados por um grande número de conexões, os quais são capazes de aprender (ajuste de pesos), armazenar conhecimentos e adaptar a novas situações. A capacidade de aprender através de exemplos (padrões), e de generalizar (fornecer respostas adequadas para dados que não estão no conjunto de exemplos) é o principal atrativo das redes neurais artificiais. Uma rede neural possibilita solucionar problemas complexos sem a necessidade de definições explícitas entre dados de entradas e saídas.

As primeiras FPTs, desenvolvidas para estimar a curva característica de água no solo, são datadas da década de 70, porém, somente a partir de 1987 começaram-se os estudos para solos brasileiros. Assim, a grande maioria das FPTs, hoje existentes, foram desenvolvidas para solos de outros países, onde as condições climáticas e pedogenéticas levaram a formação de solos diferenciados, aos solos do Brasil, quanto a composição granulométrica e mineralógica. Apesar disso, muitas vezes, devido à falta de informações locais, essas equações são generalizadas e utilizadas para condições climáticas brasileiras, o que pode levar a erros grosseiros na estimativa da retenção da água pelo solo.

Diante disso, nos últimos anos, vêm surgindo um elevado número de equações, que visam a estimativa da retenção de água para solos do Brasil. Essas equações quando avaliadas pelo seu coeficiente de determinação, apresentam boa precisão para a estimativa da curva característica, mas ainda existem dúvidas quanto ao efeito das características dos solos sobre a eficiência dessas, uma vez que as mesmas são aplicadas globalmente, sem levar em conta as peculiaridades de solos com classes texturais diferenciadas.

Dentro deste contexto, é cada vez maior a busca pelo aprimoramento das funções de pedotransferência que visam estimar umidade de solo à diferentes potências matriciais, visando subsidiar às técnicas adotadas na agricultura irrigada, a partir de metodologia menos onerosa e laboriosa, e com maior acurácia.

Frente às questões levantadas foram formuladas as seguintes hipóteses de pesquisa: (i) funções de pedotransferência, desenvolvidas para estimar o conteúdo

de água retida no solo sob determinadas tensões, quando geradas separadamente por classe textural, conseguem expressar resultados com desempenho de estimativa superior às funções de pedotransferências, que desconsideram esta particularidade; (ii) há diferenças na capacidade preditiva para a retenção de água no solo entre os métodos de redes neurais artificiais e regressão linear múltipla.

O presente trabalho apresenta como objetivo geral, gerar funções de pedotransferências para as diferentes classes de solos do Estado do Rio Grande do Sul, por meio de metodologias de predição. Os objetivos específicos foram:

- 1) montar bancos de dados, agrupados por classes texturais, para solos do Estado do Rio Grande do Sul;
- 2) estabelecer e testar FPTs pontuais, que estimem a retenção de água, para as distintas classes de solo do Estado, por meio de regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNAs);
- 3) estabelecer e testar FPTs pontuais, a partir da metodologia padrão, que desconsidera a heterogeneidade textural do banco de dados, por meio de RLM e RNAs;
- 4) testar diferentes configurações de rede, alternando as variáveis de entrada e o número de neurônios na camada intermediária;
- 5) avaliar a eficiência de predição das FPTs propostas no trabalho, em relação às obtidas pela metodologia padrão;
- 6) avaliar as vantagens do uso da rede neural comparativamente à análise de regressão linear múltipla, no desenvolvimento de funções de pedotransferência para a estimativa da retenção de água no solo.

2 REVISÃO DE LITERATURA

O estudo das propriedades físico-hídricas de um solo é de grande importância, visto que afeta preponderadamente o seu uso. Assim sendo, a exploração racional e econômica de áreas irrigadas, requer a elaboração de um criterioso dimensionamento e, manejo adequado dos sistemas de irrigação e drenagem levando-se, em consideração, as alterações das características físico-hídricas do solo, como forma de atender satisfatoriamente as necessidades hídricas das plantas. Devido à importância da água no desenvolvimento das plantas e suas implicações em várias propriedades do solo, a determinação do teor de água no solo sempre foi de grande interesse, tanto no aspecto científico como no econômico.

Deste modo, um dos parâmetros que pode servir de auxílio ao produtor no manejo da irrigação é a determinação da curva de retenção de água do solo, que representa a relação entre o teor de água e a energia com a qual ela está retida no solo, esse conhecimento é essencial no estudo das relações solo-água. No entanto, constitui uma propriedade de difícil caracterização tanto pelo tempo que se consome nas análises quanto pela intrínseca modificação da amostra devido à histerese. Sua determinação pode ser efetuada a campo (*in situ*), por meio de técnicas tradicionais de laboratório, ou através de métodos indiretos, os quais utilizam dados taxonômicos simples para a estimativa da capacidade de retenção da água nos solos. Dentre estes métodos, indiretos, se destacam as funções de pedotransferência, as quais descrevem equações que expressam dependências da retenção da água com parâmetros básicos disponíveis em levantamentos de solos.

Neste capítulo será apresentado o estado-da-arte em relação aos fundamentos teóricos do processo, para a determinação da curva característica de água no solo, de interesse neste trabalho. Será feita uma breve discussão sobre a importância da determinação deste parâmetro físico-hídrico, destacando: conceito, sua importância dentro do setor agrícola e métodos de obtenção. Também serão abordados alguns aspectos relacionados à simulação computacional utilizando modelos matemáticos e a técnica de estimativa do parâmetro estudado, bem como destacando a influência, que as práticas de modelagem têm no setor.

2.1 Curva característica de água no solo

Um solo saturado em equilíbrio com a água livre, sob pressão atmosférica, quando submetido a uma força de sucção, terá parte de sua água retirada e o ar penetrará em seu interior. Aumentando-se a sucção, poros cada vez menores perderão água, dando entrada a mais ar. Aplicando-se aumentos gradativos, o fenômeno se repetirá, com diminuição da espessura da película de água que envolve as partículas de solo. Esta água, estando “presa” mais fortemente, exigirá sucções cada vez maiores para ser retirada (KLAR, 1988).

Deste modo, pode-se construir um gráfico relacionando as umidades gravimétricas (w) ou volumétricas (θ) do solo, com os esforços de sucção ou potenciais matriciais da água (ψ_m), que é denominado “curva característica da água no solo” ou “curva de retenção” (JURY et al., 1991).

A relação entre umidade do solo e o potencial matricial do solo, denomina-se curva de retenção de água no solo, curva característica de água do solo ou simplesmente curva de retenção, que é a parte fundamental da caracterização das propriedades hidráulicas do solo (DORAN e PARKIN, 1994; CICHOTA e VAN LIER, 2004). A retenção de água na matriz do solo é governada por forças capilares e forças de adsorção, as quais são denominadas de forças mátricas, dando origem ao termo potencial mátrico da água no solo (VIEIRA, 2006).

Libardi (2000) definiu a curva de retenção como sendo a relação funcional entre a quantidade de solução em um volume do solo, em equilíbrio com a tensão aplicada. Esta relação parte do princípio de que a água ocupa os espaços porosos do solo sob determinada tensão, que é dependente da composição granulométrica e do arranjo estrutural do solo, sendo o conteúdo de umidade do solo inversamente proporcional ao seu potencial matricial (VOMOCIL, 1965; CHILDS, 1940).

Através da curva de retenção, identifica-se que, quando o solo se encontra na condição de saturação ou próximo desta, sucções bastante reduzidas são suficientes para extrair água do mesmo. Por outro lado, em solos com umidades reduzidas, a retirada de água exige elevadas sucções. Assim, a curva mostra todas as graduações entre estes extremos, indicando a modificação na tensão com que a água é retida quando diminui ou aumenta a umidade (BRADY e BUCKMAN, 1989).

A curva de retenção permite calcular a quantidade de água que um solo pode reter dentro de determinados limites de potenciais matriciais. Deve-se conhecer toda a curva para poder interpretar as características do armazenamento de água no solo, em relação às necessidades hídricas de determinado cultivo (RIGHES et al., 1983). Reforçando essa ideia, Costa (1998) menciona que a curva característica permite quantificar o conteúdo de água que um solo pode armazenar dentro de um determinado limite de potencial matricial. Essa determinação reveste-se de grande importância, visto que a resposta das plantas está relacionada mais diretamente ao potencial energético da água no solo, do que simplesmente ao teor de água do mesmo.

A relação entre o potencial matricial e a umidade no solo em geral não é unívoca, podendo ser obtida de duas maneiras diferentes: (i) por secamento, tomando uma amostra de solo inicialmente saturada de água e aplicando gradualmente sucções maiores e fazendo medidas sucessivas da sucção, que é o próprio ψ_m , em função de inferências da θ ; (ii) por molhamento, tomando uma amostra de solo inicialmente seca ao ar e permitindo seu molhamento gradual por redução da sucção (REICHARDT e TIMM, 2004).

Dependendo da forma de obtenção da curva de retenção, surgem curvas diferentes, não superpostas. Com isso, os valores de uma mesma umidade corresponderão a potenciais matriciais diferentes. Este fenômeno denomina-se histerese (KLAR, 1988). A histerese decorre da diferença do ângulo de contato da água que recua e avança no espaço poroso do solo, função do tipo de partículas minerais e orgânicas que favorecem a maior ou menor expansão ou contração dos colóides do solo, bem como da não-uniformidade dos raios dos poros capilares do solo (COSTA et al., 2008).

A histerese da curva de retenção dificulta a descrição matemática do fluxo de água no solo, especialmente quando os fenômenos de molhamento e secamento ocorrem simultaneamente. Para contornar parcialmente o problema, usa-se a curva de molhamento para descrever fenômenos de molhamento, a exemplo da infiltração, e a curva de secamento quando o fenômeno é de secamento, como no caso da evaporação (REICHARDT e TIMM, 2004).

Outro aspecto que exige atenção refere-se à variabilidade tanto metodológica quanto espacial da curva de retenção. Os resultados obtidos por Moraes et al. (1993), em seu estudo contemplando 250 curvas construídas a partir de 8 pontos

(ψ_m versus θ), evidenciaram que os problemas analíticos são de tal ordem que podem levar a interpretações errôneas, comprometendo a qualidade e até a comparabilidade de resultados. A variabilidade metodológica mostrou-se elevada, principalmente a altas tensões, devendo-se, portanto, optar pela curva de retenção completa e não apenas por um ou dois pontos de interesse.

De posse da curva característica de um solo, pode-se estimar ψ_m conhecendo-se θ , ou vice-versa. Desde que a geometria do sistema não varie com o tempo, a curva é única e não precisa ser determinada em cada experimento (REICHARDT e TIMM, 2004). A curva característica, bem como outros fatores inerentes aos solos, é variável de amostra para amostra, de local para local, de modo que a determinação de curvas em áreas maiores deverá envolver repetições que apresentem médias representativas e confiáveis (KLAR, 1988).

2.1.1 Fatores que influenciam a curva de água no solo

A retenção da água no solo é afetada por uma série de fatores, que vão desde a distribuição relativa do tamanho, da forma e do arranjo das partículas do solo (SALTER e WILLIAMS, 1965; REEVE et al., 1973; SHARMA e UEHARA, 1968) até a composição e concentração de solutos na solução do solo, no caso deste conter argilas expansivas (EL-SWAIFY e HENDERSON, 1967; THOMAS e MOODIE, 1962). Embora estes fatores possam ser altamente variáveis em uma mesma unidade pedológica, quando se analisa uma amostra das várias repetições consideradas, esta também pode sofrer alterações na curva de retenção, seja por fenômenos de histerese, às vezes tão significativa quanto a própria variabilidade espacial do solo, (ROYER e VACHAUD, 1975).

Alguns fatores têm relevante importância na retenção de água por um solo, porém, a textura merece uma atenção especial, sendo o seu conhecimento de fundamental importância para a determinação da área de contato entre as partículas sólidas e a água, determinando preponderantemente a distribuição do diâmetro dos poros (REICHARDT e TIMM, 2004; RIQUELME, 2004).

A curva de retenção de água é afetada pela textura do solo, de forma que quanto maior for o conteúdo de argila, maior será, em geral, o teor de água retida sob um dado potencial matricial e, mais suave será a inclinação da curva, devido a uma distribuição mais uniforme de tamanho dos poros. Em solos arenosos, normalmente os poros são maiores, sendo mais rapidamente esvaziados a baixas tensões, restando pequenas quantidades de água retidas a potenciais menores, o que explica a inclinação acentuada da curva de retenção de água (HILLEL, 1970; HILLEL, 1982).

Pereira (2004) em seu trabalho observou que pequenas variações de sucção respondem por praticamente toda a variação de umidade nos solos arenosos, enquanto nos solos argilosos modificações sensíveis de umidade são conseguidas pela aplicação de grandes sucções. Isso é explicado pelo fato do solo argiloso possuir poros menores quando comparados ao solo arenoso, ocorrendo a formação de finíssimos capilares. Além disso, o mecanismo de adsorção ocorre de forma mais intensa em solos de textura fina (PEREIRA, 2004).

Jamison e Kroth (1958) constataram que a retenção de água pelo solo na faixa disponível, entre 0,33 e 15 atmosferas, depende da distribuição do tamanho das partículas e que, portanto, um incremento em qualquer componente textural tenderá a modificar a capacidade de armazenamento de água disponível, por seu efeito sobre a distribuição de tamanho de poros.

Beutler et al. (2002), estudando a retenção de água em solos com diferentes manejos, observaram que as frações granulométricas mais finas do solo foram aquelas que mais influenciaram a retenção de água dos mesmos. Petry (2000), trabalhando com solos de três classes texturais, observou que um solo muito argiloso, apresentou maior quantidade total de água armazenada no perfil do que um solo de textura franco-arenosa. No entanto, a disponibilidade de água às plantas foi maior no solo de textura franco-arenosa.

Conseqüentemente, solos de textura fina ou argilosa retêm mais água quando comparados com solos arenosos (REICHARDT, 1985; REICHARDT, 1996). Tal condição é prevista pelo fato de possuírem maior porcentagem de material coloidal, maior espaço poroso e superfície adsortiva muito maior que os solos de textura mais arenosa (CARLESSO e ZIMMERMANN, 2000).

Outra particularidade da curva de retenção de água no solo é que a mesma reflete a distribuição de poros por tamanho, uma vez que a aplicação de

determinada tensão fornece o tamanho dos poros esvaziados no solo (CORDEIRO, 1975). Para altos teores de água no solo, nos quais os fenômenos de capilaridade são importantes, a curva depende do arranjo e dimensões dos poros. Passa a ser, então, uma função da densidade e da porosidade do solo, sendo, influenciada pela estrutura do solo. Por outro lado, para baixos teores de água, a curva praticamente independe do arranjo poroso do solo e, conseqüentemente, da estrutura, dependendo dos fenômenos de adsorção, os quais são mais influenciados pela textura e superfície específica (HILLEL et al., 1972).

Conforme Hillel (1982), a retenção de água pelo solo em condições de altas tensões ou baixo potencial matricial é uma decorrência mais da adsorção e, portanto, está mais relacionada a condições texturais do que estruturais do solo, ou seja, em elevados teores de água (baixas tensões) onde os fenômenos de capilaridade assumem grande importância na determinação do potencial mátrico, a curva de retenção de água fica na dependência da disposição e do tamanho dos poros, ou seja, a curva é função da estrutura do solo, em situações de baixos teores de água (altas tensões), o potencial mátrico praticamente independe dos fatores geométricos, sendo a estrutura de pouca importância em sua determinação (REICHARDT, 1985).

Outro fator é a compactação que, normalmente provoca redução na porosidade total do solo, em decorrência da diminuição dos poros maiores inter-agregados. Isso significa que o conteúdo de água de saturação e os teores de água retidos a baixos potenciais são reduzidos. Já o volume de poros médios, é provavelmente maior em solos compactados, pois muitos poros grandes são reduzidos. Por sua vez, os microporos não sofrem alterações. Assim, a curva para solos compactados pode ser quase idêntica à curva de solos não compactados na faixa de altas sucções (VASCONCELLOS, 1993).

A matéria orgânica, devido a sua alta capacidade adsorviva e a sua influência sobre a estrutura do solo, influi sobre a porosidade, distribuição de tamanho de poros, retenção de água e sobre outras características físicas do solo.

No estado coloidal a matéria orgânica pode reter até 4,4 vezes o valor de sua massa em água. Entretanto a incorporação de matéria orgânica ao solo pode aumentar ou reduzir a capacidade de retenção de água por unidade de volume do solo, dependendo do seu conteúdo inicial. Este fato foi observado por Lassen et al. (1965), os quais afirmam que, estando o conteúdo de matéria orgânica acima de

5%, o peso específico do solo diminui, porque diminui o número de partículas por unidade de volume do solo, já que o revestimento com matéria orgânica aumenta o volume unitário de cada partícula, com um menor número de partículas por unidade de volume, menor superfície estará disponível para a adsorção de água, em consequência do que, embora aumentando a capacidade de retenção de água da partícula, pode reduzir-se a capacidade de retenção de água por unidade de volume do solo.

Segundo Jamison e Kroth (1958), a matéria orgânica influi na capacidade de armazenamento de água disponível mais que o conteúdo de silte, somente em solos de médio a baixo conteúdo de argila (13% a 20%). Em solos argilosos a matéria orgânica tende a formar micro-agregados estáveis, que se assemelham em tamanho ao silte grosso, como estes solos em geral não contem teores muito elevados de matéria orgânica, seu efeito pode ser mascarado pela influência das maiores quantidades de silte e argila.

Exceto para solos arenosos, aumentos de matéria orgânica não aumentam a capacidade de um solo para armazenar água disponível, visto que a maior parte da água retida em materiais orgânicos é extraída por sucções superiores à sucção correspondente ao ponto de murcha (JAMISON, 1953).

Vários trabalhos, procurando relacionar a densidade do solo e a retenção de água, têm sido realizados, apresentando em sua maioria uma concordância. Rosenberg (1964), reportando-se ao efeito da compactação do solo sobre a retenção de umidade, constatou que uma compactação maior ocasionou um aumento na percentagem de água, em qualquer sucção acima de 60 milibares.

Heinonem (1986 apud ROSENBERG, 1964), verificou que a densidade do solo apresenta correlação positiva, com a água disponível em solos arenosos e siltosos e correlação negativa em solos argilosos. Entretanto, independente da textura, há normalmente a ocorrência de grandes decréscimos de água disponível em densidades do solo elevadas.

Segundo Hillel (1970), o decréscimo que ocorre no conteúdo de água em solos compactados, em baixas sucções, se deve ao decréscimo da porosidade total. Entretanto, o volume de poros de tamanho médio é aumentado, além de permanecerem inalterados os poros internos dos aglomerados, o que proporciona maior retenção de água na faixa intermediária de sucção.

2.1.2 A importância da curva de retenção da água no solo

O conteúdo de água no solo é uma variável utilizada em estudos que envolvem agricultura, hidrologia e meteorologia, dentre outros. Na agricultura, essa informação é necessária ao planejamento da irrigação para o aumento da produção agrícola (TEIXEIRA et al., 2005), uma vez que a frequência de irrigação requerida para uma cultura, depende da quantidade de água que pode ser armazenada no solo. Ainda, reforçando essa ideia, vários pesquisadores destacam que a curva de retenção de água no solo tem uma aplicabilidade muito ampla, tanto nos meios científicos como no cotidiano dos produtores, já que simultâneo ao seu conhecimento é possível estimar outros atributos do solo como a porosidade drenável, capacidade de campo, ponto de murcha permanente, água disponível, condutividade hidráulica não-saturada, além de balanço hídrico, determinando-se a variabilidade do armazenamento de água no solo (SCOTT, 2000; CENTURION e ANDRIOLI, 2000; MELLO et al., 2005).

Deste modo, o estudo deste parâmetro físico-hídrico tem ligação direta com o manejo racional do uso da água em sistemas irrigados, uma vez que auxilia os irrigantes na determinação da lâmina de irrigação, a ser aplicada em seus cultivos agrícolas.

O conhecimento do potencial matricial da água nos solos, mediante a curva de retenção, pode ser associado a outros parâmetros do solo e ambientais para avaliar processos hidrológicos, a condutividade hidráulica e os potenciais de expansão ou retração do solo (AMERICAN SOCIETY FOR TESTING AND MATERIALS, 2003), o que permite melhores intervenções antrópicas relativas à vegetação e à produção agrícola (DIENE e MAHLER, 2007).

A curva de retenção, uma vez que relaciona o potencial matricial e a umidade do solo, é parte fundamental da caracterização das propriedades hidráulicas deste (CICHOTA e VAN LIER, 2004). A curva faz-se necessária em estudos de balanço e disponibilidade de água às plantas, de dinâmica da água e solutos no solo e de infiltração (TORMENA e SILVA, 2002). As equações de Darcy-Buckingham e Richards, que permitem quantificar o movimento da água no solo, por exemplo, são modelos que dependem do conhecimento da curva de retenção da água no solo para suas soluções (CÁSSARO et al., 2008).

Estudos mostram que a curva de retenção de água, permite encontrar relações de dependência entre os coeficientes das equações matemáticas que a descrevem, com diversas propriedades do solo. Como diferentes sistemas de uso e manejo do solo podem promover modificações na sua estrutura e, no seu comportamento físico-hídrico, a curva de retenção pode ser utilizada na avaliação da qualidade do solo e, nortear práticas sustentáveis de produção agrícola, mediante esta inter-relação (MACHADO et al., 2008).

Um exemplo disso é apresentado por Cássaro et al. (2008), que consiste no uso da curva de retenção para inferir sobre a distribuição do tamanho dos poros no solo. Isso é possível utilizando-se os parâmetros de ajuste da curva de Van Genuchten para a determinação da função capacidade de água. Em seu estudo, os autores obtiveram informações como a complexidade da gama de poros que compõe a amostra de solo e, a relação entre a variação da granulometria e da densidade do solo e, as modificações de suas propriedades de retenção de água.

2.1.3 Métodos para obtenção da curva de retenção da água no solo

Como visto, a curva de retenção de água no solo é um indicador físico bastante valioso da qualidade do solo. Sua obtenção pode ser diretamente a campo (*in situ*) ou em laboratório, utilizando amostras indeformadas ou deformadas de solo (EMBRAPA, 1997; GONÇALVES et al., 1997; WÖSTEN et al., 2001), fazendo uso de diferentes metodologias, como: funil de Buchner e mesa de tensão, câmara de pressão de Richards, células Temp, psicrômetro termopar, método do equilíbrio com solução salina, entre outros (TAVARES et al., 2008). Verifica-se, também, a utilização de métodos conjugados de determinação da umidade e da tensão, como o uso de equipamentos TDR (Time Domain Reflectometry) associados a tensiômetros (FELICIANO, 2005).

Um procedimento alternativo, para sua obtenção é a partir de métodos indiretos, que consiste em prever a curva característica de água a partir de propriedades de solo disponíveis, como a textura e estrutura, entre outras. Esse método foi padronizado em 1987, por Bouma e Lanen, que o denominaram de funções de pedotransferências (FPTs). Uma vez que vários pesquisadores

quantificavam e interpretaram relações entre propriedades do solo, usando indistintamente os termos predição, estimativa ou correlação de propriedades do solo para nomear índices, procedimentos e resultados de tais estudos. O método consiste em estudos estatísticos através de análise de regressão, lógica fuzzy, redes neurais artificiais, entre outros (RAJKAI et al., 1996).

Segundo Van Diepen et al. (1991), o uso de modelos de simulação para o desenvolvimento e avaliação preliminar de sistema de manejo e, uso do solo em diferentes sistemas de agricultura, aumentou substancialmente nas últimas décadas. Porém, em muitas partes do mundo, a principal limitação para o uso de muitos modelos é a disponibilidade de suficientes bases de dados de solos que sejam precisos e detalhados.

2.1.3.1 Métodos diretos

Diversos são os métodos experimentais para a determinação da curva de retenção da água no solo, cada um com suas peculiaridades metodológicas, vantagens e limitações. Para a obtenção da curva de retenção 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. Esses métodos, no entanto, são grandes demandantes de tempo (SCHUH et al., 1988; WILLIAMS et al., 1992), alguns necessitam de equipamentos onerosos (WOSTEN e VAN GENUCHTEN, 1988) e raramente adequados e disponíveis (SCHUH et al., 1988; VAN DEN BERG et al., 1997) e outros ainda, fazem uso de amostras deformadas, o que não reflete a realidade do campo (OLIVEIRA e SARVASI, 1997).

Os métodos de campo requerem a instalação de equipamentos de monitoramento de umidade do solo, e tem a vantagem de possibilitar a determinação da relação potencial matricial e umidade do solo em muitas profundidades, simultaneamente sob condições naturais. Por outro lado, os métodos de laboratório, possibilitam a análise de um grande número de solos simultaneamente, e com maior facilidade (LIN, 1999).

Tais métodos consistem no levantamento de certo número de pontos, normalmente selecionados de forma arbitrária, com os quais é traçada uma curva que relaciona a umidade volumétrica retida no solo em uma determinada tensão. No ajuste da curva de retenção, é previsível que, quanto maior o número de pontos, mais representativa será a curva de retenção, no entanto, mais oneroso será seu levantamento. Na seleção dos pontos para o traçado da curva de retenção, observa-se que não existe critério padronizado, sendo comum o uso de seis a oito pontos, incluindo o conteúdo de água do solo na saturação, para o ajuste do modelo matemático adotado, como pode ser constatado em vários trabalhos (SILVA et al., 1990; MACEDO et al., 1998; SPERA et al., 2000; SILVA e AZEVEDO, 2002; ABREU et al., 2004; CINTRA et al., 2004).

O métodos laboratoriais apresentam algumas limitações, quanto à dificuldade no controle do ponto de equilíbrio, entre a pressão aplicada e a água retida no solo, não possibilitando a distribuição detalhada e contínua (curvas) dos diâmetros das partículas do solo: (i) a porcentagem de areia é determinada à parte, por peneiramento (CRESTANA, 1994; VAZ et al., 1996; VAZ et al., 1997); (ii) além da elevada ocupação de espaço físico nos laboratórios; (iii) forte dependência da habilidade da pessoa responsável por operar os equipamentos; (iv) elevado prazo de resposta dos laboratórios que podem durar até meses para a determinação da curva de retenção (VAZ et al., 1999; NAIME et al., 2001).

Na obtenção dos dados de retenção de água, em laboratório, podem ser utilizadas amostras com estrutura preservada ou deformada. Amostras com estrutura preservada são utilizadas, para as tensões de 10 e 60 cm pela técnica da mesa de tensão, que consiste em provocar uma drenagem da água retida nos poros das amostras de solo, previamente saturadas, por meio de tensão de coluna de água, até cessar a drenagem (EMBRAPA, 1997). As amostras indeformadas, nas tensões desde -10 kPa até -1500 kPa, são geralmente submetidas às técnicas da câmara de pressão de Richards (placas porosas). Amostras com estruturas não preservadas são utilizadas para potenciais mais baixos (-300 a -1500 kPa) em psicrômetro (por exemplo, WP4 - *Dewpoint potential Meter*) (URACH, 2007).

A metodologia descrita por Richards é o método tradicional de determinação da curva de retenção da água no solo, utilizado sob condições de laboratório (PREVEDELLO, 1996). O equipamento é constituído de uma câmara capaz de suportar alta pressão, ligada à atmosfera por intermédio de uma placa porosa em

seu interior (LIBARDI, 2000). O arranjo instrumental é tal que a parte inferior da placa encontra-se continuamente sob pressão atmosférica, e a parte superior, onde se encontra a amostra de solo, sob pressão controlada de ar, superior à atmosférica (REICHARDT e TIMM, 2004).

Apesar da câmara de pressão de Richards ser o método padrão para a obtenção da curva de retenção, possibilitando alcançar altos valores de pressão até maiores que -1500 kPa, este método apresenta algumas dificuldades: (i) a determinação do ponto de equilíbrio entre a pressão aplicada e a água retida no solo; (ii) o contato amostra-placa; (iii) o longo tempo exigido para as medidas, e (iv) o custo do equipamento (TAVARES et al., 2008).

Por questões práticas, a busca por métodos alternativos à câmara de Richards, financeiramente mais acessíveis e menos morosos, faz-se interessante. Deste modo, outro equipamento, amplamente utilizada nos estudos de tensão-deformação e de propriedades de resistência dos solos, é a câmara de compressão triaxial. Os ensaios consistem na compressão de uma amostra cilíndrica em que se variam as tensões radial e axial. Normalmente, são conduzidos em duas fases: na primeira, denominada de fase de confinamento, aplica-se uma tensão confinante uniforme em todas as direções da amostra e, na segunda, denominada fase de cisalhamento, mantém-se constante o valor da tensão confinante e aumenta-se o valor da tensão axial vertical, através da aplicação de uma força progressiva, até que ocorra a ruptura da amostra (ORTIGÃO, 2007).

Segundo Deka et al. (1995), outro método alternativo a câmara de Richards, à obtenção da curva de retenção de água no solo, em laboratório, é a técnica do método do papel filtro, esta foi utilizado pela primeira vez por Gardner, em 1937. Desde então, o método tem sido usado e investigado por numerosos pesquisadores, destacando-se: Fawcett e Collis-George (1967), Al-Khafaf e Hanks (1974), Chandler e Gutierrez (1986), Houston, et al., (1994), Bulut, et al., (2001), Leong e Rahardjo (2002), Marinho e Oliveira (2006) entre outros.

Briggs e McLane (1910 apud SILVA e AZEVEDO, 2002) descrevem outro método para determinação da curva característica de água no solo: método da centrifuga, que é uma técnica bastante antiga, porém, ainda utilizada em laboratórios de pesquisa onde tem sua importância reconhecida na obtenção da curva de retenção (MALCOM e ANDRÉE, 1991). A mesma apresenta como vantagem operacional a rápida obtenção do equilíbrio da amostra, que ocorre normalmente em

um período inferior a seis horas. No entanto, apresenta como limitações os possíveis erros causados pela compactação das amostras de solo durante o processo de centrifugação (FREITAS JÚNIOR e SILVA, 1984), além da influência do período de centrifugação da amostra de solo na curva de retenção da umidade, afetando principalmente os valores da umidade nas tensões mais elevadas, alterando, portanto, a umidade residual (SILVA e AZEVEDO, 2002).

Outro método é o denominado WP4 (*Dewpoint Potentia Meter*), que consiste em um aparelho que realiza leituras rápidas, em torno de 5 minutos, do potencial de água de uma amostra deformada do solo, a partir do equilíbrio entre a fase vapor da água e a fase líquida presente na amostra dentro da câmara de leitura do aparelho, onde esta fica hermeticamente fechada, medindo então a pressão de vapor do ar (COSTA et al., 2008). Possui a vantagem de proporcionar rápidas leituras, e a desvantagem de ser afetado por mudanças bruscas de temperatura do ambiente e apresentar baixa precisão em potenciais da água próximos e abaixo de - 0,1 MPa.

Dessa forma, existem várias técnicas para determinar o potencial da água nas amostras de solo. Quando se usam amostras com estrutura preservada, o efeito dos macroporos e microporos sobre a retenção de água é mantido, o que retrata melhor as condições reais de campo. No entanto, muitas vezes, a falta de estrutura para coleta e análise de amostras com estrutura preservada leva à determinação da retenção de água em amostras desestruturadas (NEBEL, 2009; NASCIMENTO, 2009). A coleta, a manipulação e as análises são facilitadas nesse tipo de amostras, mas perde-se o efeito natural dos poros na retenção da água, principalmente nos potenciais mais altos (-1 a -100 kPa). Já nos potenciais mais baixos (-100 a -1500 kPa), o efeito da estrutura sobre a retenção de água vai sendo reduzido, e tem-se um aumento acentuado do efeito da granulometria do solo (DOURADO-NETO, 2001).

Em função das dificuldades experimentais e do longo tempo envolvido nessas determinações, têm-se observado um crescente interesse por métodos indiretos de estimativa da capacidade de retenção da água nos solos.

2.1.3.2 Métodos indiretos

Como visto, a determinação da curva de retenção de água do solo pode ser efetuada por meio de técnicas tradicionais de laboratório ou, em condições de campo (SILVA e AZEVEDO, 2002), baseia-se no levantamento de certo número de pontos, normalmente selecionados de forma arbitrária. Com base nesses pontos, é traçada uma curva para representar as características de retenção da água do solo. Porém estas técnicas apresentam algumas limitações, devido principalmente ao tempo gasto para sua obtenção, custo envolvido dos equipamentos, bem como mão de obra qualificada, para sua execução.

Deste modo, têm-se observado um crescente interesse por métodos indiretos de estimativa da capacidade de retenção da água nos solos (ARYA et al., 1999; PACHEPSKY e RAWLS, 1999), a partir da utilização de dados taxonômicos simples, estas são as chamadas funções de pedotransferência (FPT), que descrevem equações que expressam dependências da retenção da água com parâmetros básicos disponíveis em levantamentos de solos.

2.1.3.2.1 Funções de pedotransferência

Várias têm sido as propostas, de metodologias indiretas, para obtenção da condutividade hidráulica e da retenção de água no solo em diferentes potenciais matriciais, uma vez que essas propriedades são relativamente difíceis de serem avaliadas (PAULETTO et al., 1988; DIRKSEN, 1999). Segundo Van den Berg et al. (1997) algumas equações podem fornecer um ajuste global bom para curvas de retenção, contudo, podem ocasionar baixa precisão em estimativas de conteúdos de água em potenciais particulares no solo.

Bouma e Lanen (1987) denominaram as equações de regressão estatística que expressam relações entre propriedades do solo, de “funções de transferência” e mais tarde “funções de pedotransferência” (BOUMA, 1989). Este termo foi introduzido para padronizar outros termos anteriormente utilizados com a mesma finalidade (McBRATNEY et al., 2002). Assim, as funções de pedotransferência

(FPTs) foram definidas como a estimativa de certas propriedades do solo a partir de propriedades mais facilmente, baratas ou rotineiramente medidas (BOUMA, 1989; VAN DEN BERG et al., 1997; McBRATNEY et al., 2002; SAXTON et al. 1986; MENG et al. 1987; RAWLS et al. 1991; KERN 1995; TOMASELLA et al., 2000).

Deste modo, funções de pedotransferência são equações de regressão ou modelos que relacionam propriedades básicas do solo entre si, e que são de importância para produção agrícola, e manejo de recursos naturais (SALCHOW et al., 1996). Segundo Wagenet et al. (1991), citado por Tietje e Hennings (1996), o princípio das FPTs consiste em que o sistema de informação ou os dados de solo permitam expressar, de forma matemática, funções de pedotransferência específicas para uma variedade de propriedades e qualidades de solo.

Contudo, Minasny et al. (2003) alertam para a necessidade de se definir dois princípios básicos de FPTs, evitando assim, o mau uso do conceito pedotransferência: (i) eficiência; (ii) incerteza. O primeiro princípio se refere a não prognosticar algo que é mais fácil e mais barato medir ou determinar. Como o objetivo de funções de pedotransferência é prever propriedades cujas medidas ou determinações diretas são difíceis, laboriosas ou muito caras, os preditores devem ser de obtenção mais fácil ou mais barata. O custo e o esforço para obter a informação sobre o preditor, deverá ser menor do que o de obter a informação sobre o que se pretende prever. O segundo princípio se refere a não usar FPTs, a menos que se possa avaliar a incerteza associada e, para um determinado problema, se um conjunto de FPTs alternativas está disponível, usar aquela com menor variância.

Uma FPT tende a ser tão mais precisa quanto mais homogêneo forem os solos que compõem a base de dados e, quanto mais próximos destes estiverem os que terão seus dados estimados (OLIVEIRA et al., 2002).

Wösten et al. (2001) distinguem três diferentes tipos de FPTs para estimar propriedades hidráulicas: i) tipo 1 - predição de propriedades hidráulicas baseada no modelo da estrutura do solo: são exemplos deste tipo de FPT os modelos apresentados por Bloemen (1980) e Arya e Paris (1981) onde a curva de retenção de água foi estimada a partir da sua relação com a forma e o tamanho dos poros do solo; ii) tipo 2 – predição de um ponto da curva de retenção de água do solo (denominada de FPT pontual): neste tipo de FPT são estimados pontos específicos de interesse da curva de retenção de água do solo; iii) tipo 3 – predição de parâmetros usados para descrever as propriedades hidráulicas do solo (denominada

de FPT paramétrica): neste tipo as FPTs são relações funcionais que transformam propriedades do solo disponíveis (ex: textura, estrutura, matéria orgânica do solo, etc.) em propriedades do solo não disponíveis (ex: curva de retenção de água no solo).

Várias equações empíricas, para estimativa da curva característica de água no solo, foram citadas e propostas por Hillel (1971), mas essas equações continham várias limitações. Ghosh (1976) recomendou um modelo empírico baseado no conteúdo de areia e silte do solo, mas com o inconveniente de que só eram aplicáveis para solos de textura arenosa. Em 1979, Gupta e Larson desenvolveram as primeiras equações de regressão baseadas na porcentagem de areia, silte, argila, matéria orgânica e densidade de solo, para prever a retenção de água no solo a 12 potenciais mátricos, com um arranjo entre -4 e -1500 kPa. Ghosh (1980) apresentou equações empíricas que consideram as propriedades mecânicas do solo e que tem uma aplicabilidade abrangente no cálculo estimativo da curva característica de água no solo.

Rawls et al. (1982) e Rawls et al. (1991), usando uma base de dados de 18 estados de E.U.A, incluindo 2543 horizontes e 500 solos, testaram a validade das equações de regressão baseado nas equações obtidas por Gupta e Larson (1979). Subseqüentemente, Rawls et al. (1982) desenvolveram funções de predição para retenção de água no solo e condutividade hidráulica a partir de propriedades presentes no solo. Já em 1983, De Jong et al., apresentaram relações funcionais entre o teor de água no solo e de sucção de água. Essas foram analisadas e relacionadas à dados texturais e matéria orgânica. As curvas de retenção de água entre -5 e -10000 kPa foram determinados com amostras deformadas de 18 solos grupos de solos, representativos, das pradarias Canadenses. O melhor ajuste foi obtido com um modelo de regressão linear de segunda ordem. As análises de correlação e de regressão mostraram que a textura foi a principal propriedade do solo que influenciam a forma e a posição da curva de retenção de água.

Mayr e Jarvis (1999) desenvolveram FPTs para a estimativa da retenção de água no solo de 286 horizontes de Inglaterra, e essas funções foram validadas com valores de uma base de dados composta por 1678 horizontes, e para obter as FPTs foram usados os parâmetros de Hutson-Cass modificados por Brooks-Corey. Bell e van Keulen (1995) apresentaram funções de pedotransferência para 4 solos do

México, incluindo 148 amostras dos solos, os dados foram baseados nas equações de Helling et al. (1964) e Bell (1993).

Os parâmetros hidráulicos de solos europeus também foram estimados a partir de funções de pedotransferência. Segundo Wösten et al. (1998), para derivar as FPTs, 18 instituições em 10 países da Europa participaram no estabelecimento de uma base de dados, denominada HYPRES "Hydraulic Properties of European Soils". Apenas como um exemplo do tipo de novas informações que podem ser obtidas a partir da combinação das FPTs, juntamente com a base de dados, foi gerado um mapa de capacidade de armazenamento de água nos solos europeus. Desse modo, eles concluíram que este trabalho constituiu uma única fonte de informação para obter as características hidráulicas dos solos.

Para estimar as propriedades hidráulicas de solos portugueses, Gonçalves et al. (1997) utilizaram FPTs. Estas foram desenvolvidas por regressão entre dados hidráulicos e propriedades básicas dos solos. Os parâmetros foram quantificados para: i) modelo de retenção de Van Genuchten usando 80 perfis do solo com um total de 230 curvas de retenção; ii) modelo de condutividade de Gardner usando 20 perfis do solo e 129 curvas de condutividade hidráulica. Os parâmetros destes modelos foram relacionados com propriedades básicas do solo, através de regressões múltiplas, a fim de se obter as FPTs. Os resultados mostraram que os parâmetros de retenção de água no solo obtidos pelas FPTs foram piores que aqueles obtidos, por exemplo, com os modelos de Gonçalves (1988) e de Wösten e Van Genuchten (1988), enquanto que os resultados das condutividades mostraram-se ligeiramente melhores.

No Brasil, os primeiros trabalhos desenvolvidos sobre FPTs datam de 1987, onde se fizeram as funções de pedotransferência para os solos do Estado de São Paulo. Arruda et al. (1987) fizeram a primeira tentativa do uso de equações de regressão para estimar a água disponível, em vários potenciais matriciais, com base na textura do solo. Em 1990, Silva et al., apresentaram as equações dos solos semiáridos do Nordeste. Posteriormente, Van den Berg et al. (1997) publicaram um trabalho de FPTs para estimar a água disponível para as plantas com os parâmetros de Van Genuchten para oxissolos usando dados de vários países, incluindo o Brasil. Em outro estudo, Tormasella e Hodnett (1998) derivaram e testaram as FPTs para estimar os parâmetros de retenção de Brooks e Corey (1964), usando dados de solos da Amazônia Brasileira. Bernoux et al. (1998) verificaram que a densidade do

solo poderia ser prevista com bom nível de exatidão a partir do teor de argila do solo.

Tomasella et al. (2000) desenvolveram FPTs, para estimativa da curva característica de água em solo brasileiros, utilizaram-se regressões múltiplas para derivar os coeficientes que relacionam os parâmetros da equação de van Genuchten com dados básicos dos solos. As FPTs foram desenvolvidas para quatro níveis de disponibilidade de dados básicos de solos e validadas usando dados independentes de 113 horizontes de solos brasileiros. As FPTs foram validadas para prever a curva de retenção dos solos brasileiros, tendo-se verificado a não validade quando se utiliza as FPTs a partir de dados de solos de regiões temperadas para prever a curva de retenção de água para solos tropicais.

Em 2002, Oliveira et al., desenvolveram as FPTs para a predição da umidade retida a potenciais específicos em solos do estado de Pernambuco, usando 98 perfis de solos, num total de 467 horizontes. No estudo foram utilizadas equações de regressão apresentadas na literatura como as de Arruda et al. (1987), Meng et al. (1987), Bell e van Keulen (1995) e Massuti (1997).

Para os solos do Rio Grande do Sul (RS), Giarola et al. (2002), Solano (2003), Urach (2007), Reichert et al. (2009) e Michelin (2010) desenvolveram FPTs a partir de conjuntos de dados com representação de diversos tipos de solos de regiões do RS. Essas foram geradas a partir de todo o conjunto de dados, desconsiderando as diferenças espaciais das características físico-hídricas do mesmo.

Diferentes abordagens têm sido utilizadas para o desenvolvimento de funções de pedotransferência, a exemplo daquelas descritas em Minasny et al. (1999), Cornelis et al. (2001), Minasny e McBratney (2002) e McBratney et al. (2002). Na literatura predominam trabalhos que apresentam funções de pedotransferência para a condutividade hidráulica saturada, para a curva de retenção de água no solo, especialmente em solos de regiões de clima temperado (WÖSTEN et al., 1999; WÖSTEN et al., 2001), os quais apresentam diferenças importantes em relação aos solos tropicais (HODNETT e TOMASELLA, 2002).

Estas FPTs desenvolvidas no Brasil incorporaram grande variação de solos com ampla diversidade pedogenética e mineralógica, exceto, alguns trabalhos, como Silva et al. (2008) que desenvolveu FPTs para Latossolos do estado de São Paulo, o de Van den Berg et al. (1997) que avaliou solos de vários países de regiões tropical,

todos predominantemente Latossolos, e Nebel et al. (2009) que gerou FPTs específicas, para solos de várzeas do Estado do Rio Grande do Sul.

Nebel em 2009 levantou o questionamento a respeito do desempenho das FPTs, quando aplicadas a solos de uma região geograficamente próxima da região para onde a FPT foi desenvolvida, com faixa de amplitude das variáveis explanatórias dentro da faixa de validação da FPT, mas com características do material de origem e ambiente de formação do solo diferente ou com pouca representação no conjunto de solos que deu origem a FPT.

Relacionado aos questionamentos referidos anteriormente, Van den Berg et al. (1997) discutem que as diferenças físicas e químicas entre os solos de regiões temperada e tropical podem ser as causas do fraco desempenho das FPTs “de solos temperados”, quando aplicadas aos solos de regiões tropicais, normalmente mais intemperizados. Tomasella e Hodnett (1998) observaram que, no caso dos oxisolos, o conteúdo de argila excede freqüentemente 60%, quando FPTs desenvolvidas para solos temperados não cobrem essa magnitude. Oliveira et al. (2002) alertam que o uso de FPTs só deve ser implementado após calibrações locais. Os autores afirmam que as FPTs tendem a ter melhor desempenho em sua aplicação quanto mais homogêneo forem os solos usados para calibração e os solos que terão os dados estimados.

Tomasella et al. (2000) comentam sobre as diferenças no teor de silte entre os solos usados na FPT de Tietje e Tapkenhinrichs (1993) e os solos brasileiros. Os autores citam que no banco de dados utilizados para desenvolvimento da FPT, o teor de silte no solo variou entre 15 e 20% e raramente foi superior a 50%, afirmando que geralmente nos solos brasileiros o teor de silte é baixo em relação aos solos de regiões temperadas. Esta diferença foi atribuída pelos autores como a causa do baixo desempenho das FPTs de Saxton et al. (1986) e Vereecken et al. (1989) testadas no banco de dados de solos brasileiros. Tomasella e Hodnett (1998) afirmam que em regiões tropicais úmidas somente solos hidromórficos podem apresentar teor de silte maior do que 40%.

Com relação ao desenvolvimento de novas FPTs, Minasny et al. (2003) esclarecem que é uma tarefa árdua, porque requer uma ampla base de dados de solos contendo muitos dados morfológicos e determinações de laboratório. Aconselham que, em primeira instância, se faça uso de FPTs já desenvolvidas, mas ponderam que a validade de uma determinada FPT não deve ser interpolada ou

extrapolada além do ambiente pedológico ou tipo de solo em que foi desenvolvida, e que, a aplicação direta de uma FPT em solos com propriedades distintas só deve ser feita após testar seu desempenho, de forma que FPTs mais adequadas possam ser identificadas.

Conforme já destacaram Rawls et al. (1991), que apresentaram uma revisão sobre funções de pedotransferência, as pesquisas que relacionam as propriedades físicas dos solos com a retenção de água são limitadas pelas próprias propriedades incluídas na base de dados. Assim, as bases de dados dos solos deveriam ser expandidas para incluírem análise detalhada do tamanho das partículas (entre cinco a nove classes), argila mineralógica, matéria orgânica, densidade global; informações morfológicas tais como estrutura, horizonte e consistência; propriedades químicas e distribuição de tamanho dos poros.

Grande maioria das FPTs, hoje existentes, são geradas por simples uso de equações lineares de regressão múltipla (GUPTA e LARSON, 1979; RAWLS et al., 1982; VEREECKEN et al., 1989; VEREECKEN et al., 1990).

FPTs também podem ser construídas por redes neurais artificiais. Estudos de Pachepsky et al. (1996), Schaap e Bouten (1996), Schaap et al. (1998), e Tamari et al. (1996) mostraram que os resultados obtidos por FPTs geradas por redes neurais, são frequentemente melhores do que aquelas obtidas pelos métodos tradicionais. De acordo com Haykin (1994) redes neurais são por vezes descritos como funções aproximadoras universais, uma vez que pode "aprender" à aproximar qualquer função não-linear contínua.

2.1.3.2.1.1 Regressão Linear Múltipla

A regressão linear múltipla (*Multiple Linear Regression–MLR*) foi introduzida por Stenberg et al. (1960). Essa técnica busca estabelecer uma relação linear entre as variáveis preditoras e preditas aplicando o método dos mínimos quadrados. Para isso, faz uso tanto na calibração clássica como na calibração inversa. O modelo *MLR* pode ser obtido a partir de uma matriz X de respostas instrumentais com dimensão $(m \times k)$, onde m representa o número de amostras e k o número de variáveis (no caso de espectros $k =$ comprimentos de onda). Além disso, utiliza os

dados de um vetor y de dimensão $(m \times 1)$ que contém as concentrações (ou outra propriedade) obtidas por um método de referência das amostras (NUNES, 2008).

A seleção de comprimentos de onda de um espectro que resulte em modelos de calibração multivariada com máxima precisão é ainda uma tarefa desafiadora (CANECA et al., 2006). Diversos métodos têm sido propostos para essa finalidade entre os quais é descrito, a seguir, o mais utilizado no contexto de geração de FPTs.

O método de regressão *stepwise* é um procedimento padrão para seleção de variáveis que combina dois outros métodos, o *forward selection* e *backward elimination* (MONTGOMERY et al. apud CHONG e JUN, 2005). O algoritmo, progressivamente, adiciona novas variáveis ao modelo, iniciando daquela com maior correlação com a resposta, como no método *forward selection* e incorpora um mecanismo de eliminação de variáveis igual ao método de *backward elimination*. O *forward selection* é um método iterativo que começa com uma variável (x) e, progressivamente, adiciona mais variáveis ao modelo de regressão até que um critério de parada seja satisfeito. A variável inicial deve apresentar máxima correlação com a variável de resposta (y). A cada iteração, é construído um novo modelo e o efeito da variável incluída é avaliado por um teste-F. A variável com um valor de F maior que um F-crítico é incluída no modelo. No método *backward elimination*, inicia-se com a construção de um modelo de regressão com todas as variáveis disponíveis e, subseqüentemente, variáveis são retiradas e o efeito dessa eliminação é avaliado, da mesma forma que no método *forward selection*. As variáveis com valores de F menores que F-crítico são descartadas do modelo (NUNES, 2008).

2.1.3.2.1.2 Redes Neurais Artificiais

Métodos rápidos e de baixo custo para obtenção da curva característica de água no solo, são de fundamental importância na avaliação das propriedades hídricas do mesmo. A formulação de um modelo matemático, para a predição da umidade do solo em diferentes potenciais matriciais, é difícil e limitado devido à complexidade e a não linearidade nos dados dos parâmetros relacionados (teor de argila, teor de silte, teor de areia, matéria orgânica, densidade do solo e densidade

de partícula). Vários autores indicam a utilização de redes neurais artificiais quando se trata de sistemas complexos como nos casos de pesquisas do solo (YOUNG et al., 2001; ATTOH-OKINE e FEKPE, 1996; LEVINE et al., 1996).

Na literatura (AZEVEDO et al., 2000; BARRETO, 1997; BRAGA et al., 2000; FISCHER et al., 2001; HAYKIN, 2001; MEDEIROS, 2003; OSÓRIO e BITTENCOURT, 2000; NEURAI, 2011; NIEVOLA, 2004; SARLE, 2004; ZELL et al., 1998), várias são as definições que os autores atribuem às Redes Neurais Artificiais (RNAs) ou, simplesmente, Redes Neurais (RNs), ou ainda métodos conexionistas. Todos os autores citados concordam que as RNAs consistem em uma metodologia para solucionar problemas de inteligência artificial (IA), a partir de um sistema que possui circuitos que simulam o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência.

A habilidade das RNAs em solucionar problemas complexos e variados tem as tornado uma abordagem interessante que pode ser aplicada em diversas áreas de engenharia e ciências (SILVA et al., 2001). Os trabalhos têm sido motivados desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma diferente do computador digital convencional. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos (reconhecimento de padrões, percepção, e controle motor) mais rapidamente que o mais rápido computador digital hoje existente (HAYKIN, 2001).

Devido a capacidade das RNAs de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam, essas são empregadas em uma gama muito variada de estudos, dentre eles, os que predizem fenômenos de transporte em solos (PACHEPSKY e TIMLIN, 1994), retenção de água em potenciais específicos (PACHEPSKY et al., 1996; PACHEPSKY et al., 1997; NETTO, 2007; JANA et al., 2007; JANA e MOHANTY, 2011), planejamento de transportes rodoviários (BOCANEGRA, 2002), modelos de parâmetros hidráulicos e otimizar FPTs para ajustar conteúdos de água estimados e medidos (MINASNY e McBRATNEY, 2002), previsão de defeitos em estradas vicinais (NUNES, 2003), mineração de dados e diagnóstico ambiental (PEREIRA, 2005), previsão de

incidência de dengue (STRINI, 2006), estudo de relações entre propriedades do solo (TIMM et al., 2006), estimativa de produtividade agrícola (PICOLI, 2006; WEBER, 2005).

Conforme Young et al. (2001), as vantagens da utilização das redes neurais artificiais em relação aos modelos convencionais deve-se, principalmente, a não requererem informações prévias relativas à natureza do conjunto de dados e a facilidade para instruir uma rede.

Nas seções a seguir estão descritos os principais fundamentos das RNAs, no que se refere ao neurônio artificial, o mecanismo de funcionamento e a forma de representar geometricamente uma RNA.

2.1.3.2.1.2.1 Histórico

As pesquisas sobre redes neurais artificiais são relativamente recentes, o primeiro modelo artificial de um neurônio biológico foi fruto do trabalho de McCulloch e Pitts em 1943. Contudo, esse trabalho se concentrou mais em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais do que em apresentar técnicas de aprendizado (BRAGA et al., 2000).

Em 1949, Donald Hebb propôs uma regra de aprendizagem para redes neurais (hoje conhecida como regra de Hebb) mostrando que a aprendizagem de redes neurais é conseguida através de variação de pesos sinápticos dos nós de entradas (HAYKIN, 2001).

O modelo mais simples de rede neural, conhecido como *perceptron*, foi apresentado por Frank Rosenblatt em 1958, no qual várias unidades de processamento estão conectadas unicamente a uma unidade de saída através dos pesos sinápticos (GALVÃO e VALENÇA, 1999).

Em 1960, Widrow e Hoff introduziram o algoritmo de treinamento baseado nos mínimos quadrados (conhecido como Regra Delta) e usaram a rede ADALINE (ADaptive LINear Element) para treinar. A diferença entre o *Perceptron* e o ADALINE está no procedimento de aprendizagem. Mais tarde, Widrow e seus estudantes introduziram a generalização multidimensional, o MADALINE (Multiple ADALINE) (HAYKIN, 2001).

A rede *perceptron* foi recebida na época com grande entusiasmo devido à sua simplicidade, mas infelizmente tanto a rede de Rosenblatt como a de Widrow têm suas limitações. Em 1969 Minsk e Papert provaram matematicamente que o *perceptron* não pode ser usado no mapeamento de funções lógicas complexas. O *perceptron* resolve somente problemas linearmente separáveis, isto é, problemas cujas soluções podem ser obtidas dividindo-se o espaço de entrada em duas regiões através de uma reta. Muitos pesquisadores foram influenciados por Minsk e Papert, e também pelo fato de não existir máquinas potentes na época, as pesquisas na área de redes neurais ficaram paralisadas durante a década de 70 (BRAGA et al., 2000; FUKUDA e SHIBATA, 1992; HAGAN et al., 1996). Embora, poucos pesquisadores continuassem trabalhando na área durante a década de 70, os mesmos apresentaram contribuições significativas.

Nos anos 80, muitos pesquisadores passaram a publicar diversas propostas para a exploração de desenvolvimento de redes neurais, bem como suas aplicações. Esta retomada de interesse em redes neurais artificiais foi, por vários fatores e entre as quais, ressaltam-se melhores conhecimentos da estrutura real do cérebro, disponibilidade de computadores com maior capacidade de cálculo e, sobretudo, o desenvolvimento de novos algoritmos de aprendizado (SILVA, 1997).

Vários artigos foram publicados na década de 80, mas os mais influentes para o ressurgimento da área foi o artigo de John Hopfield em 1982, com a modelagem de redes neurais com realimentação, e o desenvolvimento do algoritmo de aprendizado *backpropagation* para redes neurais de múltiplas camadas (HAYKIN, 2001).

Em 1986, com a descrição do algoritmo de treinamento *backpropagation*, Rumelhart e colaboradores demonstraram que as RNAs *Perceptron* de Múltiplas Camadas (*MLP*) são capazes de resolver “problemas difíceis de aprender”. RNAs com duas camadas intermediárias podem implementar qualquer função, seja ela linearmente separável ou não (BRAGA et al., 2000).

As redes neurais de múltiplas camadas com algoritmo *backpropagation* são capazes de resolver problemas complexos, superando as críticas de Minsk e Papert (HAYKIN, 2001). A partir deste novo algoritmo, várias aplicações vêm sendo feitas através de mapeamento de redes neurais em diversas áreas, inclusive na área agrícola.

2.1.3.2.1.2.2 O neurônio artificial e a rede neural

Considerando que o sistema nervoso é composto por bilhões de células nervosas, a ideia é que a RNA também seja constituída por unidades de processamento que simulem o funcionamento de um neurônio biológico. Estes módulos devem estar interconectados e funcionar de acordo com os elementos em que foram inspirados, recebendo, retransmitindo informações e gerando conhecimento.

Em 1911, Ramon y Cajal introduziu a ideia de neurônios como estrutura básica do cérebro, cujo funcionamento pode ser resumido basicamente do seguinte modo: os dendritos recebem sinais de entrada oriundos de outras células, o elemento soma e os próprios dendritos integram e processam estes sinais, a informação é transmitida ao longo do axônio para outros neurônios por meio das sinapses, que são as ligações entre os dendritos de neurônios diferentes (HAYKIN, 1999).

Na Figura 1 é apresentado o modelo do neurônio proposto por McCulloch e Pitts (MCCULLOCH e PITTS, 1943). O neurônio possui i entradas (equivalente aos dendritos) X_1, X_2, \dots, X_i e apenas uma saída (equivalente ao axônio) y . Para simular a sinapse, cada entrada do neurônio tem um peso W_1, W_2, \dots, W_i cujos valores podem ser positivos (excitatórios) ou negativos (inibitórios). Os pesos têm como finalidade armazenar o conhecimento e determinar a intensidade com que cada entrada contribuirá no resultado do neurônio. O corpo celular é emulado simplesmente somando os valores do produto de suas entradas com seus respectivos pesos, $X_i W_i$ e, se a soma for maior ou igual ao seu limiar (*threshold*) a sua saída, y , é ativada com valor 1. Resumindo o neurônio será ativo quando:

$$\sum_{i=1}^m X_i W_i \geq \Theta \quad (1)$$

onde m é o número de entradas do neurônio, W_i é o peso associado à entrada X_i e Θ é o limiar do neurônio, conforme ilustrado na Figura 1.




Figura 1 - Modelo matemático de um neurônio biológico

Fonte: Adaptado de Braga et al.(2000).

No decorrer dos anos seguintes, vários pesquisadores propuseram variações do modelo do neurônio McCulloch e Pitts. A principal diferença entre a ideia original e suas variações encontra-se na função que determina o estado de ativação da saída do neurônio (função ativação) e o acréscimo de um bias. Bias corresponde a um neurônio ou a uma entrada especial que serve para aumentar os graus de liberdade, permitindo uma melhor adaptação por parte da rede neural, ao conhecimento a ela fornecido, pode ser considerado como um ajuste fino.

Haykin (2001) descreve o modelo de neurônio, que identifica a base para projetos de RNAs, sendo composto por três elementos básicos (Figura 2).

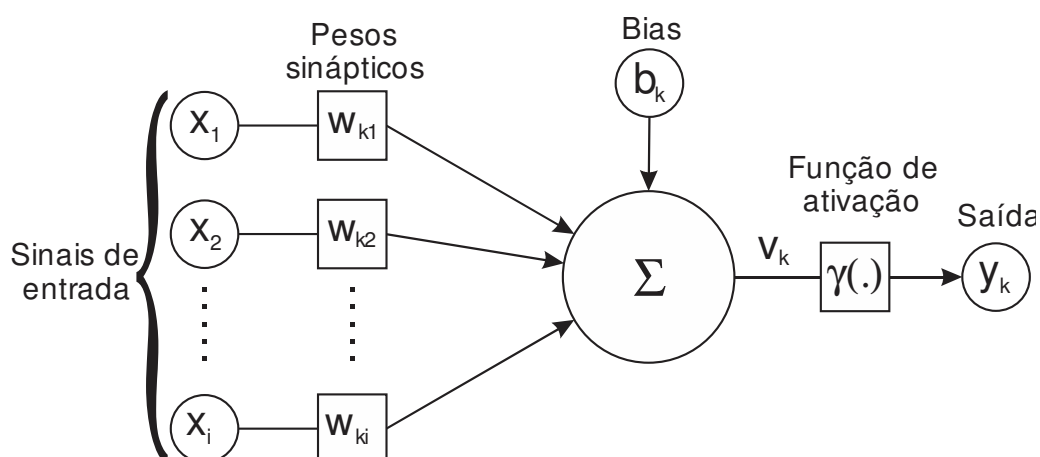


Figura 2 – Modelo de neurônio base para projetos de RNAs

Fonte: Adaptado de Haykin (2001).

- Conjunto de sinapses ou elos de conexão: cada uma se caracteriza por seu peso ou força própria. Um sinal x_i na entrada da sinapse i conectado a um neurônio k é multiplicado pelo peso sináptico w_{ki} , onde o índice k refere-se ao neurônio em questão e o índice i refere-se ao terminal de entrada da sinapse.
- Junção aditiva: somador dos sinais de entrada, ponderados pelos respectivos pesos sinápticos. Estas funções constituem um combinador linear.
- Função de ativação: tem por finalidade restringir a amplitude de saída de um neurônio, pode ser também referenciada como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou $[-1,1]$.

Neste modelo, pode ser notado o acréscimo de um bias, que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente,

Uma função de ativação receberá o resultado do somatório do produto de cada entrada por cada peso e responderá com um único valor, usado como entrada para o próximo neurônio ou como resposta da rede neural.

A escolha da função de ativação deve ser feita de acordo com o problema a ser tratado pela rede neural. Conforme Silva (1997) e Braga et al. (2000), as funções de ativação mais comuns são: a função linear, função rampa, função degrau (step) e função sigmoidal.

2.1.3.2.1.2.3 Arquitetura da rede neural artificial

Braga et al. (2000) destaca que a definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Redes com uma camada única de neurônios, por exemplo, só conseguem resolver problemas linearmente separáveis. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal.

O autor coloca que os parâmetros que definem a arquitetura de uma rede são: (i) número de camadas da rede, (ii) número de neurônios em cada camada, (iii)

tipo de conexão entre os neurônios e (iv) topologia da rede. Em geral, identificam-se classes de arquiteturas fundamentalmente diferentes (HAYKIN, 2001; BRAGA et al., 2000), a seguir explicitadas (Figura 3).

Quanto ao número de camadas, pode-se ter:

- Redes de camada única: só existe uma camada de neurônio entre qualquer entrada e qualquer saída da rede (Figura 3 a, e);
- Redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 3 b, c, d).

Os neurônios podem ter conexões do tipo:

- *Feedforward*, ou acíclica: a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de neurônios em camadas de índice menor ou igual a i (Figura 3 a, b, c);
- *Feedback*, ou cíclica: a saída de algum neurônio na i -ésima camada da rede é usada como entrada de neurônios em camadas de índice menor ou igual a i (Figura 3 d, e).

Redes cuja saída final (única) é ligada às entradas comportam-se como autômatos reconhedores de cadeias, onde a saída que é realimentada fornece o estado do autômato (Figura 3 d).

Se todas as ligações são cíclicas, a rede é denominada auto-associativa. Estas redes associam um padrão de entrada com ele mesmo, e são particularmente úteis para recuperação ou "regeneração" de um padrão de entrada (Figura 3 e).

Finalmente, as RNAs podem também ser classificadas quanto à sua conectividade:

- Rede fracamente (ou parcialmente) conectada (Figura 3 b, c, d):
- Rede completamente conectada (Figura 3 a, e).

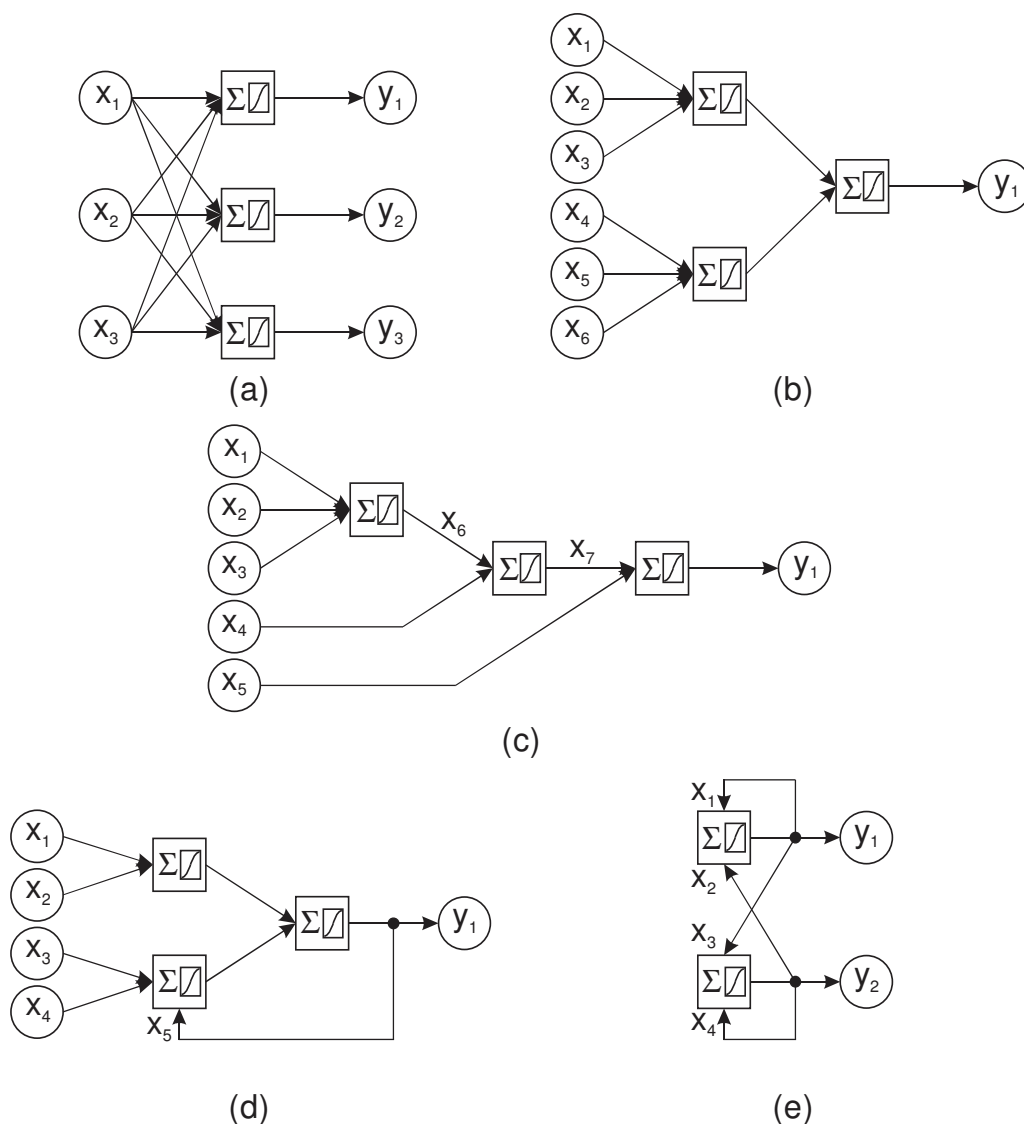


Figura 3 – Exemplos de arquiteturas de RNAs

Fonte: Adaptado de Braga et al. (2000).

A solução de problemas através de RNAs é bastante atrativa, já que a forma como estes são representados internamente pela rede, e o paralelismo natural inerente à arquitetura das RNAs criam a possibilidade de um desempenho superior ao dos modelos convencionais. Em RNAs, o procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem, em que um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida.

2.1.3.2.1.2.4 Treinamento das redes neurais artificiais

A utilização de uma rede neural artificial na solução de uma tarefa inicia-se por uma fase de aprendizagem, que é quando a rede extrai informações relevantes de padrões de informação apresentados a ela e, cria uma representação própria para o problema (BRAGA et al., 2000). A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

A aprendizagem em RNAs foi definida (MENDEL e MCLAREN, 1972 apud BRAGA et al., 2000) como um processo pelo qual os parâmetros livres de uma rede neural, são adaptados por meio de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

As redes neurais artificiais são capazes de extrair informações não-apresentadas de forma explícita através dos exemplos. Não obstante, as RNAs são capazes de atuar como mapeadores universais de funções multivariáveis, com custo computacional que cresce apenas linearmente com o número de variáveis. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que, aliada àquelas citadas anteriormente, faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

Rohn e Mine (2003) destacaram que, para o aprendizado não é necessário um conhecimento detalhado sobre as relações entre as variáveis envolvidas no problema, contudo, as redes necessitam de uma quantidade considerável de dados históricos para que consigam extrair satisfatoriamente as características relevantes, existentes no conjunto de dados. Se treinada corretamente, a rede é capaz não somente de aproximar qualquer função, mas também de generalizar (validar), proporcionando saídas corretas para entradas não apresentadas anteriormente.

Generalização é a capacidade de um modelo de aprendizado responder corretamente aos exemplos que lhe são apresentados, sendo que, estes exemplos não devem estar presentes na base de aprendizado. Ou seja, um modelo que tem uma boa generalização é aquele modelo que responde corretamente aos exemplos

contidos na base de aprendizado, mas, também a outros exemplos diferentes daqueles da base de aprendizado, e que estão contidos em uma base de teste (BRAGA et al., 2000; HAYKIN, 2001; WASSERMAN, 1989; REFENES, 1993; LECUN, 1989).

Estes autores relatam que a capacidade de generalizar é a principal característica buscada nas tarefas que envolvem aprendizado. Contudo, na tentativa de generalizar, uma RNA pode se especializar demasiadamente em relação aos exemplos contidos na base de aprendizado. Este tipo de comportamento gera um problema de aprendizado conhecido como super-aprendizado (*over-training/over-fitting*), que pode ocorrer quando na arquitetura da RNA o número de camadas e/ou neurônios for muito grande. Outra situação, é a rede não conseguir generalizar, gerando o problema chamado de sub-ajuste (*under-fitting*), o qual pode ocorrer quando o número de camadas e/ou neurônios for muito pequeno.

Braga et al. (2000) destaca que diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não-supervisionado. Outros dois paradigmas bastante conhecidos são os de aprendizado por reforço (que é um caso particular de aprendizado supervisionado) e aprendizado por competição (que é um caso particular de aprendizado não-supervisionado).

Segundo Braga et al. (2000), o método de aprendizado supervisionado é o mais comum no treinamento das RNAs, tanto de neurônios com pesos como de neurônios sem pesos. É chamado de aprendizado supervisionado porque a entrada e saída desejadas para a rede são fornecidas por um supervisor (professor) externo, ou seja, neste aprendizado são apresentados à rede um par de vetores de entrada e de saída desejada. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. O professor indica explicitamente um comportamento bom ou ruim para a rede, visando a direcionar o processo de treinamento. A rede tem sua saída corrente (calculada) comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual.

O autor registra ainda que a cada padrão de entrada submetido à rede compara-se a resposta desejada (que representa uma ação ótima para ser realizada pela rede) com a resposta calculada, ajustando-se os pesos as conexões para minimizar o erro. A minimização da diferença é incremental, já que pequenos ajustes

são feitos nos pesos a cada etapa de treinamento, de tal forma que estes caminhem - se houver solução possível - para uma solução. A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento. O processo de treinamento é repetido para cada padrão de dados, até alcançar um valor de erro pré-fixado ou atingir um determinado número de iterações.

A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta (WIDROW e HOFF, 1960) e a sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* (RUMELHART, et al., 1986).

No aprendizado não supervisionado, não é apresentado à rede o vetor de saída desejada. Para estes algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características intrínsecas da entrada e, deste modo, criar novas classes ou grupos automaticamente. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada (HAYKIN, 2001; BRAGA et al., 2000).

2.1.3.2.1.2.5 Modelos de aprendizagem

Os modelos de aprendizagem estão relacionados ao ajuste dos pesos e podem ser implementados por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. As regras de aprendizado mais usadas são (RIBEIRO, 2003; OSÓRIO e BITTENCOURT, 2000):

- Aprendizagem por Correção de Erro – a rede é estimulada por um vetor de entrada e sua saída desejada. A regra de ajuste consiste em achar o erro subtraindo

a resposta desejada com a resposta da rede, calculando o gradiente descendente da função do erro.

- Aprendizagem Baseada em Memória – usa-se arquitetura de redes alimentadas com camada única de modo supervisionado. A maioria das amostras de treino é armazenada em uma grande memória de exemplos de entrada-saída. Um exemplo simples de aprendizagem baseada em memória é a regra do vizinho mais próximo, onde a rede classifica de acordo com a distância euclidiana entre os vetores de treino.
- Aprendizagem competitiva – na camada de saída da rede, após receber as características dos objetos na camada de entrada, os neurônios competem entre si, e o neurônio que tiver o maior valor discriminante, se torna vencedor.

As regras de aprendizagem se constituem como elementos básicos para o projeto de redes neurais artificiais.

2.1.3.2.1.2.6 Redes do tipo *Perceptron* de Múltiplas Camadas

As redes neurais de uma camada têm suas limitações, pois elas são capazes de solucionar apenas problemas que são linearmente separáveis (NAGAOKA, 2003; BRAGA et al., 2000).

Com o desenvolvimento do algoritmo de treinamento (*backpropagation*) foi possível treinar redes com camadas intermediárias, sendo atualmente a rede *perceptron* multicamadas uma das mais utilizadas em problemas de identificação de sistemas.

As arquiteturas do tipo *Perceptron* de Múltiplas Camadas ou *Multi Layer Perceptron (MLP)* são os modelos neurais artificiais mais utilizados e conhecidos. Esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (chamadas escondidas ou ocultas) e uma camada de saída (Figura 4). Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Esta arquitetura representa uma topologia de rede do tipo *feedforward*, ou seja, são redes cujos sinais se propagam sempre da camada de entrada para a

camada de saída da rede, passando por eventuais camadas intermediárias (GONÇALVES, 1997; CASTRO, 1998; HAYKIN, 1999; GALO, 2000).

As camadas intermediárias funcionam como extratoras de características, seus pesos são codificações das informações apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e detalhada, do problema (SILVA, 1997).

Cibenko (1989 apud SILVA, 1997) provou a partir de extensões do teorema de *Kolmogorov*, que são necessárias no máximo duas camadas intermediárias, com um número suficiente de neurônios por camada, para se produzir quaisquer mapeamentos. Foi provado também que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua.

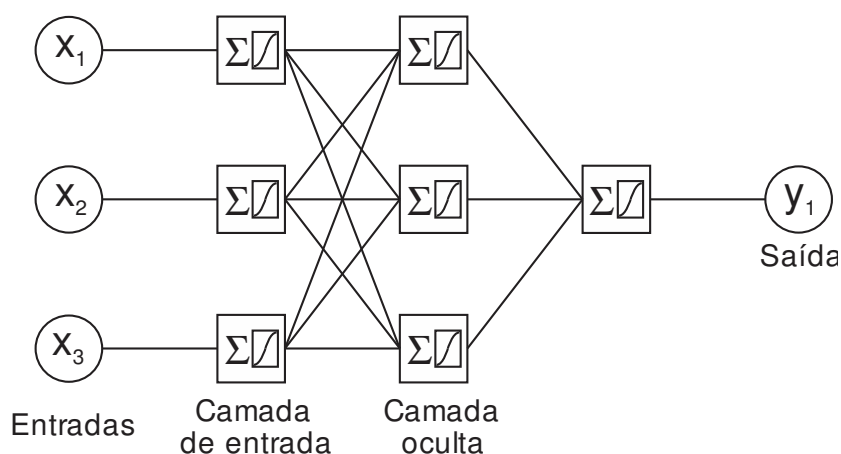


Figura 4 - Estrutura topológica da rede neural *MLP*

Fonte: Adaptado de Braga et al. (2000).

As redes do tipo *MLP* são muito utilizadas para a solução de problemas envolvendo alto grau de não-linearidade. Seu treinamento é do tipo supervisionado e, usualmente, utiliza um algoritmo chamado retro-propagação do erro (*error-backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que corrige o erro durante o treinamento (HAYKIN, 1999).

Existem atualmente vários algoritmos para treinar redes *MLP* (RUMELHART e MCCLELL, 1986; FAHLMAN, 1988; RIEDMILLER, 1994; PEARLMUTTER, 1992; BARLETTA, 1991; HAGAN e MENHAJ, 1994). Estes algoritmos são geralmente do

tipo supervisionado. De acordo com os parâmetros que eles utilizam, os algoritmos para treinamento de redes do tipo *MLP* podem ser classificados em: (i) estáticos e (ii) dinâmicos (BRAGA, et al., 2000).

Enquanto os algoritmos estáticos não alteram a estrutura da rede, variando apenas os valores de seus pesos, os algoritmos dinâmicos podem tanto reduzir quanto aumentar o tamanho da rede (número de camadas, número de neurônios nas camadas intermediárias e número de conexões). Quando o aprendizado estático é utilizado, a mesma regra de aprendizado é empregada para redes do tipo *MLP* com diferentes tamanhos e formatos. É interessante observar que topologias diferentes podem resolver o mesmo problema.

O algoritmo de aprendizado mais conhecido para treinamento destas redes é o algoritmo *backpropagation* (RUMELHART e MCCLELL, 1986). A maioria dos métodos de aprendizado para RNAs do tipo *MLP* utiliza variações deste algoritmo. O algoritmo *backpropagation* foi um dos principais responsáveis pelo ressurgimento do interesse em RNAs, por ocasião da publicação, em 1986 (RUMELHART e MCCLELL, 1986), de *Parallel Distributed Processing*, mais conhecido por PDP. Embora a popularização deste algoritmo tenha surgido a partir de 1986, ele foi proposto muito antes, com diferentes propósitos, por diferentes pesquisadores, como Bryson e Ho (1969), Werbos (1974), Parker (1985) e Lecun (1985).

O algoritmo *backpropagation* é um algoritmo supervisionado que utiliza pares (entrada e saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de fase *forward* (passo para frente) e fase *backward* (passo para trás).

No passo para frente, a entrada é apresentada à primeira camada. Para cada camada calcula-se a saída, e esta saída será utilizada como entrada da camada seguinte, e assim sucessivamente, até chegar à última camada, onde terão as saídas da rede comparadas com as saídas desejadas.

No passo para trás, na camada de saída, calcula-se o erro entre a saída desejada e a saída da rede, este erro é propagado para trás e os pesos são ajustados de forma a reduzir seus erros (BRAGA et al., 2000; HAYKIN, 2001). Na Figura 5 pode-se observar as fases de treinamento.

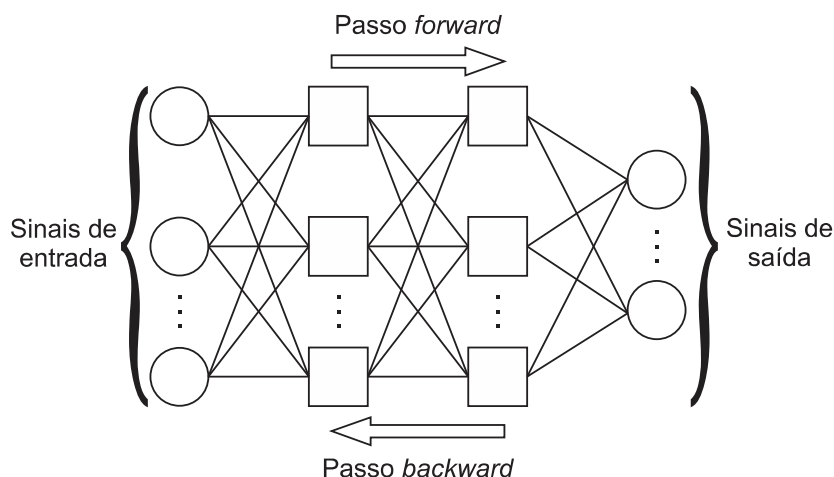


Figura 5 - Fluxo do algoritmo *backpropagation*

Fonte: Adaptado de Braga et al. (2000).

2.1.3.2.1.2.7 Aplicações de redes neurais na área agrícola

As aplicações de redes neurais artificiais na área agrícola ainda são recentes, tendo poucos trabalhos publicados, principalmente quando se tratam de pesquisas em solos agrícolas (NAGAOKA, 2003). A seguir serão elencadas algumas das principais pesquisas, realizadas na área agrícola.

Conforme Najjar et al. (1995), na literatura existem vários modelos com equações de regressão, desenvolvidos para relacionar umidade ótima e densidade máxima aparente no estudo da compactação do solo, tendo quase todos os modelos, coeficientes de determinação R^2 acima de 0,75. Os referidos autores treinaram redes neurais *feedforward* de múltiplas camadas com algoritmo *backpropagation* para determinar os parâmetros umidade ótima e densidade aparente máxima. As redes foram treinadas fazendo-se diferentes combinações de variáveis de entradas de 1 a 11 variáveis em dois tipos solos (sintético e natural). Os resultados obtidos pelas redes quando comparados com os resultados fornecidos por análise de regressão, encontrados na literatura, apresentaram bons resultados para ambos os solos, com ajustes superiores ao método padrão (regressão linear).

Batchelor et al. (1996) treinaram redes neurais artificiais com algoritmo *backpropagation* de três camadas (entrada, intermediária e saída) para prever a porcentagem de doença na soja, mais especificamente a ferrugem de soja

(*Phakospsora pachyrihizi*). As redes foram treinadas variando o número de neurônios na camada intermediária de 10 a 48. Para a validação, do total desses 577 dados, foi dividido em 70% para treinamento, 15% para teste e 15% para validação. Os resultados obtidos tanto na avaliação como na validação foram excelentes, sendo escolhida a arquitetura de 32 neurônios na camada intermediária, tanto na avaliação como no teste, tendo como erro médio de 2,4% com máximo de 15,7%. Esse trabalho teve excelente contribuição, pois a técnica tradicional utilizada é baseada no modelo matemático, o que torna limitado, pois deve-se desenvolver matematicamente cada processo biológico do sistema, e qualquer limitação na informação, é introduzido erro na predição. Os autores afirmam que a técnica de redes neurais é muito eficaz na aprendizagem de informações biológicas complexas, fornecendo bons resultados.

Levine et al. (1996) treinaram redes neurais artificiais *feedforward* com algoritmo *backpropagation* para definir as variáveis de entrada e classificar três tipos de estruturas de solo (granular, bloco e maciço). Assim, várias redes foram treinadas para definir o conjunto de variáveis de entrada importantes na classificação da estrutura do solo. Foram testadas combinações de 12 variáveis de entradas com redes de uma camada intermediária. A arquitetura escolhida nesse trabalho foi a rede com três variáveis de entrada, dois neurônios na camada intermediária e três neurônios na camada de saída. A precisão na referida rede foi da ordem de 79%.

Parmar et al. (1997) treinaram redes neurais multicamadas com algoritmo *backpropagation* para estimar o nível de aflatoxina, e também determinar as variáveis que afetam o processo de contaminação na pré-colheita de amendoim. Os referidos autores treinaram redes empregando diversos valores de números de neurônios na camada intermediária e fazendo combinações de 1 a 4 variáveis de entradas. Modelos de regressão linear foram desenvolvidos para cada combinação de variáveis de entradas e comparados com os resultados obtidos pelas redes. A rede que obteve melhor resultado para o nível de aflatoxina foi a de 4 variáveis de entrada e 8 neurônios na camada intermediária. Para o modelo de análise de regressão, foi também o de 4 variáveis, sendo as mesmas utilizadas pela rede. Os resultados obtidos pelas redes foram mais precisos do que os obtidos pela regressão linear.

Yang et al. (1998) pesquisaram aplicações de redes neurais artificiais com algoritmo de aprendizado *backpropagation*, para imitar o convencional modelo

matemático DRAINMOD na simulação da quantidade de água em função da profundidade. Como a quantidade de água em função da profundidade, em um dado dia, é dependente das condições dos dias anteriores, foram treinadas 3 redes neurais com atraso de tempo. A rede-1 com nenhum dia de atraso (os dados de entrada não dependem dos dias anteriores), a rede-2 com três dias de atraso (os dados de entrada dependem dos dados de um período de três dias anteriores) e a rede-3 com cinco dias de atraso (os dados dependem de um período de cinco dias anteriores). Os resultados obtidos foram comparados com o método tradicional DRAINMOD, tendo resultados muito próximos.

O conhecimento do volume de água no solo é requerido por muitas aplicações na agricultura, recursos naturais e engenharia. Assim, Altendorf et al. (1999) utilizaram redes neurais na previsão da quantidade de água no solo e compararam à técnicas de regressão. Um conjunto de redes neurais foi desenvolvido para prever a umidade de determinados tipos de solos, numa dada profundidade, associadas à temperatura do solo. As redes foram geralmente capazes de prever as variações no teor de água ao longo do tempo. Para fins de comparação, vários modelos de regressão linear também foram utilizados para estimar a umidade do solo em diferentes profundidades. Eles, porém, não apresentaram bom desempenho, particularmente em seguir as tendências nos dados ao longo do tempo.

Ulson et al. (2001) estudaram um sistema baseado em redes neurais artificiais do tipo *perceptron* multicamadas para a identificação da taxa de aplicação de fertilizante fluido a taxas variáveis. O treinamento da rede foi realizado através do algoritmo de *Levenberg-Marquardt* (algoritmo *backpropagation* otimizado) com dados experimentais. O resultado obtido pela rede neural de arquitetura formada por 5 entradas, 1 camada escondida com 10 neurônios e uma saída foi de 0,00028 de erro médio quadrático e 1,7736 % de erro médio relativo (validação cruzada). Os autores concluíram que o método proposto no estudo forneceu uma abordagem alternativa e eficiente aos modelos de controle convencionais para aplicação de fertilizante fluido a taxas variáveis ao longo do campo.

Silva (2002) em uma investigação acerca da aplicabilidade das redes neurais, na previsão da evapotranspiração de referência, observou que as redes neurais como modelo de reconhecimento de padrão teriam a capacidade de entender o comportamento do clima local, podendo, a partir dos dados climáticos do passado

próximo, inferir sobre seu comportamento futuro. O autor observou em seus resultados, que as melhores predições obtidas promoveram um erro padrão de estimativa de 0,8mm e um erro percentual relativo médio de 20% para valores da evapotranspiração.

Silva et al. (2004), propuseram em seu trabalho investigar o uso de RNAs como ferramenta de suporte para a determinação das necessidades de adubação da cultura da goiabeira utilizando agricultura de precisão. Os mesmos observaram que o uso de redes *MLP* treinadas com o algoritmo *backpropagation* mostrou seu grande potencial para a recomendação de adubação correta de fósforo para a cultura da goiabeira, levando-se em consideração princípios da agricultura de precisão.

Machado (2005), modelando a relação entre chuva e vazão através da técnica de RNA, avaliou a capacidade das mesmas, modelarem o processo chuva-vazão em base mensal. Para o autor a utilização desta técnica, foi justificável uma vez que a relação entre chuva e vazão é altamente não linear, e as RNA são ditas aproximadores universais de funções não lineares. Foram considerados durante o treinamento das RNA as influências da arquitetura da rede, do número de *epochs* (épocas), da inicialização dos pesos e da extensão das séries de dados. Foi desenvolvido um algoritmo computacional que ao final do processo de treinamento gerou 1296 resultados. Os resultados das três melhores RNAs foram confrontados com os resultados calculados pelo modelo conceitual IPHMEN e, em todas as ocasiões, as RNA apresentaram um melhor desempenho, os coeficientes de correlação alcançados foram maiores e os erros menores.

Mathias (2006) apresenta o desenvolvimento de um sistema computacional denominado PMNeural, baseado em RNAs. A finalidade do sistema foi reconhecer padrões de comportamento de variáveis meteorológicas em relação ao molhamento foliar por orvalho. O autor conclui que o sistema foi eficiente, uma vez que apresentou grau de exatidão entre 73,96% a 96,40%, para reconhecer padrões em dados de variáveis meteorológicas visando estimar o molhamento foliar originado por orvalho, em estudos de caso com bases de dados obtidas em áreas onde a cultura alvo foi o trigo.

Netto (2007) em seu trabalho desenvolveu FPTs que estimasse a partir de análise em RNAs a retenção de água nos solos da microbacia hidrográfica do Ribeirão Canchim, município de São Carlos, SP. Os atributos físicos, textura (argila, silte e areia), densidade e resistência à penetração dos solos, manejados com e sem

cobertura vegetal e sob mata, foram utilizados como variáveis de entrada nas duas redes neurais artificiais. Foram obtidas, ainda, as curvas de retenção de água no solo por meio da câmara de pressão de Richards e da tomografia computadorizada, além da porosidade total e da condutividade hidráulica não saturada. As RNAs foram eficientes no desenvolvimento de FPTs, capazes de estimar a retenção de água com base em propriedades básicas de solo obtidas em grande número.

3 MATERIAL E MÉTODOS

Para desenvolver o presente trabalho foram utilizados dados disponíveis na literatura, que apresentassem valores das características físico-hídricas e químicas de solos do Rio Grande do Sul (RS), visando desenvolver funções de pedotransferência (FPTs), para estimar valores de unidade de solo, sob diferentes tensões.

O Estado do Rio Grande do Sul caracteriza-se por uma heterogeneidade muito grande de tipos de solos, tendo em vista a grande diversidade dos fatores responsáveis pela formação desses solos. Segundo Streck et al., 2008, as principais classes de solos identificadas no Rio Grande do Sul são: Alissolos, Argissolos, Cambissolos, Chernossolos, Gleissolos, Latossolos, Luvisolos, Neossolos, Nitossolos, Organossolos, Planossolos, Plintossolos e Vertissolos. No entanto, os autores destacam que solos com características texturais siltosas, são raros e, observados apenas em pontos muito específicos do Estado.

3.1 Bancos de Dados: obtenção e caracterização

Neste trabalho foram utilizadas informações de retenção de água de solos do Rio Grande do Sul, disponíveis na literatura. A busca foi realizada nas seguintes formas: (i) biblioteca digital (PORTAL DOMÍNIO PÚBLICO, 2011); (ii) Sistema de Comutação Bibliográfica – COMUT (IBICT, 2005).

O levantamento de material foi realizado nas bibliotecas das seguintes Instituições: Universidade Federal de Santa Maria, Universidade Federal do Rio Grande do Sul, Universidade Federal de Pelotas e Universidade de Passo Fundo. Objetivou-se coletar dados de retenção de água no solo que possuem informações de unidade volumétrica a vários potenciais matriciais ou parâmetros de ajuste da curva de retenção de água no solo, que permitisse obter valores de unidade, além de teores de areia, silte, argila, matéria orgânica (MO), densidade do solo (ρ_s), densidade de partículas (ρ_p) e porosidade total (η).

Nessa busca, foram identificados um total de 50 trabalhos, com dados de retenção de água, dando origem ao que chamou-se de banco de dados geral, sem separação por classe textural (Tabela 1). O mesmo foi organizado em planilha eletrônica, para posterior classificação textural dos solos.

O banco de dados foi obtido de trabalhos dos seguintes autores: Kochhann (1971); Gomes (1972); Curi (1975); Scopel (1977); Cintra (1980); Salton (1991); Carpenedo (1994); Barcelos (1996); Rojas (1998); Klein (1998); Dalmolin (2002); Peraza (2003); Silva (2003); Camara (2004); Dalmago (2004); Riquelme (2004); Bernardon (2005); Brandt (2005); Cardoso (2005); Franco (2006); Nunes (2006); Vieira (2006); Spohr (2007); Streck (2007); Fontanela (2008); Machado et al. (2008); Menezes (2008); Uhde (2009); Brandt (2009); Kunz (2009); Marcolin (2006); Collares (2005); Marcolin (2009); Kaiser (2010); Mentges (2010); Knes (2010); Sturmer (2008); Bamberg (2010); Franco (2010); Fiorin (2008); Losekann (2009); Mallmann (2009); Prevedello (2008); Dalbianco (2009); Potes (2009); Nebel (2009); Severo (2009); Medeiros (2010); Navarini (2010); Rosa (2009);

O banco de dados obtidos na literatura é bastante heterogêneo, quanto à textura, pois se trata de um banco composto por dados de várias regiões do RS, predominando solos argilosos (Figura 6).

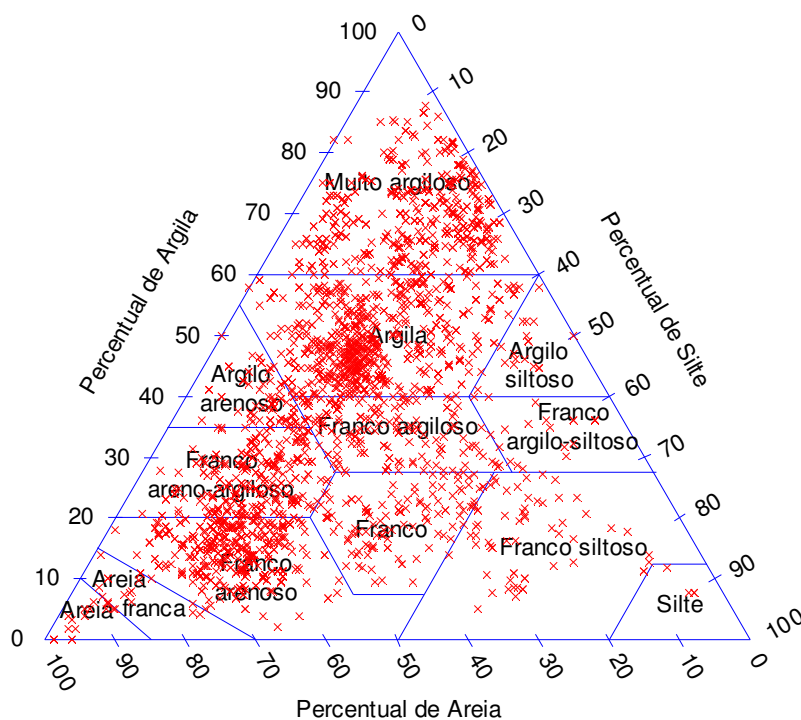


Figura 6 - Variabilidade textural dos solos do Estado do Rio Grande do Sul disponíveis no banco de dados utilizado para desenvolver as FPTs

Tabela 1 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs do Banco de dados geral

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	87.65	0.00	40.86	20.69	50.63
Silte (%)	88.20	0.00	22.28	11.66	52.34
Areia total (%)	98.70	0.00	36.84	21.38	58.05
Densidade do solo (g.cm^{-3})	1.92	0.50	1.35	0.22	16.51
Densidade de partículas (g.cm^{-3})	2.99	1.19	2.63	0.20	8.00
Matéria orgânica (g.g^{-1})	0.39	0.00	0.02	0.08	3.50
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.76	0.29	0.48	0.08	0.17
θ - 0kPa	0.83	0.22	0.48	0.09	19.41
θ - 6kPa	0.84	0.11	0.37	0.08	22.27
θ - 10kPa	0.77	0.07	0.35	0.08	23.65
θ - 33kPa	0.65	0.03	0.32	0.08	26.13
θ - 100kPa	0.64	0.03	0.30	0.08	28.36
θ - 500kPa	0.62	0.01	0.24	0.08	33.07
θ - 1500kPa	0.61	0.01	0.20	0.08	39.96

De posse da classe granulométrica do banco de dados geral, foi realizada a subdivisão do mesmo, nas diferentes classes texturais identificadas no Estado, na tentativa de melhorar a capacidade preditiva das pedofunções, formando subconjuntos mais homogêneos. Sendo assim, foram criados novos bancos de dados, divididos em: solo arenoso (Tabela 2); solo arenoso franco (Tabela 3); solo argilo arenoso (Tabela 4); solo argilo siltoso (Tabela 5); solo argiloso (Tabela 6), solo franco (Tabela 7); solo franco arenoso (Tabela 8); solo franco argilo arenoso (Tabela 9); solo franco argilo siltoso (Tabela 10); solo franco argiloso (Tabela 11); solo franco siltoso (Tabela 12); solo muito argiloso (Tabela 13).

Devido ao baixo número de amostras encontradas com características texturais siltoso, a respectiva classe não foi utilizada para desenvolvimento das FPTs.

Tabela 2 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural arenoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	6.30	0.00	3.22	2.39	74.05
Silte (%)	7.40	1.30	3.78	2.05	54.15
Areia total (%)	98.70	87.60	92.99	4.01	4.31
Densidade do solo (g.cm^{-3})	1.78	1.22	1.47	0.14	9.76
Densidade de partículas (g.cm^{-3})	2.89	1.93	2.49	0.29	12.00
Matéria orgânica (g.g^{-1})	0.08	0.01	0.01	0.02	1.91
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.49	0.34	0.41	0.04	0.10
θ 0kPa	0.49	0.34	0.41	0.04	10.01
θ -6kPa	0.48	0.13	0.34	0.08	23.28
θ -10kPa	0.41	0.07	0.31	0.09	28.31
θ -33kPa	0.36	0.03	0.28	0.09	33.58
θ -100kPa	0.34	0.03	0.26	0.09	36.36
θ -500kPa	0.31	0.01	0.23	0.09	38.35
θ -1500kPa	0.30	0.01	0.22	0.09	41.59

Tabela 3 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural arenoso franco

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	11.00	4.30	8.06	2.25	27.93
Silte (%)	19.80	3.40	9.12	5.11	55.99
Areia total (%)	88.20	75.90	82.95	4.10	4.94
Densidade do solo (g.cm^{-3})	1.59	1.17	1.46	0.12	7.96
Densidade de partículas (g.cm^{-3})	2.94	2.50	2.69	0.16	6.00
Matéria orgânica (g.g^{-1})	0.03	0.01	0.00	0.00	1.43
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.59	0.40	0.46	0.05	0.11
θ 0kPa	0.54	0.34	0.42	0.05	11.86
θ -6kPa	0.53	0.16	0.32	0.09	29.68
θ -10kPa	0.52	0.12	0.30	0.11	35.05
θ -33kPa	0.48	0.07	0.26	0.12	44.97
θ -100kPa	0.42	0.06	0.23	0.11	49.18
θ -500kPa	0.35	0.03	0.19	0.10	55.99
θ -1500kPa	0.33	0.02	0.16	0.10	63.75

Tabela 4 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argilo arenoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	50.00	35.10	39.59	3.41	8.62
Silte (%)	18.70	0.00	11.56	4.47	38.66
Areia total (%)	59.70	44.40	48.84	3.02	6.18
Densidade do solo (g.cm^{-3})	1.70	0.66	1.42	0.21	14.57
Densidade de partículas (g.cm^{-3})	2.99	2.28	2.66	0.18	6.66
Matéria orgânica (g.g^{-1})	0.04	0.01	0.01	0.01	1.32
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.65	0.35	0.47	0.06	0.13
θ 0kPa	0.68	0.26	0.45	0.08	16.89
θ -6kPa	0.47	0.18	0.32	0.07	21.80
θ -10kPa	0.46	0.17	0.30	0.07	24.14
θ -33kPa	0.44	0.14	0.27	0.08	29.02
θ -100kPa	0.41	0.11	0.25	0.08	31.81
θ -500kPa	0.42	0.06	0.20	0.07	32.43
θ -1500kPa	0.32	0.04	0.17	0.05	32.55

Tabela 5 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argilo siltoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	58.00	41.00	47.80	3.86	8.07
Silte (%)	50.00	40.00	43.85	2.74	6.24
Areia total (%)	18.00	0.00	8.28	4.18	50.42
Densidade do solo (g.cm^{-3})	1.62	0.69	1.19	0.29	23.99
Densidade de partículas (g.cm^{-3})	2.97	1.26	2.48	0.45	17.95
Matéria orgânica (g.g^{-1})	0.19	0.01	0.03	0.05	1.68
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.70	0.39	0.51	0.11	0.21
θ 0kPa	0.69	0.35	0.50	0.11	21.63
θ -6kPa	0.84	0.24	0.44	0.16	35.96
θ -10kPa	0.77	0.19	0.41	0.15	37.32
θ -33kPa	0.65	0.17	0.37	0.15	39.28
θ -100kPa	0.64	0.12	0.34	0.15	43.44
θ -500kPa	0.62	0.11	0.30	0.15	49.25
θ -1500kPa	0.61	0.09	0.26	0.15	57.71

Tabela 6 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural argiloso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	60.00	7.20	48.67	7.52	15.45
Silte (%)	79.30	0.00	22.57	9.05	40.10
Areia total (%)	45.00	3.79	28.75	8.49	29.53
Densidade do solo (g.cm^{-3})	1.80	0.66	1.36	0.21	15.25
Densidade de partículas (g.cm^{-3})	2.99	1.19	2.63	0.23	8.80
Matéria orgânica (g.g^{-1})	0.24	0.00	0.02	0.05	2.42
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.73	0.34	0.48	0.07	0.15
θ 0kPa	0.77	0.27	0.48	0.08	15.79
θ -6kPa	0.65	0.17	0.38	0.06	17.25
θ -10kPa	0.60	0.17	0.36	0.07	18.43
θ -33kPa	0.57	0.13	0.33	0.07	20.69
θ -100kPa	0.56	0.10	0.30	0.07	21.95
θ -500kPa	0.52	0.05	0.25	0.06	23.07
θ -1500kPa	0.50	0.04	0.23	0.06	26.65

Tabela 7 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	27.90	8.18	20.22	4.73	23.38
Silte (%)	61.52	27.61	40.22	6.43	15.98
Areia total (%)	51.30	25.40	39.55	7.51	18.99
Densidade do solo (g.cm^{-3})	1.78	0.60	1.30	0.26	19.82
Densidade de partículas (g.cm^{-3})	2.98	2.00	2.58	0.21	8.16
Matéria orgânica (g.g^{-1})	0.18	0.00	0.07	0.15	2.13
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.71	0.32	0.50	0.09	0.19
θ 0kPa	0.71	0.26	0.48	0.10	21.50
θ -6kPa	0.60	0.18	0.37	0.09	23.69
θ -10kPa	0.59	0.17	0.34	0.09	26.03
θ -33kPa	0.58	0.15	0.30	0.09	29.07
θ -100kPa	0.57	0.12	0.27	0.09	32.81
θ -500kPa	0.54	0.09	0.22	0.09	40.86
θ -1500kPa	0.53	0.03	0.19	0.10	51.88

Tabela 8 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco arenoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	20.00	2.00	14.31	3.70	25.88
Silte (%)	59.00	4.00	19.46	6.26	32.16
Areia total (%)	85.00	36.00	66.17	5.76	8.71
Densidade do solo (g.cm^{-3})	1.92	0.50	1.48	0.18	12.30
Densidade de partículas (g.cm^{-3})	2.99	1.85	2.63	0.13	5.07
Matéria orgânica (g.g^{-1})	0.05	0.00	0.01	0.01	1.60
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.73	0.30	0.44	0.06	0.15
θ 0kPa	0.83	0.22	0.42	0.09	20.92
θ -6kPa	0.71	0.11	0.34	0.08	25.20
θ -10kPa	0.69	0.09	0.32	0.09	26.84
θ -33kPa	0.63	0.06	0.29	0.09	30.24
θ -100kPa	0.59	0.04	0.27	0.09	33.18
θ -500kPa	0.52	0.02	0.21	0.09	42.87
θ -1500kPa	0.50	0.02	0.16	0.08	52.87

Tabela 9 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argilo arenoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	35.00	20.20	26.69	4.36	16.34
Silte (%)	27.40	2.60	16.40	4.95	30.15
Areia total (%)	75.90	45.10	56.91	6.26	11.01
Densidade do solo (g.cm^{-3})	1.90	0.53	1.45	0.17	11.80
Densidade de partículas (g.cm^{-3})	2.98	1.96	2.66	0.15	5.46
Matéria orgânica (g.g^{-1})	0.05	0.00	0.01	0.01	1.65
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.76	0.29	0.45	0.06	0.14
θ 0kPa	0.75	0.27	0.43	0.08	17.88
θ -6kPa	0.70	0.12	0.33	0.09	25.69
θ -10kPa	0.68	0.14	0.31	0.08	26.80
θ -33kPa	0.65	0.12	0.29	0.09	29.88
θ -100kPa	0.63	0.10	0.26	0.08	32.08
θ -500kPa	0.52	0.06	0.21	0.08	39.22
θ -1500kPa	0.50	0.03	0.17	0.08	47.47

Tabela 10 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argilo siltoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	40.00	28.20	34.41	3.51	10.21
Silte (%)	60.00	40.90	53.79	5.68	10.57
Areia total (%)	19.90	4.00	11.81	5.73	48.51
Densidade do solo (g.cm^{-3})	1.56	0.81	1.16	0.18	15.22
Densidade de partículas (g.cm^{-3})	2.74	1.48	2.50	0.25	10.14
Matéria orgânica (g.g^{-1})	0.12	0.00	0.11	0.25	2.32
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.65	0.43	0.55	0.07	0.13
θ 0kPa	0.65	0.31	0.53	0.09	17.39
θ -6kPa	0.59	0.22	0.45	0.11	23.95
θ -10kPa	0.58	0.22	0.44	0.10	23.54
θ -33kPa	0.56	0.20	0.40	0.11	28.24
θ -100kPa	0.55	0.15	0.36	0.12	34.72
θ -500kPa	0.52	0.13	0.30	0.13	42.91
θ -1500kPa	0.50	0.04	0.26	0.14	56.37

Tabela 11 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco argiloso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	40.00	28.20	35.15	3.59	10.22
Silte (%)	50.10	15.50	29.43	8.31	28.24
Areia total (%)	44.70	20.10	35.41	6.81	19.22
Densidade do solo (g.cm^{-3})	1.74	0.53	1.36	0.22	15.97
Densidade de partículas (g.cm^{-3})	2.99	2.04	2.61	0.21	8.00
Matéria orgânica (g.g^{-1})	0.28	0.00	0.04	0.12	3.03
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.71	0.34	0.48	0.08	0.17
θ 0kPa	0.71	0.30	0.46	0.08	17.16
θ -6kPa	0.58	0.20	0.36	0.07	19.67
θ -10kPa	0.57	0.19	0.34	0.07	21.30
θ -33kPa	0.55	0.15	0.31	0.07	23.39
θ -100kPa	0.53	0.13	0.29	0.07	25.47
θ -500kPa	0.51	0.07	0.24	0.07	30.54
θ -1500kPa	0.49	0.04	0.20	0.08	38.57

Tabela 12 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural franco siltoso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	27.10	12.10	19.77	4.09	20.67
Silte (%)	78.80	50.00	58.08	6.74	11.60
Areia total (%)	35.70	7.30	22.14	6.62	29.90
Densidade do solo (g.cm^{-3})	1.70	0.76	1.26	0.28	22.40
Densidade de partículas (g.cm^{-3})	2.93	1.65	2.47	0.27	10.75
Matéria orgânica (g.g^{-1})	0.39	0.00	0.14	0.26	1.82
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.64	0.34	0.50	0.09	0.18
θ 0kPa	0.63	0.27	0.49	0.09	18.68
θ -6kPa	0.58	0.17	0.35	0.10	28.65
θ -10kPa	0.54	0.17	0.33	0.10	29.39
θ -33kPa	0.47	0.14	0.29	0.09	29.33
θ -100kPa	0.45	0.13	0.26	0.08	30.38
θ -500kPa	0.39	0.07	0.22	0.08	36.86
θ -1500kPa	0.37	0.06	0.15	0.07	46.89

Tabela 13 - Valores médios, mínimos, máximos, desvio padrão e coeficiente de variação (CV) das variáveis utilizadas na elaboração das FPTs para a classe textural muito argiloso

Variável	Máximo	Mínimo	Média	Desvio Padrão	CV (%)
Argila (%)	87.65	60.10	69.81	6.19	8.86
Silte (%)	33.80	0.00	17.86	7.61	42.60
Areia total (%)	33.30	0.70	12.31	8.26	67.04
Densidade do solo (g.cm^{-3})	1.77	0.56	1.21	0.19	16.05
Densidade de partículas (g.cm^{-3})	2.99	2.22	2.69	0.16	6.06
Matéria orgânica (g.g^{-1})	0.07	0.00	0.01	0.01	1.45
Porosidade total ($\text{m}^3.\text{m}^{-3}$)	0.73	0.34	0.56	0.08	0.15
θ 0kPa	0.80	0.30	0.55	0.08	14.13
θ -6kPa	0.66	0.22	0.42	0.06	15.43
θ -10kPa	0.66	0.22	0.40	0.07	16.49
θ -33kPa	0.65	0.18	0.36	0.07	18.40
θ -100kPa	0.64	0.13	0.34	0.07	20.09
θ -500kPa	0.62	0.09	0.28	0.06	22.23
θ -1500kPa	0.61	0.03	0.25	0.06	25.12

3.2 Desenvolvimento das Funções de Pedotransferência

O desenvolvimento das FPTs baseou-se em dois métodos de modelagem, que permitiram transferir valores de propriedades básicas de solo em estimativas da curva de retenção de água no solo.

3.2.1 FPTs geradas por regressão linear múltipla

Foram feitas análises de regressão linear múltipla para obtenção das FPTs pontuais, para cada um dos treze bancos de dados.

Assim, foram selecionadas as variáveis que entraram nas equações de regressão, estimando-se os parâmetros para as variáveis independentes incluídas no modelo. O conjunto de dados foi submetido à análise de correlação simples para identificar as variáveis que possuíam maior efeito na curva de retenção de água no solo. Após a observação e seleção dos parâmetros mais significativos, realizou-se análise de regressão múltipla com o procedimento *stepwise* do programa *Statistical Analysis System* (SAS Institute, 1997), o qual parte da variável independente que mais se correlaciona com a variável dependente, para no passo seguinte, adicionar outra variável de maior correlação parcial com o modelo pré-selecionado e, posteriormente, testar pelo teste F. Quando o valor do F calculado ultrapassar 0.05, o procedimento de inserção de variáveis é encerrado.

Foram geradas FPTs para estimar cada um dos pontos de 0, -6, -10, -33, -100, -500 e -1500 kPa da curva de retenção de água no solo, totalizando sete FPTs geradas para cada classe textural estudada (uma para cada ponto da curva). Essas FPTs foram geradas por meio de variáveis independentes incluídas no modelo, em nível de 5% de probabilidade de erro. As variáveis independentes utilizadas neste estudo foram: areia, silte, argila, densidade do solo, densidade de partícula, porosidade total e matéria orgânica.

Cada conjunto de dados foi dividido aleatoriamente, em 60% das amostras para geração das FPTs e os 40% restante para validação das mesmas. Na Tabela

14 são apresentados os números de dados utilizados em cada face do processo, para obtenção das FPTs, nas distintas classes texturais.

Tabela 14 – Número de amostras utilizadas, para geração e validação das FPTs, nas distintas classes texturais

Classe Textural (sigla)	Nº amostras geração	Nº amostras validação
Todos os dados de solos, independentes da classe (geral)	1096	731
Solo Arenoso (Are)	11	7
Solo Arenoso Franco (AF)	10	6
Solo Argilo Arenoso (ArgAre)	39	26
Solo Argilo Siltoso (ArgS)	10	7
Solo Argiloso (Arg)	326	217
Solo Franco (F)	75	51
Solo Franco Arenoso (FAre)	230	153
Solo Franco Argilo Arenoso (FArgAre)	133	90
Solo Franco Argilo Siltoso (FArgS)	12	8
Solo Franco Argiloso (FArg)	78	52
Solo Franco Siltoso (FS)	27	17
Solo Muito Argiloso (MArg)	145	97

Com a obtenção das equações, para o banco de dados geral, essas foram testadas nos demais bancos de dados da seguinte forma: equação banco de dados geral versus banco de dados solo arenoso, banco de dados solo arenoso franco, banco de dados solo argilo arenoso, banco de dados solo argilo siltoso, banco de dados argiloso, banco de dados solo franco, banco de dados solo franco arenoso, banco de dados solo franco argilo arenoso, banco de dados solo franco argilo siltoso, banco de dados solo franco argiloso, banco de dados solo franco siltoso, banco de dados solo muito argiloso.

3.2.2 FPTs geradas a partir de Redes Neurais Artificiais

A próxima etapa foi o estabelecimento das FPTs, para os treze bancos de dados, baseando em análises de Redes Neurais Artificiais (RNAs), sendo essas utilizadas para expressar a dependência da retenção de água no solo com propriedades dos solos.

3.2.2.1 Definição da entrada e saída das RNAs

Para a definição das variáveis de entrada com maior influência, na predição da curva característica de água no solo, foram testadas arquiteturas com diferentes números de neurônios na camada de entrada. Treinou-se RNAs com sete, seis, cinco e quatro neurônios na camada de entrada.

As variáveis para RNAs com sete entradas foram: teores de argila, silte e areia, densidade de solo (em g.cm^{-3}), densidade de partícula (em g.cm^{-3}), matéria orgânica e porosidade total; nas redes com seis entradas, testou-se: teores de argila, silte e areia, densidade de solo (em g.cm^{-3}), densidade de partícula (em g.cm^{-3}) e matéria orgânica; para redes com cinco entradas avaliou-se: teores de argila, silte e areia, densidade de solo (em g.cm^{-3}) e densidade de partícula (em g.cm^{-3}); e para redes com quatro neurônios na camada de entrada testou-se: teores de argila, silte, areia e densidade de solo (em g.cm^{-3}). A partir da definição do número de neurônios na camada de entrada, os treinos nas demais classes de solo procederam-se com arquiteturas sem variação nesta camada.

A saída da rede foi: umidade volumétrica do solo nas tensões de 0, -6, -10, -33, -100, -500 e -1500 kPa. A ilustração, das entradas e saídas das redes, é mostrada na Figura 7.

Para desenvolvimento do sistema foi utilizado o Neural Network Toolbox do software Matlab (versão 7.12.0.635). O treinamento das redes neurais artificiais multicamadas, foi através do algoritmo *backpropagation*, com otimização *Levenberg-Marquadt*.




Figura 7 - Arquitetura da rede neural

Para os treze bancos de dados estudados, foram treinadas redes com as características descritas na Tabela 15.

Tabela 15 – Classe textural do solo e número de amostras totais utilizadas em cada rede

Nome da RNA	Classe Textural (Sigla)	Nº amostras
Rede 1	Todos os dados de solos, independentes da classe (geral)	1827
Rede 2	Solo Arenoso (Are)	18
Rede 3	Solo Arenoso Franco (AF)	16
Rede 4	Solo Argilo Arenoso (ArgAre)	65
Rede 5	Solo Argilo Siltoso (ArgS)	17
Rede 6	Solo Argiloso (Arg)	543
Rede 7	Solo Franco (F)	126
Rede 8	Solo Franco Arenoso (FAre)	383
Rede 9	Solo Franco Argilo Arenoso (FArgAre)	223
Rede 10	Solo Franco Argilo Siltoso (FArgS)	20
Rede 11	Solo Franco Argiloso (FArg)	130
Rede 12	Solo Franco Siltoso (FS)	44
Rede 13	Solo Muito Argiloso (MArg)	242

3.2.2.2 Treinamento e validação da rede

Para cada rede, os bancos de dados foram divididos aleatoriamente em cerca de 70% dos dados para treinamento, 15% dos dados para validação, e 15% dos dados restantes para teste.

A RNA foi treinada 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, da umidade de água em diferentes potenciais, na amostra de treinamento. Em cada iteração, os parâmetros w 's (pesos) e b 's (bias) da RNA foram atualizados por meio da regra de treinamento.

O treinamento foi feito mantendo constante o número de camadas (camada de entrada, intermediária e saída), variando-se: o número de neurônios na camada de entrada (4, 5, 6 e 7 neurônios na camada) e, o número de neurônios na camada intermediária (5, 6, 7, 8, 9, 10, 13, 15, 18, 21, 24, 27, 30, 35, 40 e 50 neurônios na camada). Como os pesos são elementos iniciados com valores aleatórios, para cada treinamento obtêm-se valores diferentes. Desta forma, cada rede foi treinada várias vezes (50, 100, 200, 250, 300, 500, 1000 e 2000 treinos) com a mesma arquitetura para selecionar o melhor resultado, a partir dos indicadores estatísticos indicados nas equações 2, 3, 4, 5 e 6.

Para representar a arquitetura de uma rede foi utilizada a notação "NE - NCE NS", onde NE é o número de entradas da camada de entrada da rede, NCE é o número de neurônios da camada escondida, e NS é o número de neurônios da camada de saída.

A escolha da arquitetura de uma rede deve ser feita com cautela, pois uma rede com muitas camadas escondidas ou muitos neurônios nestas camadas pode fornecer excelentes resultados para os dados de treinamento, mas para os dados de validação os resultados podem ser totalmente imprecisos (este problema chama-se *overfitting*) (BRAGA et al., 2007). Desta forma, escolheu-se como melhor resultado a rede que obteve menor erro relativo médio e menor variância em relação aos dados de validação. Havendo resultados próximos na escolha da arquitetura, selecionou-se aquela com menor quadrático médio para os dados de treino e menor número de neurônios.

A partir dos treinos, com a escolha da melhor arquitetura para a rede 1 e, a obtenção das matrizes de pesos e bias da mesma, essa foi testada nos demais banco de dados (doze classes texturais).

3.2.3 Análise dos dados

Para a interpretação das RNAs, em cada treinamento determinou-se o erro relativo médio, através das seguintes equações:

$$\bar{E} = \frac{1}{n} \sum_{i=1}^n E_i \quad (2)$$

onde n é a quantidade de padrões de teste e E_i é o erro relativo do i -ésimo padrão de teste ou seja:

$$E_i = \frac{|d_i - r_i|}{|d_i|} \cdot 100 \quad (3)$$

onde d_i é a saída desejada e r_i é a saída obtida pela rede.

A variância do erro relativo e o desvio padrão do mesmo foram calculados, respectivamente, através das duas equações seguintes:

$$\text{Var}(E) = \frac{1}{n} \sum_{i=1}^n (r_i - \bar{E})^2 \quad (4)$$

$$\text{Desvio} = \sqrt{\text{Var}(E)} \quad (5)$$

A eficiência da estimativa da curva característica de água no solo, a partir do uso de regressão linear múltipla e redes neurais artificiais, foram analisadas graficamente pela relação 1:1, entre os dados estimados versus os observados e, por meio dos seguintes indicadores estatísticos: coeficiente de correlação (r); índice

de concordância de Wilmont (c); coeficiente de determinação (R^2) e índice de desempenho (id).

O coeficiente de correlação (r) permite quantificar o grau de associação entre as duas variáveis envolvidas na análise (SCHNEIDER, 1998), sendo seu campo de variação de -1 a 1 e quanto maior o seu valor absoluto maior o grau de associação entre os valores observados e os valores estimados.

O coeficiente de correlação pode ser estimado por:

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

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 índice de concordância (c) fornece o grau de exatidão entre as variáveis envolvidas, uma vez que está relacionada a diferença entre os valores estimados em relação aos valores observados, sendo seu campo de variação de 0 (zero) (nenhuma concordância) a 1 concordância perfeita (WILLMONT, 1981).

O índice de concordância pode ser calculado pela expressão:

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2} \quad (7)$$

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.

Conhecendo-se esses indicadores foi determinado o índice de desempenho id , segundo Camargo e Sentelhas (1997), calculado por: $id = r c$.

O índice id tem a finalidade de avaliar o desempenho do método utilizado, considerando as seguintes classes de interpretação, de acordo com Costa (2004) (Tabela 16).

Tabela 16 - Classificação para o índice de desempenho (id) do método proposto.

Classes	Valores de id	Desempenho
1	> 0.85	Ótimo
2	0.76 a 0.85	Muito Bom
3	0.66 a 0.75	Bom
4	0.61 a 0.65	Regular
5	0.51 a 0.60	Fraco
6	0.41 a 0.50	Muito Fraco
7	< 0.41	Péssimo

Fonte: Costa (2004).

Para análise da acurácia das FPTs pontuais, geradas por RLM e RNAs, utilizou-se o conjunto de dados da validação. Primeiramente, calcularam-se os indicadores estatísticos, r , c , R^2 e id , em cada potencial matricial considerado, confrontando-se os dados observados (presentes no banco) com os dados estimados (por equações lineares e pelas RNAs treinadas), utilizando todo o conjunto de dados selecionado para validar as FPTs, em cada classe textural do solo.

Em um segundo momento, a análise foi feita comparando-se dados observados de cada classe textural com dados estimados, para essas mesmas classes, pelas equações geradas, por RLM, para o banco de dados geral. Após realizou-se a mesma análise, porém para as FPTs obtidas por RNAs, onde foram comparados os dados observados de cada classe textural com dados estimados, para as respectivas classes, quando utilizando a RNA treinada para o banco de dados geral (rede1). Finalmente, através dos indicadores estatísticos, foi realizado um estudo entre os resultados obtidos pelas FPTs geradas por regressão linear múltiplas e as FPTs geradas a partir de redes neurais artificiais, para avaliar qual apresentou maior capacidade preditiva.

4 RESULTADOS E DISCUSSÃO

4.1 Correlações entre as variáveis e a retenção de água

Na Tabela 17 encontram-se as correlações entre as características, estruturais, granulométricas e mineralógicas, e a umidade do solo nos diferentes potenciais matriciais, e classes texturais estudados. De acordo com Libardi (2005) estas características são responsáveis pela retenção de água no solo. O coeficiente de correlação de Pearson (r) indica a força e a direção do relacionamento linear entre duas variáveis (MILONE e ANGELINI, 2003), este varia entre os valores -1 e 1. O valor 0 (zero) significa que não há relação linear, o valor 1 indica uma relação linear perfeita e o valor -1 também indica um relação linear perfeita mas inversa, ou seja quando uma das variáveis aumenta a outra diminui. Quanto mais próxima estiver de 1 e -1, mais forte é a associação linear entre as duas variáveis.

Observa-se a partir da Tabela 17, que a porosidade total (η) foi o atributo que melhor correlação apresentou para os conjuntos de dados das seguintes classes texturais: argilo siltoso; franco arenoso; franco argiloso e franco siltoso, assim como para o banco de dados geral, nos diferentes potenciais matriciais.

Na classe de solo arenosa, nos potenciais de 0, -100, -500 e -1500 kPa os maiores valores para o coeficiente de correlação foi para o atributo η , nas três últimas tensões os valores foram negativos. Para este mesmo conjunto de dados, as propriedades do solo que apresentaram maiores correlações para o potencial de -6 kPa foi a matéria orgânica (MO), enquanto que nos potenciais de -10 e -33 kPa a variável silte destacou-se.

Para o conjunto de dados que compõem a classe de solo arenoso franco, observou-se que entre as diversas variáveis, a η apresentou a melhor correlação com a umidade do solo no potencial matricial de -1500 kPa, enquanto que para os potenciais de 0 a -6 kPa, com correlação negativa, as variáveis densidade do solo (d_s) e MO destacaram-se, respectivamente. Para os demais potenciais as maiores correlações foram observadas com a densidade de partícula (d_p).

Observando a classe de solo argilo arenosa, nota-se que em todos os potenciais matriciais os valores elevados dos coeficientes de correlação foram positivos, sendo que para as tensões de 0, -500 e -1500 kPa os atributos com maiores correlações são respectivamente η , d_p e d_p , enquanto que para as tensões de -6, -10, -33 e -100 kPa as maiores correlações foram para a variável silte.

Para a classe de solo Argiloso, a variável argila apresentou as maiores correlações, positivas, com as umidades do solo para os potenciais intermediários (-33 e -100 kPa), já para os potenciais matriciais maiores, de 0 a -10 kPa, a variável com maior correlação foi a η . Enquanto, que a variável silte apresentou a maior correlação (negativa) com a umidade do solo nos potenciais de -500 e -1500 kPa

Esse comportamento corrobora com Rivers e Shipp (1978), onde encontraram correlações significativas da retenção de água no solo com a percentagem de areia, silte e argila. Sendo que o teor de argila do solo apresentou as maiores correlações com a retenção de água.

A correlação positiva com argila é explicada pelo efeito das partículas menos grosseiras do solo na retenção de água, em contraposição do efeito das partículas maiores, no caso da areia. Arruda et al. (1987), Centurion e Andrioli (2000) observaram que a retenção de água, nas tensões correspondentes ao ponto de murcha permanente, mostrou-se dependente das frações mais finas do solo (silte+argila), além da matéria orgânica que atuou de forma indireta.

No conjunto de dados da classe franco, a variável η apresentou as maiores correlações, com as umidades do solo para os potenciais de 0 a -100 kPa, enquanto que para os potenciais de -500 e -1500 kPa, a variável com maior correlação (negativa) foi d_s .

Para o banco de dados da classe franco argilo arenoso, nos diferentes potenciais matriciais a variável η , apresentou as maiores correlações, exceto para o potencial de -500 kPa, onde a maior correlação foi com a variável d_s .

Para o banco de dado da classe franco argilo siltoso, nos diferentes potenciais matriciais a variável η , apresentou as maiores correlações, positivas, exceto para o potencial de -1500 kPa, onde a maior correlação foi com a variável areia (correlação negativa).

Notou-se, para o conjunto de dados da classe muito argiloso, a variável η apresentou as maiores correlações, com as umidades do solo para os potenciais de 0, -6, -500 e -1500 kPa, enquanto que para os potenciais de -10, -33 e -100 kPa, a

variável com maior correlação foi MO. Montenegro (1976) menciona que, em geral, a capacidade de armazenamento de água do solo aumenta com o teor de MO, e que esse comportamento, tanto para amostras superficiais como para amostras profundas do perfil do solo, está associado a variações texturais.

Esses resultados concordam parcialmente com os encontrados por Michelin (2010) e Solano Peraza (2003), estes desenvolveram seus trabalhos a partir de um conjunto de amostras, consideradas representativas do solo do RS, os autores destacaram que a correlação da granulometria dos solos com a retenção de água é alto, sendo positiva para a fração argila. Para Arruda et al. (1987) a retenção de água, nas tensões correspondentes à capacidade de campo e ponto de murcha permanente, mostrou-se dependente das frações mais finas do solo (silte+argila). Além da composição granulométrica, alguns atributos estruturais do solo apresentam alta correlação com a retenção de água, especialmente em potenciais mais elevados (MICHELON, 2010).

Rivers e Shipp (1978), Saxton et al. (1986) e Tyler e Wheatcraft (1989), consideram a textura do solo como a principal variável dos modelos matemáticos para estimar suas relações com a retenção de água no solo. Outros pesquisadores (WÖSTEN et al., 1995 e BATJES, 1996) consideraram variáveis texturais e matéria orgânica. Fernandez e Oliveira (1987), em pesquisa realizada em São Paulo, consideraram valores relacionados com a textura, somatórios de tamanhos de partículas e densidade de solo.

Tabela 17 – Coeficiente de correlação (r) entre as variáveis e a umidade retida a diferentes potenciais dos dados utilizados para gerar as funções de pedotransferência das diferentes classes de solo, de solos do RS

(continua)

Classe Textural	Var.	Potencial (kPa)							Classe Textural	Var.	Potencial (kPa)						
		0	-6	-10	-33	-100	-500	-1500			0	-6	-10	-33	-100	-500	-1500
arenoso	Argila	0.411	0.102	0.153	0.094	0.052	0.000	-0.024	argilo siltoso	Argila	0.383	0.391	0.426	0.465	0.446	0.443	0.398
	Silte	0.407	0.341	0.345	0.252	0.182	0.138	0.108		Silte	0.476	0.417	0.448	0.475	0.485	0.499	0.510
	Areia	-0.453	-0.235	-0.268	-0.185	-0.124	-0.070	-0.041		Areia	-0.574	-0.542	-0.591	-0.640	-0.631	-0.636	-0.597
	MO	0.207	0.380	0.286	0.161	0.052	0.130	0.082		MO	-0.351	-0.266	-0.298	-0.305	-0.290	-0.263	-0.202
	ds	0.434	0.162	0.131	0.048	-0.017	0.001	-0.019		ds	-0.447	-0.390	-0.366	-0.383	-0.396	-0.431	-0.493
	dp	0.778	0.192	0.117	-0.009	-0.099	-0.109	-0.151		dp	0.613	0.510	0.544	0.557	0.530	0.495	0.440
	η	0.998	0.090	-0.011	-0.136	-0.213	-0.272	-0.320		η	0.938	0.785	0.784	0.805	0.792	0.793	0.804
arenoso franco	Argila	0.278	0.241	0.281	0.287	0.287	0.332	0.387	argiloso	Argila	0.198	0.303	0.291	0.303	0.288	0.283	0.246
	Silte	-0.308	0.172	0.137	0.109	0.074	-0.110	-0.213		Silte	-0.123	-0.150	-0.130	-0.189	-0.214	-0.288	-0.274
	Areia	0.231	-0.344	-0.318	-0.287	-0.240	-0.031	0.064		Areia	-0.049	-0.119	-0.132	-0.072	-0.028	0.066	0.085
	MO	0.074	-0.641	-0.556	-0.576	-0.585	-0.577	-0.534		MO	0.228	0.162	0.153	0.118	0.053	0.011	-0.011
	ds	-0.527	-0.144	-0.165	-0.147	-0.116	-0.194	-0.272		ds	-0.667	-0.351	-0.261	-0.131	-0.041	0.039	0.052
	dp	-0.030	0.599	0.610	0.629	0.663	0.615	0.548		dp	0.097	0.048	0.064	0.064	0.082	0.072	0.082
	η	0.426	0.478	0.504	0.501	0.494	0.528	0.551		η	0.898	0.495	0.420	0.274	0.187	0.075	0.068
argilo arenoso	Argila	0.121	-0.224	-0.300	-0.300	-0.306	-0.219	-0.169	franco	Argila	0.239	0.225	0.161	0.143	0.135	0.052	0.093
	Silte	-0.361	0.349	0.425	0.455	0.496	0.370	0.253		Silte	0.292	0.088	0.033	0.051	0.036	0.085	-0.017
	Areia	0.369	-0.241	-0.263	-0.305	-0.356	-0.275	-0.167		Areia	-0.400	-0.217	-0.129	-0.134	-0.117	-0.105	-0.044
	MO	0.654	0.145	0.160	0.081	-0.040	-0.027	0.090		MO	0.014	-0.125	-0.269	-0.235	-0.198	-0.161	-0.021
	ds	-0.663	0.152	0.209	0.254	0.298	0.324	0.255		ds	-0.874	-0.585	-0.506	-0.461	-0.406	-0.337	-0.243
	dp	0.011	0.227	0.268	0.272	0.243	0.372	0.401		dp	0.016	0.148	0.160	0.115	0.071	-0.034	-0.028
	η	0.811	-0.021	-0.059	-0.113	-0.189	-0.137	-0.027		η	0.948	0.672	0.588	0.522	0.445	0.324	0.212

Tabela 17 – Coeficiente de correlação (r) entre as variáveis e a umidade retida a diferentes potenciais dos dados utilizados para gerar as funções de pedotransferência das diferentes classes de solo, de solos do RS

(continuação)

Classe Textural	Var.	Potencial (kPa)							Classe Textural	Var.	Potencial (kPa)						
		0	-6	-10	-33	-100	-500	-1500			0	-6	-10	-33	-100	-500	-1500
franco arenoso	Argila	-0.037	-0.075	-0.081	-0.047	0.008	0.016	0.020	franco argiloso	Argila	-0.079	0.088	0.100	0.092	0.083	0.057	0.120
	Silte	0.116	0.141	0.115	0.048	-0.019	0.000	0.018		Silte	0.470	0.248	0.173	0.140	0.117	0.093	-0.030
	Areia	-0.120	-0.136	-0.104	-0.054	-0.015	-0.035	-0.050		Areia	-0.505	-0.333	-0.252	-0.209	-0.177	-0.137	-0.027
	MO	0.245	0.180	0.149	0.056	-0.008	0.109	0.167		MO	0.022	-0.042	-0.125	-0.118	-0.114	-0.107	-0.103
	ds	-0.640	-0.396	-0.335	-0.293	-0.270	-0.255	-0.292		ds	-0.798	-0.598	-0.535	-0.500	-0.451	-0.389	-0.257
	dp	0.357	0.380	0.378	0.339	0.284	0.187	0.140		dp	-0.058	0.006	0.055	0.025	0.037	0.061	0.126
	η	0.875	0.651	0.589	0.522	0.459	0.372	0.382		η	0.805	0.609	0.565	0.513	0.468	0.416	0.308
franco argilo arenoso	Argila	0.080	0.106	0.119	0.098	0.111	0.185	0.190	franco siltoso	Argila	0.293	0.250	0.220	0.258	0.278	0.279	0.179
	Silte	-0.165	-0.168	-0.162	-0.136	-0.142	-0.116	-0.128		Silte	-0.079	-0.088	-0.072	-0.157	-0.235	-0.362	-0.215
	Areia	0.086	0.070	0.056	0.048	0.044	-0.030	-0.023		Areia	-0.101	-0.065	-0.063	-0.001	0.067	0.196	0.109
	MO	0.239	0.091	0.091	0.013	-0.065	-0.049	0.042		MO	0.007	-0.084	-0.174	-0.084	0.003	0.112	-0.037
	ds	-0.640	-0.520	-0.513	-0.486	-0.474	-0.486	-0.460		ds	-0.861	-0.583	-0.515	-0.545	-0.567	-0.566	-0.444
	dp	0.448	0.389	0.329	0.278	0.257	0.097	0.124		dp	-0.283	-0.011	0.044	0.004	-0.064	-0.164	0.019
	η	0.804	0.663	0.617	0.560	0.529	0.478	0.481		η	0.936	0.690	0.629	0.651	0.651	0.607	0.533
franco argilo siltoso	Argila	-0.015	0.106	0.005	-0.031	-0.039	0.019	0.329	muito argiloso	Argila	0.272	-0.020	-0.045	-0.035	-0.051	0.025	0.039
	Silte	0.466	0.426	0.419	0.303	0.265	0.251	0.219		Silte	-0.510	0.036	0.118	0.166	0.128	0.007	-0.156
	Areia	-0.453	-0.488	-0.418	-0.282	-0.240	-0.261	-0.419		Areia	0.306	-0.021	-0.081	-0.132	-0.087	-0.022	0.122
	MO	0.217	0.124	-0.035	-0.080	-0.152	-0.199	-0.100		MO	-0.115	0.228	0.306	0.338	0.308	0.214	0.177
	ds	-0.444	-0.206	-0.175	-0.107	-0.137	-0.221	-0.109		ds	-0.787	-0.187	-0.091	-0.058	-0.082	-0.283	-0.412
	dp	0.092	-0.019	-0.031	-0.064	-0.059	0.018	0.018		dp	0.492	0.133	0.069	0.001	0.042	0.138	0.185
	η	0.833	0.495	0.485	0.378	0.381	0.461	0.305		η	0.982	0.249	0.140	0.074	0.117	0.341	0.471

Tabela 17 – Coeficiente de correlação (r) entre as variáveis e a umidade retida a diferentes potenciais dos dados utilizados para gerar as funções de pedotransferência das diferentes classes de solo, de solos do RS

(conclusão)

Classe Textural	Variáveis	Potencial (kPa)						
		0	-6	-10	-33	-100	-500	-1500
Banco de dados geral	Argila	0.443	0.278	0.262	0.222	0.221	0.309	0.379
	Silte	0.017	0.065	0.063	0.031	-0.013	-0.018	-0.080
	Areia	-0.432	-0.307	-0.290	-0.232	-0.204	-0.283	-0.310
	MO	0.148	0.097	0.086	0.056	0.014	0.029	0.011
	ds	-0.815	-0.509	-0.435	-0.354	-0.309	-0.323	-0.319
	dp	0.150	0.131	0.155	0.147	0.150	0.132	0.161
	η	0.914	0.582	0.516	0.427	0.380	0.383	0.387

4.2 FPTs pontuais obtidas por regressão linear múltipla

A seguir serão apresentados os resultados das FPTs pontuais, para estimativa da retenção de água no solo, obtidas a partir de regressão linear múltipla, para as diferentes classes texturais estudadas.

4.2.1. Estimativa da retenção de água para classe de solo arenoso

As FPTs geradas para estimar a retenção de água nos potenciais de 0 e -6 kPa, com respectivos coeficientes de determinação (R^2), são apresentados na Tabela 18.

Observa-se que as variáveis com contribuição significativa, para a FPT de estimativa da retenção de água no potencial de 0 kPa, foram: silte, MO, ds e η , com destaque para η , que apresentou R^2 parcial de 0,9993. Esse resultado está de acordo com aquele obtido na Tabela 17, o qual indica maior correlação da porosidade com a retenção de água no potencial de 0 kPa, quando comparada às demais variáveis consideradas, e destaca a importância da estrutura do solo na

estimativa da retenção de água em potenciais mais elevados. Deste modo, corroborando com Michelin (2010), Reichert (2009), e Hillel et al. (1972).

A FPT para estimativa da retenção de água no potencial de -6 kPa foi composta por teor de silte e MO. A MO foi o atributo que mais contribuiu para a função gerada, apresentando coeficiente de determinação parcial de 0,2576. Esse resultado está de acordo com aqueles obtidos na Tabela 17, onde se observa alta correlação da MO com a retenção de água no respectivo potencial, e indica que 25,7% da variação na retenção de água no potencial de -6 kPa deve-se ao teor de matéria orgânica do solo.

Para os potenciais de retenção de água no solo de -10, -33, -100, -500 e -1500 kPa, não houve variáveis significativas a 5% para construção dos modelos.

Tabela 18 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe arenoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)			
	0		-6	
	Coef.	R ² -parcial	Coef.	R ² -parcial
Intersec.	-0,0082		0,3052	
Argila	ns		ns	
Silte	-0,0003	0,0004	0,0267	0,2372
Areia	ns		ns	
MO	-0,0217	0,0001	1,9201	0,2576
ds	0,0054	0,0002	ns	
dp	ns		ns	
η	1,0010	0,9993	ns	
R ²		1,000		0,4948

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

A partir dos modelos gerados para estimar umidade do solo nos diferentes potenciais matriciais, os mesmos foram avaliados quanto sua capacidade preditiva no restante do conjunto de dados, através da relação 1:1 entre os dados observados e estimados pelas FTPs, juntamente com o R² calculado com todas as amostras

presentes no banco de dados, utilizado para validação. Essa relação é apresentada na Figura 8.




Figura 8 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural arenoso

Nota-se na Figura 8 que as FPTs geradas, para a classe de solo arenosa, apresentaram uma forte correlação, com coeficiente de determinação superior a 0.70. De acordo com a classificação de Garcia (1989), valores de coeficiente de determinação superiores a 0,70 indicam bons ajustes. Deste modo, 71,7% da umidade de água no solo é função das variáveis independentes incluídas no modelo.

4.2.2 Estimativa da retenção de água para classe de solo arenoso franco

As FPTs geradas para estimar a retenção de água nos diferentes potenciais e seus respectivos coeficientes de determinação (R^2) são apresentados na Tabela 19. Observa-se, na composição das FPTs para os potenciais maiores e iguais a -33

kPa, a presença de atributos estruturais, já para os potenciais menores que -33 kPa, as FPTs foram compostas também por atributos texturais. A densidade de partícula (d_p), com coeficiente de determinação parcial de 0.5825, 0.5633, 0.5201, 0.5542, 0.5727, 0.4015 e 0.3694, foi o atributo com a maior contribuição para as funções geradas, nos potenciais matriciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, respectivamente.

Estes resultados corroboram, parcialmente com a literatura, a qual destaca que a retenção de água em baixos potenciais está relacionada principalmente a adsorção de água nas partículas do solo (HODNETT e TOMASELLA, 2002; TESSIER et al., 1999; RAWLS et al., 2003; BAUER e BLACK, 1992; PACHEPSKY e RAWLS, 1999).

De acordo com Hillel et al., (1972); Reichardt e Timm, (2004), em elevados conteúdos de água no solo, nos quais os fenômenos de capilaridade são importantes, a curva característica de água do solo é dependente do arranjo e da distribuição dos poros do solo. Assim sendo, é influenciada pela estrutura do solo, tornando-se uma função da densidade e da porosidade do solo. Por outro lado, para baixos conteúdos de água no solo, a retenção depende dos fenômenos de adsorção, os quais são mais influenciados pela textura e pela superfície específica das partículas.

No entanto discordam de Righes et al. (1983), estes analisando o comportamento da curva de retenção de água em relação as diferentes profundidades, observaram que a retenção de água em potenciais maiores que -33 kPa obedeceu, particularmente, a variação da composição granulométrica das diferentes camadas. No entanto, quando as amostras de solo foram submetidas a potenciais iguais ou menores a -33 kPa, observou que esse fato não ocorreu, sendo contrário à variação da composição granulométrica.

Tabela 19 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural arenoso franco e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	1,1095		-1,1350		-1,3056		-1,6757		-2,9682		-2,8597		-2,8034	
Argila	ns		ns		ns		ns		ns		ns		ns	
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		0,0102	0,1197	0,0123	0,1972	0,0127	0,2268
MO	ns		ns		ns		ns		ns		ns		ns	
ds	ns		ns		ns		ns		ns		ns		ns	
dp	-0,2618	0,5825	0,5388	0,5633	0,5950	0,5201	0,7199	0,5542	0,8755	0,5727	0,7526	0,4015	0,7130	0,3694
η	ns		ns		ns		ns		ns		ns		ns	
R ²		0,5825		0,5633		0,5201		0,5542		0,6924		0,5987		0,5962

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

A partir dos modelos gerados para estimar umidade do solo nos diferentes potenciais matriciais, os mesmos foram avaliados quanto sua capacidade preditiva, no conjunto de dados de validação, através da relação 1:1 entre os dados observados e estimados pelas FPTs (Figura 9). A baixa correlação linear ($R^2 \approx 0.18$), observada entre as umidades volumétricas medidas e previstas de ambas as FPTs, são indicativo do baixo desempenho das FPTs na estimativa da retenção de água no solo arenoso franco.




Figura 9 - Valores de umidade volumétrica observados na literatura e previstos com regressão linear múltipla, para a classe textural arenoso franco

4.2.3 Estimativa da retenção de água para classe de solo argilo arenoso

As equações de regressão para a estimativa do conteúdo de água no solo nos diferentes potenciais, obtidas a partir do conjunto de dados argilo arenoso, são apresentadas na Tabela 20.

Tabela 20 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argilo arenoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)											
	0		-6		-10		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	0,0040		-0,0905		0,2178		-0,4179		-0,1600		-0,2308	
Argila	ns		ns		ns		ns		ns		ns	
Silte	ns		0,0021	0,0587	ns		0,0045	0,0574	ns		ns	
Areia	ns		ns		ns		ns		ns		ns	
MO	1,5020	0,0131	-4,9351	0,2322	-4,9967	0,2589	ns		-5,1611	0,0614	ns	
ds	ns		ns		-0,3347	0,0544	ns		-0,2736	0,1721	ns	
dp	ns		ns		0,2258	0,1126	0,2465	0,2945	0,3001	0,3139	0,1554	0,1663
η	0,9196	0,8859	0,9051	0,1141	ns		ns		ns		ns	
R ²		0,8990		0,4050		0,4259		0,3519		0,5474		0,1663

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

Observa-se a partir da Tabela 20, que a η , para a estimativa da umidade do solo no potencial de 0 kPa foi o atributo que mais contribuiu para a função gerada, apresentando um coeficiente de determinação parcial de 0,8859. Para os potenciais de -100, -500 e -1500 kPa, a dp foi a maior responsável pela variação da retenção de água, enquanto que para a MO foi responsável por 23,22% e 25,89% da variação da umidade retida nos potenciais de -6 e -10 kPa, respectivamente. Na Tabela 20 não foi apresentada a FPT para retenção no potencial de -33 Kpa, uma vez, que não houve variáveis significativas, à 5%, para construção dos modelos.

Na Figura 10 está ilustrado o resultado da correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos potenciais de 0, -6, -10, -100, -500 e -1500 kPa. Verifica-se que as equações preditivas do teor de água nos diferentes potenciais, caracterizam-se como de baixa capacidade preditiva, com coeficiente de determinação inferior a 30%.




Figura 10 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argilo arenoso

4.2.4 Estimativa da retenção de água para classe de solo argilo siltoso

As FPTs geradas para estimar a retenção de água nos diferentes potenciais e seus respectivos coeficientes de determinação (R^2) são apresentados na Tabela 21. Observa-se que os atributos estruturais apresentaram maior contribuição para a composição das FPTs. Para os potenciais iguais e maiores que -33 kPa a variável η foi a maior responsável pela variação de retenção de água. Já para os potenciais menores que -33 kPa, a variação da retenção de água no solo foi devido a dp .

Na Figura 11 é apresentada a relação entre os valores de umidade observados como os estimados, pelas FPTs geradas para o banco de dados argilo siltoso. Observa-se, que os resultados obtidos pelas FPTs geradas, apresentaram bom ajuste, principalmente para umidade do solo a elevados potenciais. No entanto, nota-se a presença de valores anômalos (pontos distantes da linha principal 1:1), para os valores de umidade estimados a baixos potenciais. Esses valores contribuíram negativamente para a eficiência das FPTs, observando-se que o modelo superestima os valores determinados, para um grande número de dados observados.




Figura 11 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argilo siltoso

Tabela 21 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argilo siltoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	0,0836		-0,0732		-0,1011		-0,1552		-0,7729		-0,8302		-0,8519	
Argila	ns		ns		ns		ns		ns		ns		ns	
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		-0,0276	0,2603	-0,0278	0,2797	-0,0284	0,2945
MO	ns		ns		ns		-6,4217	0,2223	ns		ns		ns	
ds	ns		ns		ns		ns		ns		ns		ns	
dp	ns		ns		ns		ns		0,5189	0,4977	0,5235	0,5354	0,5231	0,5439
η	0,8582	0,9216	1,0791	0,4496	1,0706	0,4537	1,3011	0,4702						
R ²		0,9216		0,4496		0,4537		0,6925		0,7580		0,8151		0,8384

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.5 Estimativa da retenção de água para classe de solo argiloso

As equações de regressão para a estimativa do conteúdo de água no solo nos distintos potenciais, obtidas a partir de análises no conjunto de dados da classe textural argiloso, são apresentadas na Tabela 22. Nota-se na composição dessas FPTs, a presença de atributos estruturais e texturais do solo. A maior contribuição, para as funções geradas, observadas a partir dos coeficientes de determinação, nos potenciais de 0 a -10 kPa, foi da estrutura do solo, por meio do atributo η . Enquanto, que para as FPTs geradas nos potenciais menores que -10 kPa, os atributos texturais, por meio dos teores de argila e silte, tiveram maior contribuição na formação das mesmas.

A capacidade preditiva das equações também pode ser aferida visualmente, comparando os dados estimados com os dados das curvas observadas, em um gráfico 1:1 (Figura 12), obtido com as equações da Tabela 22. Observa-se que as FPTs desenvolvidas, apresentaram baixa capacidade preditiva, com valor de $R^2 \approx 58$, sem tendência clara de sub ou superestimação em determinados valores de umidade.




Figura 12 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural argiloso

Tabela 22 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural argiloso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	-0,0230		0,1036		0,0687		0,0432		29,3192		0,1336		0,1818	
Argila	0,0002	0,0013	0,0015	0,0424	0,0015	0,0407	0,0019	0,0809	0,2951	0,0816	0,0011	0,0162	ns	
Silte	ns		ns		ns		ns		0,2928	0,0250	-0,0012	0,1276	-0,0022	0,1275
Areia	-0,0002	0,0007	ns		ns		ns		0,2937	0,0084	ns		-0,0010	0,0128
MO	-0,0799	0,0030	ns		ns		ns		ns		ns		ns	
ds	ns		ns		ns		ns		ns		ns		ns	
dp	ns		ns		0,0201	0,0061	0,0293	0,0122	0,0366	0,0189	ns		ns	
η	1,0204	0,8883	0,3958	0,2092	0,3069	0,1514	0,1952	0,0563	0,1799	0,0359	0,1463	0,0279	0,2088	0,0540
R ²		0,8933		0,2516		0,1982		0,1494		0,1698		0,1717		0,1943

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.6 Estimativa da retenção de água para classe de solo franco

Na Tabela 23 são apresentados os coeficientes de determinação, e das distintas variáveis que compõem as FPTs, geradas para predição da umidade de água no solo nos potenciais de 0, -6, -10, -33, -100 e -500 kPa. Ambas as FPTs, foram compostas somente por atributos estruturais do solo, exceto para a FPT do potencial 0 kPa, que apresentou significância, também para teores de silte e MO. A porosidade total foi o atributo que mais contribuiu para as funções geradas, apresentando coeficientes de determinação parciais de 0.9053, 0.4103, 0.3472, 0.2461, 0.1662 e 0.0709, para os potenciais de 0 a -500 kPa, respectivamente. Esse resultado está de acordo com aqueles obtidos na Tabela 17, onde se observa alta correlação da η com a retenção de água nos potenciais estudados. Para o potencial de -1500 kPa, nenhuma variável apresentou nível de significância de 5% para entrada no modelo.

A moderada correlação linear, segundo classificação de Garcia (1989), observada na Figura 13, entre as umidades observadas e preditas, é um indicativo de que as FPTs geradas, não apresentam boa acurácia.




Figura 13 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco

Tabela 23 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe franco e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)											
	0		-6		-10		-33		-100		-500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial.	Coef.	R ² - parcial
Intersec.	-0,1062		0,9408		1,1975		0,0746		0,0643		0,0854	
Argila	ns		ns		ns		ns		ns		ns	
Silte	0,0015	0,0062	ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		ns		ns	
MO	0,3083	0,0037	ns		ns		ns		ns		ns	
ds	ns		-0,6766	0,0308	-0,8418	0,0466	ns		ns		ns	
dp	ns		0,3561	0,0343	0,4230	0,0319	ns		ns		ns	
η	1,0428	0,9053	-1,1937	0,4103	-1,6726	0,3472	0,4946	0,2461	0,4276	0,1662	0,2890	0,0709
R ²		0,9152		0,4754		0,4257		0,2461		0,1662		0,0709

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.7 Estimativa da retenção de água para classe de solo franco arenoso

Na Tabela 24, são apresentadas as FPTs geradas para estimar a retenção de água nos diferentes potenciais matriciais e seus respectivos coeficientes de determinação (R^2). Observa-se, na composição dessas FPTs, a presença de atributos estruturais e texturais do solo. A maior contribuição para o coeficiente de determinação das funções geradas foi da estrutura do solo, por meio do atributo η , com um R^2 parcial de 0.6286, 0.3336, 0.2645, 0.2180, 0.1631, 0.0928 e 0.1028 para os potenciais de 0 a -1500 kPa, respectivamente.

Os resultados da correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos distintos potenciais, são apresentados na Figura 14. Nota-se através do coeficiente de determinação que as equações propostas apresentam baixa capacidade preditiva ($R^2 \approx 0.55$). Também, é possível verificar a presença de valores anômalos (pontos distantes da linha principal 1:1), o que contribui de forma negativa para a eficiência das FPTs.




Figura 14 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco arenoso

Tabela 24 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco arenoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	-0,2364		-0,1992		-0,1697		-0,0946		-0,0983		0,1720		-0,1394	
Argila	ns		0,0016	0,0074	0,0018	0,0077	0,0019	0,0076	0,0029	0,0169	0,0049	0,0548	0,0042	0,0452
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		ns		ns		ns	
MO	1,3426	0,0138	ns		-1,4539	0,0182	-3,8075	0,0739	-4,7588	0,1105	-3,2906	0,0400	-2,0328	0,0225
ds	ns		ns		ns		ns		ns		-0,1184	0,0103	ns	
dp	0,0888	0,0289	0,0578	0,0115	0,0457	0,0072	ns		ns		ns		ns	
η	0,9280	0,6286	0,7861	0,3336	0,7447	0,2645	0,8090	0,2180	0,7434	0,1631	0,2829	0,0928	0,5165	0,1028
R ²		0,6713		0,3525		0,2976		0,2995		0,2905		0,1979		0,1705

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.8 Estimativa da retenção de água para classe de solo franco argilo arenoso

Na Tabela 25, são apresentadas as FPTs geradas para estimar a retenção de água nos diferentes potenciais matriciais e seus respectivos coeficientes de determinação (R^2), para a classe franco argilo arenoso. Observa-se, na composição dessas FPTs, a presença de atributos estruturais, texturais e mineralógico do solo. A variável com maior contribuição no desenvolvimento das FPTs, foi a estrutura do solo, por meio do atributo η , com um R^2 parcial de 0,6737, 0,4700, 0,3457, 0,2879, 0,2400 e 0,0718 para os potenciais de 0 a -500 kPa, respectivamente. Já, para a FPT de estimativa da umidade no potencial de -1500 kPa, os atributos texturais, por meio do teor de silte, tiveram maiores contribuições no modelo.

Na Figura 15 estão ilustrados os resultados da correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa. Verifica-se que as equações preditivas do teor de água nos respectivos potenciais, caracterizam-se pela baixa capacidade preditiva, com valor de R^2 inferior a 40%.




Figura 15 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argilo arenoso

Tabela 25 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argilo arenoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	-0,3470		-0,3176		0,0230		-0,1857		0,7397		0,1553		0,1571	
Argila	ns		ns		ns		ns		ns		ns		ns	
Silte	-0,0014	0,0105	-0,0028	0,0426	-0,0033	0,0566	ns		-0,0033	0,0448	-0,0031	0,0474	-0,0048	0,1266
Areia	ns		ns		ns		0,0024	0,0387	ns		ns		ns	
MO	5,2965	0,0442	ns		-2,8522	0,0128	-5,7945	0,0635	-9,1690	0,0960	-6,4704	0,0379	-3,8154	0,0225
ds	0,1821	0,0268	0,1368	0,0241	ns		ns		-0,3887	0,0120	ns		ns	
dp	ns		ns		ns		ns		0,0992	0,0189	-0,0573	0,0458	-0,0437	0,0131
η	1,1428	0,6737	1,1034	0,4700	0,7657	0,3457	0,7529	0,2879	-0,2404	0,2400	0,5779	0,0718	0,4512	0,0435
R ²		0,7552		0,5367		0,4151		0,3901		0,4117		0,2029		0,2057

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.9 Estimativa da retenção de água para classe de solo franco argilo siltoso

As equações de regressão linear múltipla, para estimar o conteúdo de água nos diferentes potenciais matriciais, apresentaram R^2 significativos a 5%, somente nas tensões de 0 e -6 kPa (Tabela 26). No potencial de 0 kPa, observa-se valores de R^2 parciais para a FPT entre 0,0002 (argila e MO) e 0,9979 (η). Para -6 kPa, observou-se valor de R^2 parcial de 0,2472 (ds). Para os demais potenciais não houve variáveis significativas, à 5%, para construção das FPTs.

Tabela 26 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argilo siltoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)			
	0		-6	
	Coef.	R^2 -parcial	Coef.	R^2 - parcial
Intersec.	0,1437		0,8200	
Argila	0,0005	0,0002	ns	
Silte	ns		ns	
Areia	0,0007	0,0007	ns	
MO	-0,0794	0,0002	ns	
ds	-0,0799	0,0008	-0,3555	0,2472
dp	ns		ns	
η	0,8668	0,9979	ns	
R^2		0,9998		0,2472

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

A relação 1:1 entre os dados observados, e estimados pelas FPTs obtidas para estimativa da umidade nos potenciais de 0 e -6 kPa, juntamente com o coeficiente de determinação (R^2), são apresentados na Figura 16. O valor de R^2 de 0,2557 indica baixa correlação entre os valores observados e os estimados pelas FPTs. A dispersão não homogênea dos pontos em relação à linha 1:1 indica que, as FPTs obtidas não apresentaram acurácia, para estimativa da umidade do solo nos potenciais avaliados.




Figura 16 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argilo siltoso

4.2.10 Estimativa da retenção de água para classe de solo franco argiloso

As equações de regressão linear múltipla, desenvolvidas, para estimar o conteúdo de água nos diferentes potenciais matriciais, da respectiva classe textural, apresentaram R^2 significativos a 5% (Tabela 27). No potencial 0 kPa, observa-se valores parciais de R^2 entre 0.0081 (dp) e 0.8416 (η). Para a tensão de -6 kPa, observa-se valores de R^2 parciais, entre 0.0196 (ds) e 0.3849 (η). Na tensão de -10 kPa, nota-se valores parciais de R^2 entre 0.0230 (argila) e 0.2932 (η). Para o potencial de -33 kPa, os valores parciais de R^2 ficaram entre 0.0225 (dp) e 0.2533 (ds). Enquanto que para os potenciais de -100 e -500 kPa, apenas a ds apresentou R^2 significativo, com valores parciais de 0.2026 e 0.1403, respectivamente. O potencial de -1500 kPa, também apresentou uma única variável significativa, para composição da equação, com valor parcial de R^2 , para a mesma, de 0.0351 (η).

Tabela 27 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco argiloso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	0,0720		1,5507		-0,0559		2,1696		0,5259		0,4608		0,0996	
Argila	ns		0,0027	0,0218	0,0034	0,0230	ns		ns		ns		ns	
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		ns		ns		ns	
MO	0,7251	0,0197	ns		ns		ns		ns		ns		ns	
ds	ns		-1,1107	0,0196	ns		-1,4883	0,2533	-0,1762	0,2026	-0,1571	0,1403	ns	
dp	-0,0396	0,0081	0,4926	0,0531	ns		0,6744	0,0225	ns		ns		ns	
η	0,9954	0,8416	-2,1936	0,3849	0,5963	0,2932	-3,3203	0,0873	ns		ns		0,2248	0,0351
R ²		0,8694		0,4794		0,3162		0,3631		0,2026		0,1403		0,0351

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

A relação 1:1 dos dados observados, e estimados pelas FPTs obtidas para estimativa da umidade nos diferentes potenciais, juntamente como coeficiente de determinação (R^2), são apresentados na Figura 17. A dispersão não homogênea dos pontos em relação à linha 1:1 ($R^2 \approx 0,55$) indica que, as FPTs obtidas apresentaram baixa acurácia para estimativa da umidade do solo, nos potenciais avaliados.




Figura 17 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco argiloso

4.2.11 Estimativa da retenção de água para classe de solo franco siltoso

Observa-se, na composição dessas FPTs, a presença de atributos estruturais, texturais e mineralógica do solo (Tabela 28). A maior contribuição, observada pelo coeficiente de determinação, para as funções geradas foi da estrutura do solo, por meio do atributo η , com um R^2 parcial de 0,8445, 0,2037, 0,1799, 0,2342, 0,2850 e 0,3150 para os potenciais de 0 a -500 kPa, respectivamente. Já, para a FPT de estimativa da umidade no potencial de -1500 kPa, os atributos texturais, por meio do teor de areia, tiveram maiores contribuições no modelo.

Tabela 28 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural franco siltoso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	0,0105		-0,5642		-0,7684		-0,6191		-0,0726		-0,1370		0,0826	
Argila	ns		ns		ns		ns		ns		ns		ns	
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		ns		0,0037	0,0661	0,0041	0,1925
MO	-0,0411	0,0273	ns		ns		ns		ns		ns		ns	
ds	ns		ns		ns		ns		ns		ns		ns	
dp	ns		0,2026	0,0994	0,2637	0,1642	0,1983	0,1143	ns		ns		ns	
η	0,9639	0,8445	0,8255	0,2037	0,8613	0,1799	0,8079	0,2342	0,6347	0,2850	0,5341	0,3150	ns	
R ²		0,8718		0,3031		0,3441		0,3485		0,2850		0,3811		0,1925

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

Na Figura 18 estão ilustrados os resultados de correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos diferentes potenciais avaliados. Verifica-se que as equações preditivas do teor de água, nos respectivos potenciais, caracterizam-se pela baixa capacidade preditiva, com valor de R^2 inferior a 70%.




Figura 18 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural franco silty

4.2.12 Estimativa da retenção de água para classe de solo muito argiloso

As equações de regressão linear múltipla desenvolvidas, para estimar o conteúdo de água nos diferentes potenciais matriciais avaliados, apresentaram R^2 significativos para atributos texturais, estruturais e mineralógica do solo (Tabela 29). Nos potenciais maiores e iguais que -33 kPa, as equações foram compostas somente por variáveis estruturas do solo. Os maiores valores de R^2 parciais para os potenciais de 0, -6, -10, -33 kPa foram de 0,9975 (η), 0,0951(ds), 0,1264 (η) e 0,0763(ds), respectivamente.

Já, para os potenciais matriciais inferiores a -33 kPa, as FPTs foram compostas também por variáveis texturais do solo. No entanto, as variáveis com maiores contribuições nas equações, foram as estruturais do solo, por meio da ds, com R^2 parcial de 0,0704, 0,2255 e 0,3489, para os potenciais de -100, -500 e -1500 kPa, respectivamente.

Os resultados da correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos distintos potenciais são apresentados na Figura 19. Nota-se através do coeficiente de determinação que as equações propostas apresentam baixa capacidade preditiva ($R^2 \approx 0.55$), devido à distribuição heterogênea dos valores de umidade em relação a reta 1:1. No entanto, nota-se para os maiores valores de umidade uma distribuição homogênea, com pouca variação em torno da reta.




Figura 19 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para a classe textural muito argiloso

Tabela 29 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados da classe textural muito argiloso e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	0,0032		0,5093		-0,1889		-0,1123		-0,1765		0,3796		-0,0398	
Argila	ns		ns		ns		ns		ns		ns		ns	
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	ns		ns		ns		ns		0,0011	0,0288	0,0010	0,0199	0,0019	0,0581
MO	ns		ns		ns		ns		ns		ns		-0,6009	0,0084
ds	ns		-0,0903	0,0951	0,4415	0,0308	0,3867	0,0763	0,3753	0,0704	-0,1160	0,2255	0,1475	0,3489
dp	ns		ns		-0,2559	0,0145	-0,2337	0,0388	-0,2154	0,0194	ns		-0,1344	0,0303
η	0,9932	0,9975	ns		1,3053	0,1264	1,0960	0,0195	1,0646	0,0185	ns		0,7903	0,0109
R ²		0,9975		0,0951		0,1717		0,1346		0,1371		0,2454		0,4566

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

4.2.13 Estimativa da retenção de água para classe de solo geral

Na Tabela 30 são apresentadas as FPTs geradas para estimativa da umidade do solo nos diferentes potenciais estudados, para o conjunto de dados geral. As equações de regressão linear múltipla apresentaram R^2 significativos para atributos texturais, estruturais e mineralógico do solo. Nos potenciais maiores, de 0 a -100 kPa, as variáveis estruturais apresentaram maior contribuição na composição das equações, com destaque para a η , com valores de R^2 parciais de 0,8221, 0,3188, 0,2470, 0,1514 e 0,0946, respectivamente. Para os potenciais menores, de -500 e -1500 kPa, embora as FPTs também sejam constituídas pelas variáveis estruturais, as maiores contribuições foram pelas variáveis texturais, por meio do teor de argila, em ambos os potenciais, com valores de R^2 parciais de 0,0986 e 0,1531, respectivamente.

Resultados semelhantes foram encontrados por Michelin et al. (2010), os mesmos observaram que alguns atributos estruturais do solo apresentaram alta correlação com a retenção de água, especialmente em potenciais mais elevados. De acordo com Hillel (1998) e Assad et al. (2001), em elevados potenciais matriciais, as forças capilares são mais atuantes e, nesses potenciais, a retenção de água é influenciada, pela estrutura do solo. Por outro lado, em potenciais mais baixos, a retenção de água no solo depende dos fenômenos de adsorção, os quais são mais influenciados pela textura e superfície específica das partículas.

Valores de R^2 superiores, foram obtidos por Oliveira et al (2002) considerando as frações areia, silte, argila e ds para a estimativa do conteúdo de água de solos no Estado de Pernambuco. Estes autores encontraram valores de R^2 de 0,96, 0,96, e 0,89, para as equações que estimaram o conteúdo de água nos potenciais de -33 kPa (silte e argila), -1.500kPa (areia, silte, argila e ds) e água disponível (areia, silte, argila e ds), respectivamente.

Em solos do noroeste do Paraná, sob sistemas de manejo com cobertura permanente em citros, Fidalski e Tormena (2007) desenvolveram FPT para a determinação da curva de retenção de água a partir da ds, carbono orgânico e da cobertura vegetal (gramínea, leguminosa e vegetação espontânea). Estes encontraram valor para o R^2 de 0,94.

Tabela 30 – Equações de regressão linear múltipla para estimativa da umidade retida ($\text{cm}^3.\text{cm}^{-3}$) a diferentes potenciais matriciais, para o conjunto de dados geral e respectivo coeficiente de determinação

Variáveis	Potencial (kPa)													
	0		-6		-10		-33		-100		-500		-1500	
	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial	Coef.	R ² - parcial
Intersec.	-0,0206		0,0617		0,0614		0,0628		0,0379		0,0359		-0,0763	
Argila	ns		ns		ns		ns		0,0006	0,0206	0,0012	0,0986	0,0017	0,1531
Silte	ns		ns		ns		ns		ns		ns		ns	
Areia	-0,0206	0,0064	-0,0005	0,0137	-0,0006	0,0223	-0,0005	0,0139	ns		ns		ns	
MO	-0,0206	0,0005	ns		-0,0830	0,0050	-0,0734	0,0038	-0,0644	0,0030	ns		ns	
ds	0,0159	0,0010	ns		ns		ns		ns		ns		0,0540	0,0072
dp	ns		0,0299	0,0134	0,0365	0,0188	0,0398	0,0223	0,0382	0,0222	0,0277	0,0105	ns	
η	0,9940	0,8221	0,4985	0,3188	0,4337	0,2470	0,3353	0,1514	0,2476	0,0946	0,1620	0,0302	0,3004	0,0240
R ²		0,8300		0,3459		0,2931		0,1914		0,1404		0,1393		0,1843

Coef.= coeficiente da equação; Argila (%), Silte (%) e Areia (%); MO – matéria orgânica (%); Ds - densidade do solo (g cm^{-3}); Dp - densidade de partículas (g cm^{-3}); η - porosidade total; ns - não significativo a 5%.

Na Figura 20 é ilustrado os resultados da correlação entre os dados observados e preditos, correspondentes ao conteúdo de água nos diferentes potenciais estudados. O coeficiente de determinação de aproximadamente 20%, indica que as equações propostas apresentam baixa capacidade preditiva. Embora a distribuição dos valores de umidade em relação à reta 1:1, não apresenta uma tendência muito clara, nota-se tanto para menores, quanto para maiores valores de umidade do solo a tendência das FPTs de subestimar a umidade do solo, enquanto que para os valores intermediários de umidade, observa-se a tendência de superestimativa.




Figura 20 - Valores de umidade volumétrica observados na literatura e preditos com regressão linear múltipla, para o banco de dados geral

Através da interpretação conjunta do desempenho das FPTs, geradas por regressão linear múltipla, apresentados desde a Tabela 18 até a Tabela 30, e pelas Figuras 8 à 20, observou-se uma forte relação das equações preditivas do conteúdo de água no solo, nas tensões mais elevadas, com os atributos texturais do solo, enquanto que nas baixas tensões, as correlações são mais expressivas com os dados estruturais do solo. Também é possível verificar a presença de valores

anômalos (pontos distantes da linha principal 1:1), nas distintas classes texturais analisadas. Estes valores contribuíram negativamente para a eficiência das FPTs, uma vez que acarretaram em baixos valores de coeficiente de correlação (R^2), exceção feita para as classes texturais arenoso e argilo siltoso, onde foi observado valor de R^2 superior a 70%, o que, segundo classificação de Garcia (1989), é considerado um bom ajuste entre as variáveis comparadas.

Os valores de R^2 , para as FPTs geradas, variam de 0,1781 (classe de solo arenoso franco) à 0,7471 (classe argilo siltoso), ficando abaixo dos obtidos por Oliveira et al (2002), Fidalski e Tormena (2007) e Reichert (2009).

No entanto, os resultados corroboram parcialmente com o trabalho realizado por Marcolin (2009) em solos sob plantio direto no Estado do Rio Grande do Sul. O autor estabeleceu funções de estimativa da CC e do PMP, verificando que para a CC a função pode ser obtida a partir dos teores de argila e valores de ds, apresentando um valor de R^2 de 0,69. Para o PMP foram empregados para o estabelecimento da função os valores do conteúdo de matéria orgânica, teores de argila e silte e ds, sendo obtido um valor R^2 de 0,937. Michelon et al (2010) obtiveram FPTs, em solos de áreas irrigadas por aspersão no estado do Rio Grande do Sul a 0kPa, -1kPa, -33kPa, -100kPa, -500kPa e -1.500kPa, com correlação entre dados observados e estimados entre 0,71 (-500kPa) e 0,93 (-33kPa). Ambas as funções foram estabelecidas por meio de regressão linear múltipla.

4.3 FPTs pontuais obtidas por redes neurais artificiais

Primeiramente, a fim de definir quais variáveis de entrada seriam utilizadas no treinamento das diferentes arquiteturas de RNAs, foram realizados treinamentos preliminares, alterando o número de neurônios (variáveis) na camada de entrada. Foi constatado, nestes treinamentos, que para ambas as variáveis de entrada, os erros de estimativa foram pequenos, com valores muito próximos entre as arquiteturas testadas (Apêndice A, Apêndice B, Apêndice C, Apêndice D, Apêndice E e Apêndice F). Desta maneira, foi selecionada, para geração das FPTs, as arquiteturas com o menor número de variáveis na camada de entrada, ou seja, quatro variáveis de entrada (argila, silte, areia e ds).

Dentre as diferentes arquiteturas de redes treinadas, escolheu-se com base no menor erro relativo médio e variância, para os dados de teste, uma única rede para cada classe de solo.

4.3.1 Estimativa da retenção de água para classe de solo arenoso

Conforme observa-se no Apêndice G, a arquitetura da RNA que melhor estimou o conteúdo de água no solo arenoso, para os diferentes potenciais, foi com 15 neurônios na camada intermediária.

A seguir, na Figura 21, é apresentado o gráfico que apresenta a correlação entre os valores de umidade observados e os estimados. Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela RNA, para o conteúdo de água no solo, se distribuiu de forma linear e forma um ângulo de 45° , sobre a reta que passa na origem dos eixos, o que corresponde ao coeficiente de determinação igual a 1. Resultados, estes, semelhantes aos de Netto (2007), que para solos do município de São Carlos (SP), observou alto desempenho da RNA na estimativa de retenção de água no solo, uma vez que estas conseguiram expressar, entre 92% e 93%, da variação da retenção de água no solo.

Na literatura, vários são os trabalhos que mostram que as RNAs apresentam alto poder preditivo. A exemplo cita-se: Vieira et al. (2009) apresentaram um trabalho cujo objetivo foi definir um procedimento de classificação automática, utilizando redes neurais artificiais, para identificação de áreas cafeeiras em imagens de satélite, foi aplicada uma rede neural artificial treinada para discriminar classes de uso da terra na classificação de dados de sensoriamento remoto; Chagas et al. (2009) avaliaram a eficiência de redes neurais artificiais na classificação do uso da terra, a partir de imagens de um sensor, com ênfase nos níveis de degradação das pastagens; a utilização de imagens aéreas, obtidas à baixa altura, para o mapeamento da infestação de plantas invasoras em cultura de soja, foi realizada por Neto et al. (2005), utilizando a classificação digital de imagens realizada por redes neurais. A foto foi classificada segundo as classes temáticas “cultura”, “invasora” e “entrelinha”. Ambos, os trabalhos demonstraram que o uso de RNAs, para estimativa de variáveis, apresenta alta capacidade preditiva.




Figura 21 - Valores de umidade volumétrica observados na literatura e preditos com a rede2

4.3.2 Estimativa da retenção de água para classe de solo arenoso franco

A arquitetura com 50 neurônios na camada escondida foi a que apresentou melhor capacidade preditiva do conteúdo de água no solo, para a classe de solo arenoso franco nos diferentes potenciais matriciais (Apêndice H).

A relação 1:1, entre os dados observados, presentes no banco de dados da respectiva classe textural, e os estimados pela RNA, são apresentados na Figura 22. A não existência de dispersão dos dados em relação à linha 1:1 e, o alto coeficiente de determinação ($R^2=1.0$), indicando que a RNA, com a arquitetura de 4-50-7, apresentou boa capacidade preditiva do conteúdo de água do solo, nos potenciais analisados.




Figura 22 - Valores de umidade volumétrica observados na literatura e preditos com a rede3

4.3.3 Estimativa da retenção de água para classe de solo argilo arenoso

Dentre as diversas arquiteturas treinadas, para a rede4, a que melhor capacidade preditiva expressou foi com 50 neurônios na camada escondida, (Apêndice I). A partir da validação da respectiva arquitetura, foi realizada a comparação entre os valores do conteúdo de água no solo estimados pela mesma, com os dados obtidos na literatura (Figura 23). O coeficiente de determinação encontrado, ajustado foi 0,9645, significando que 96% da variação total é explicada pela RNA treinada. De acordo com o exposto, pode-se dizer que os conjuntos de dados são similares e, conseqüentemente, a função de pedotransferência baseada em redes neurais apresentou uma boa capacidade de estimar a retenção de água no solo.

Os pontos do diagrama de dispersão apresentam-se dispostos próximos da reta 1:1, significando que os valores estimados pela rede neural foram similares aos medidos.




Figura 23 - Valores de umidade volumétrica observados na literatura e preditos com a rede4

4.3.4 Estimativa da retenção de água para classe de solo argilo siltoso

Dentre as diversas arquiteturas treinadas, para a rede5, a que melhor capacidade preditiva expressou, foi com 18 neurônios na camada escondida, (Apêndice J).

A relação entre o conteúdo de água nos diferentes potenciais matriciais estimados pela arquitetura 4-18-7, treinada na rede5, com os valores observados, é apresentada na Figura 24. Observa-se, que a respectiva RNA, apresentou ótima capacidade preditiva, para a variável estudada, com R^2 de 1.0, expressando exatidão na estimativa. Esses resultados encontrados, corroboram com Cagliari (2010). Esta autora observou que a função de pedotransferência baseada em redes neurais apresentou uma boa capacidade de estimar o fósforo remanescente no solo, com coeficiente de determinação (R^2) superior a 90%.




Figura 24 - Valores de umidade volumétrica observados na literatura e preditos com a rede5

4.3.5 Estimativa da retenção de água para classe de solo argiloso

Dentre as diversas arquiteturas treinadas, para a rede6, a que melhor capacidade preditiva expressou foi com 24 neurônios na camada escondida, (Apêndice K).

A relação entre o conteúdo de água nos diferentes potenciais matriciais estimados pela arquitetura (4-24-7) treinada na rede6, com os valores observados, é apresentada na Figura 25. Observa-se que os pontos do diagrama de dispersão apresentam-se dispostos próximos da reta 1:1, significando que os valores estimados pela rede neural foram similares aos medidos. O que também, pode ser confirmado pela proximidade do R^2 (0.8167) da unidade.




Figura 25 - Valores de umidade volumétrica observados na literatura e preditos com a rede6

4.3.6 Estimativa da retenção de água para classe de solo franco

A rede que apresentou melhor capacidade preditiva para a retenção de água no solo franco, foi com 35 neurônios na camada escondida (Apêndice L). A relação entre os valores estimados pela rede de arquitetura 4-35-7, com os valores observados para a respectiva classe textural, é apresentada na Figura 26.

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela rede, para o conteúdo de água no solo se distribuiu de forma homogênea em relação à reta 1:1, apresentando um R^2 de 0.9375. Indicando que a rede treinada apresenta alta capacidade preditiva para a variável estudada.

Resultados estes, semelhantes aos obtidos por Mathias et al. (2009), que através do uso de RNAs, propuseram um novo modo para definir relações entre variáveis meteorológicas e o molhamento foliar por orvalho. Estes observaram grau de exatidão entre 73,96% a 96,40%, para reconhecer padrões em dados de variáveis meteorológicas visando estimar o molhamento foliar originado por orvalho.




Figura 26 - Valores de umidade volumétrica observados na literatura e preditos com a rede7

4.3.7 Estimativa da retenção de água para classe de solo franco arenoso

Dentre as diversas arquiteturas treinadas, para a rede8, a que melhor capacidade preditiva expressou foi com 40 neurônios na camada escondida, (Apêndice M).

A relação entre o conteúdo de água nos diferentes potenciais matriciais estimados pela arquitetura (4-40-7) treinada na rede8, com os valores observados, é apresentada na Figura 27. Nota-se que os pontos do diagrama de dispersão apresentam-se dispostos próximos da reta 1:1, com R^2 de 0.8068, significando que os valores estimados pela rede neural foram similares aos medidos.

Os resultados corroboram com Jana et al. (2012), Jana e Mohanty (2011, 2012) e Jana et al. (2008; 2007). Estes autores, através do uso de RNAs para estimativa de propriedades hidráulicas do solo, observaram que o método apresenta alta capacidade preditiva, além de superar os métodos padrões de estimativa.




Figura 27 - Valores de umidade volumétrica observados na literatura e preditos com a rede8

4.3.8 Estimativa da retenção de água para classe de solo franco argilo arenoso

Dentre as diversas arquiteturas treinadas, para a rede9, a que melhor capacidade preditiva expressou foi com 18 neurônios na camada escondida, (Apêndice N).

A relação entre os valores estimados pela rede neural artificial (4-18-7) e os observados, durante a etapa de validação está apresentada na Figura 28. O coeficiente de determinação encontrado ajustado foi de 0,8321. De acordo com o exposto, pode-se dizer que os conjuntos de dados são similares e, conseqüentemente, a RNA treinada apresentou uma boa capacidade de estimar o conteúdo de água no solo nos diferentes potenciais avaliados. Estes resultados corroboram com Bucene e Rodrigues (2004), que treinaram diferentes arquiteturas de RNAs, visando classificar terras para irrigação, observando que a metodologia aplicada apresentou desempenho satisfatório, uma vez que a rede obteve 78% dos resultados iguais aos desejados.

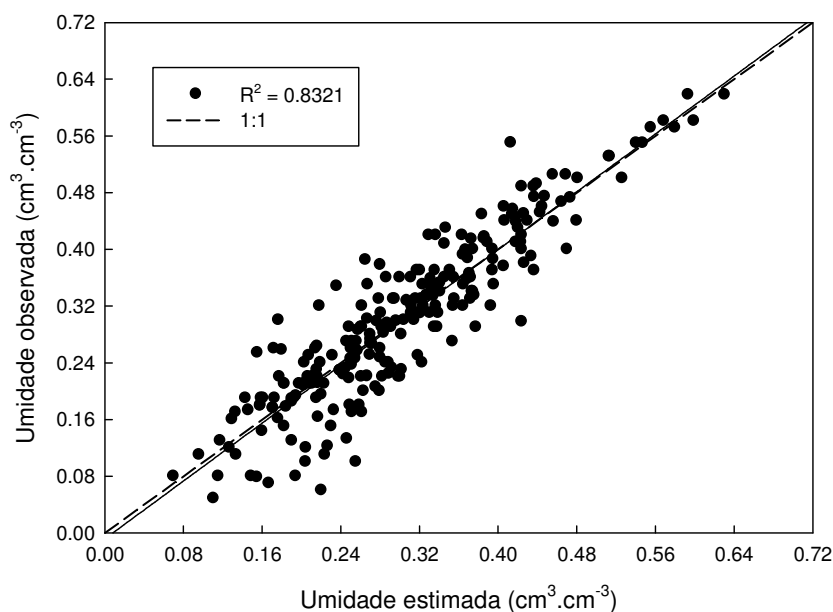


Figura 28 - Valores de umidade volumétrica observados na literatura e preditos com a rede9

4.3.9 Estimativa da retenção de água para classe de solo franco argilo siltoso

Dentre as diversas arquiteturas treinadas, para a rede10, a que melhor capacidade preditiva expressou foi com 35 neurônios na camada escondida, (Apêndice O).

A relação entre o conteúdo de água nos diferentes potenciais matriciais estimados pela arquitetura (4-35-7) treinada na rede10, com os valores observados, é apresentada na Figura 29. Observa-se que a RNA treinada, apresentou ótima capacidade preditiva, para a variável estudada, com R^2 de 1.0, expressando exatidão na estimativa.

A observação da forma de distribuição dos valores oriundos do ajustamento dos valores de retenção de água no solo, permite deduzir que a estimativa da retenção de água no solo, nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, pela RNA de arquitetura 4-35-7 não difere do método padrão (método direto), no banco de dados utilizado nesta classe textural.




Figura 29 - Valores de umidade volumétrica observados na literatura e preditos com a rede10

4.3.10 Estimativa da retenção de água para classe de solo franco argiloso

Dentre as diversas arquiteturas treinadas, para a rede11, a que melhor capacidade preditiva expressou foi com 30 neurônios na camada escondida, (Apêndice P).

A relação entre o conteúdo de água nos diferentes potenciais matriciais estimados pela arquitetura (4-30-7) treinada na rede11, com os valores observados, é apresentada na Figura 30. Observa-se que distribui-se de forma linear e forma um ângulo de 45° , sobre a reta que passa na origem dos eixos, o que corresponde o coeficiente de determinação igual a 1. Esta observação, permite deduzir que a determinação da retenção de água no solo, nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, pela RNA de arquitetura 4-30-7 não difere do método padrão (método direto), no banco de dados utilizado nesta classe textural.




Figura 30 - Valores de umidade volumétrica observados na literatura e preditos com a rede11

4.3.11 Estimativa da retenção de água para classe de solo franco siltoso

A rede que apresentou melhor capacidade preditiva para a retenção de água no solo franco siltoso, foi com 30 neurônios na camada escondida (Apêndice Q). A relação entre os valores estimados pela rede de arquitetura 4-30-7, com os valores observados para a respectiva classe textural, é apresentada na Figura 31. Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela rede, para o conteúdo de água no solo se distribuiu de forma homogênea em relação à reta 1:1, apresentando um R^2 de 0.9798. Indicando que a rede treinada apresenta alta capacidade preditiva para a variável estudada.

A observação da forma de distribuição dos valores oriundos do ajustamento dos valores de retenção de água no solo, na Figura 31, permite deduzir que a determinação da retenção de água no solo, nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, pela RNA de arquitetura 4-30-7 não difere do método padrão (método direto), no banco de dados utilizado nesta classe textural.

Vários autores, também observaram, quando trabalhando com RNAs, para estimativa de variáveis, que a mesma apresenta alta capacidade preditiva, com os valores estimados muito próximo dos observados (BUCENE e RODRIGUES, 2004; NAGAOKA, et al., 2005; NASCIMENTO, 2007; NETTO, 2007; JANA et al., 2008; MATHIAS et al., 2009).




Figura 31 - Valores de umidade volumétrica observados na literatura e preditos com a rede12

4.3.12 Estimativa da retenção de água para classe de solo muito argiloso

A rede que apresentou melhor capacidade preditiva para a retenção de água no solo muito argiloso, foi com 21 neurônios na camada escondida (Apêndice R). A relação entre os valores estimados pela rede de arquitetura 4-21-7, com os valores observados para a respectiva classe textural, é apresentada na Figura 32. Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela rede, para o conteúdo de água no solo se distribuiu de forma homogênea em relação à reta 1:1 (R^2 de 0.9285), em toda a concentração de dados, tanto nas menores

quanto nas maiores umidades. Indicando que a rede treinada apresenta alta capacidade preditiva para a variável estudada.

A observação da forma de distribuição dos valores oriundos do ajustamento dos valores de retenção de água no solo, na Figura 32, permite deduzir que a determinação da retenção de água no solo, nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, pela RNA de arquitetura 4-21-7 não difere do método padrão (método direto), no banco de dados utilizado nesta classe textural.




Figura 32 - Valores de umidade volumétrica observados na literatura e preditos com a rede13

4.3.13 Estimativa da retenção de água para o banco de dados geral

A rede que apresentou melhor capacidade preditiva para a retenção de água dos solos do Estado do Rio Grande do Sul, treinadas a partir do banco de dados geral, foi com 27 neurônios na camada escondida (Apêndice S).

A relação entre os valores estimados pela rede de arquitetura 4-27-7, com os valores observados para o respectivo banco de dados, é apresentada na Figura 33.

Observa-se que o ajustamento dos valores obtidos na literatura com os estimados pela rede, para o conteúdo de água no solo, não distribuiu-se de forma homogênea, em relação a reta 1:1, embora, de acordo com Garcia (1989), haja um bom ajuste entre as variáveis, uma vez que o valor de R^2 foi superior a 70%.




Figura 33 - Valores de umidade volumétrica observados na literatura e preditos com a rede1

A observação da forma de distribuição dos valores oriundos do ajustamento dos valores de retenção de água no solo, na Figura 33, permite deduzir que a determinação da retenção de água no solo, nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, pela RNA de arquitetura 4-27-7 não difere do método padrão (método direto), no banco de dados utilizado. Embora quando comparada com a capacidade preditiva das redes, dos demais bancos de dados, nota-se uma menor exatidão.

Fazendo-se uma síntese dos resultados observados desde a Figura 21 até a Figura 33, observa-se que as RNAs apresentam alta capacidade preditiva, para retenção de água no solo, nos diferentes potenciais matriciais estudados.

Na literatura são raros os casos em no momento da validação de uma FPTs, o R^2 apresente valor de 100%, deste modo quando observou-se nas Figura 21, Figura 22, Figura 24, Figura 29 e Figura 30, induziu-se a pensar que a rede treinada para as respectivas classes texturais, apresentou o problema de *overfitting*, uma vez que o número de dados utilizados no processo de treinamento estava abaixo das demais classes de solo. Entretanto, Nagaoka (2003) em seu trabalho mostrou que o fato de treinar redes com grande quantidade de padrões de treinamento, não garante a obtenção de resultados precisos. Esta autora quando treinou redes com pouca quantidade de dados, observou que as mesmas não apresentavam capacidade de generalizar, ou seja baixo valo de R^2 .

Os resultados dos ajustes obtidos são consistentes com os de vários autores, sumarizados por Moreira et al. (2006), neste os autores treinaram RNAs para estimar a erosividade da chuva no Estado de São Paulo, e analisaram a acurácia desta com o método de interpolação “Inverso de uma Potência da Distância”. Comparando a RNA desenvolvida com o método de interpolação, os autores verificam que a primeira apresentou menor erro relativo médio na estimativa da erosividade e melhor índice de confiança, classificado como “Ótimo”, podendo, portanto, ser utilizada no planejamento de uso, manejo e conservação do solo no Estado de São Paulo.

Ainda, em 2008, Moreira e colaboradores, desenvolveram RNAs para a estimativa mensal da erosividade da chuva no Estado de Minas Gerais. Utilizaram-se dados de erosividade da chuva, latitude, longitude e altitude de 268 estações pluviométricas situadas no Estado e em seu entorno. A análise dos resultados possibilitou aos autores verificarem que as RNAs desenvolvidas foram eficientes para estimativa mensal da erosividade da chuva, constituindo alternativa viável para a obtenção desses valores, para qualquer localidade do Estado.

Silva et al. (2004) concluiu que o uso de redes MLP treinadas com o algoritmo *backpropagation* mostrou seu grande potencial para a recomendação de adubação correta de fósforo, para a cultura da goiabeira, levando-se em consideração princípios da agricultura de precisão. Jana et al. (2007) treinou redes neurais utilizando dados de textura e densidade do solo, com o objetivo de desenvolver uma função de pedotransferência para prever parâmetros da equação de Van Genuchten, a fim de obter a curva de retenção de água no solo. Neste estudo, as

curvas de retenção de água construídas pela RNA apresentaram-se semelhantes aquelas observadas em campo.

Wang et al. (2006) estudaram a distribuição espacial da poluição de águas subterrâneas por nitrato. O desempenho da rede foi mensurado por meio do coeficiente de determinação. Neste estudo, a RNA com arquitetura, 4-7-1 e algoritmo de aprendizagem *backpropagation*, apresentou bom desempenho, $R^2 = 0,77$, na etapa de validação. Jana e Mohanty (2012) utilizaram quatro metodologias para estimativa de parâmetros hidráulicos do solo (α , θ_r , θ_s , n , k_s). Os autores concluíram que as RNAs foram capazes de capturar a maior parte da variação de parâmetros hidráulicos do solo.

Ainda, Jana e Mohanty (2012), visando estimar parâmetros hidráulicos do solo, desenvolveram um algoritmo baseado em RNAs. A comparação entre os valores medidos a campo e o estimados, pelas redes neurais, para a umidade de saturação (θ_s), umidade residual (θ_r) e condutividade hidráulica saturada (k_s), apresentou coeficiente de correlação superior a 60%. Os autores concluíram que o uso desta metodologia é aplicável a região de estudo (Novo México/Texas), devido ao elevado valor de correlação.

Comparações entre conteúdo de água no solo para os potenciais de 0 e - 0.33bar, estimados por RNAs com os obtidos por metodologia direta são apresentados por Jana et al (2008) e Jana e Mohanty (2011). Em ambos o trabalhos os autores concluíram que a metodologia proposta é um alternativa para estimativa da retenção de água nos solos, uma vez que os coeficientes de correlação foram superiores a 93%.

4.4 Desempenho das FPTs geradas por classes texturais

A seguir serão apresentados os desempenhos das FPTs, geradas por classes texturais, a partir do uso de RLM e RNAs. O banco de dados geral foi subdividido pelas características texturais, a fim de formar subconjuntos mais homogêneos, uma vez que as funções de pedotransferência tendem a ser tão mais acuradas, quanto mais homogêneos forem os solos que compõem a base de dados, e quão mais

próximos destes estiverem os que terão seus dados estimados (SALCHOW et al., 1996; PACHEPSKY e RAWLS, 1999; OLIVEIRA et al., 2002).

4.4.1 FPTs por classes, obtidas por RLM

Os valores do coeficiente de correlação, índice de concordância, índice e classificação do desempenho, obtidos a partir da comparação entre os valores de umidade de água no solo observados, em cada classe textural, com os estimados, para as respectivas classes, pelas FPTs geradas em sua própria classe, e pelas FPTs desenvolvidas para o banco de dados geral, são apresentados na Tabela 31.

Nota-se, para ambas as classes texturais, que as FPTs geradas na própria classe, para qual foram validadas, apresentaram maior capacidade preditiva da umidade de água no solo, comparada com a estimativa utilizando as FPTs geradas no banco de dados geral (FPTs geral).

Deste modo observa-se que a geração de FPTs agrupadas por classes texturais semelhantes, se mostrou importante na estimativa da retenção de água em solos do Estado do Rio Grande do Sul. As estimativas da retenção de água, em todas as classes texturais, apresentaram maior desempenho quando estimadas pelas FPTs geradas em sua própria classe de solo. No entanto o desempenho, das mesmas, foram inferiores a “muito bom”, exceto para a classe argilo siltoso, onde o desempenho obtido pelo uso das FPTs foi “muito bom”. Já, o desempenho pelo uso das FPTs geradas no banco de dados geral, foi classificado como “péssimo”, em todas as classes de solo, exceção feita para a classe de solo argilo siltoso, onde o desempenho foi “muito fraco”.

Esta tendência corrobora com a obtida por Salchow et al (1996) e Pachepsky e Rawls (1999), que obtiveram melhorias consideráveis após agruparem os solos em categorias mais uniformes. Estes autores utilizaram, dentre outros critérios, a classe textural na categorização de seus dados. Os mesmos destacam que as funções de pedotransferência tendem a ser tão mais acuradas quanto mais homogêneos forem os solos que compõem a base de dados, e quão mais próximos destes estiverem os que terão seus dados estimados.

Tabela 31 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, nos diferentes métodos de estimativa da retenção de água no solo

Método	c	r	id	Desempenho
Are x FPTs geral	0.0269	-0.4846	-0.0131	Péssimo
Are x FPTs Are	0.8743	0.8470	0.7406	Bom
AF x FPTs geral	0.0491	-0.3277	-0.0161	Péssimo
AF x FPTs AF	0.9091	0.4227	0.3842	Péssimo
ArgAre x FPTs geral	0.0366	-0.7491	-0.0274	Péssimo
ArgAre x FPTs ArgAre	0.7302	0.5352	0.3908	Péssimo
ArgS x FPTs geral	0.7213	0.6532	0.4711	Muito Fraco
ArgS x FPTs ArgS	0.9343	0.8642	0.8075	Muito Bom
Arg x FPTs geral	0.1562	-0.3729	-0.0582	Péssimo
Arg x FPTs Arg	0.8557	0.7586	0.6491	Regular
F x FPTs geral	0.1931	-0.2140	-0.0413	Péssimo
F x FPTs F	0.8728	0.8104	0.7073	Bom
FAre x FPTs geral	0.0836	-0.2597	-0.0217	Péssimo
FAre x FPTs FAre	0.8315	0.7417	0.6167	Regular
FArgAre x FPTs geral	0.1016	-0.3242	-0.0329	Péssimo
FArgAre x FPTs FArgAre	0.7526	0.6278	0.4725	Muito Fraco
FArgS x FPTs geral	0.6433	0.4871	0.3134	Péssimo
FArgS x FPTs FArgS	0.8386	0.5049	0.4234	Muito Fraco
Farg x FPTs geral	0.1962	-0.2509	-0.0492	Péssimo
Farg x FPTs Farg	0.8286	0.7365	0.6103	Regular
FS x FPTs geral	0.3821	-0.0275	-0.0105	Péssimo
FS x FPTs FS	0.9082	0.8298	0.7536	Bom
MArg x FPTs geral	0.5935	0.3323	0.1973	Péssimo
MArg x FPTs MArg	0.8550	0.7495	0.6408	Regular

Resultados semelhantes foram descritos por Nebel (2009). O autor observou que FPTs geradas especificamente para solos de várzeas da região sul do Brasil, apresentaram maior capacidade preditiva, do que, quando estimadas por FPTs publicadas na literatura. Segundo o autor, isto deve-se a baixa homogeneidade do banco de dados, assim como, pela baixa representatividade do banco de dados que originaram estas FPTs, com as características dos solos de várzeas. Para Costa (2012), as FPTs pontuais devem ser utilizadas separadamente para cada horizonte do solo (superficiais e subsuperficiais), para uma melhor estimativa da retenção e disponibilidade de água dos solos do Estado de Santa Catarina. O mesmo observou que as FPTs geradas por classe texturais, estimaram adequadamente a curva de

retenção de umidade do solo para a maioria das classes texturais dos solos do Estado.

Estes resultados apóiam a recomendação de Minasny et al. (2003), de que, a validade de uma determinada FPT não deve ser interpolada ou extrapolada além do ambiente pedológico ou tipo de solo em que a mesma foi desenvolvida.

No entanto este resultados divergem dos encontrados por Oliveira et al. (2002), estes observaram que o agrupamento dos dados em subconjuntos baseado na classe textural ou na atividade da fração argila, de maneira geral, não produziu melhorias consideráveis na capacidade preditiva das pedofunções quanto à reunião dos dados num conjunto único.

As comparações entre os valores de umidade de água no solo, observados, nas diferentes classes texturais analisadas, com os estimados pelas FPTs desenvolvidas para a respectiva classe textural, e pelas FPTs geradas para o banco de dados geral, são apresentadas nas Figura 34, Figura 35, Figura 36, Figura 37, Figura 38, Figura 39, Figura 40, Figura 41, Figura 42, Figura 43, Figura 44 e Figura 45.




Figura 34 - Comparação entre valores de umidade do solo observados, na classe Are, e estimados pelas FPTs geral e FPTs Are




Figura 35 - Comparação entre valores de umidade do solo observados, na classe AF, e estimados pelas FPTs geral e FPTs AF




Figura 36 - Comparação entre valores de umidade do solo observados, na classe ArgAre, e estimados pelas FPTs geral e FPTs ArgAre




Figura 37 - Comparação entre valores de umidade do solo observados, na classe ArgS, e estimados pelas FPTs geral e FPTs ArgS




Figura 38 - Comparação entre valores de umidade do solo observados, na classe Arg, e estimados pelas FPTs geral e FPTs Arg




Figura 39 - Comparação entre valores de umidade do solo observados, na classe F, e estimados pelas FPTs geral e FPTs F




Figura 40 - Comparação entre valores de umidade do solo observados, na classe FAre, e estimados pelas FPTs geral e FPTs FAre




Figura 41 - Comparação entre valores de umidade do solo observados, na classe FArgAre, e estimados pelas FPTs geral e FPTs FArgAre

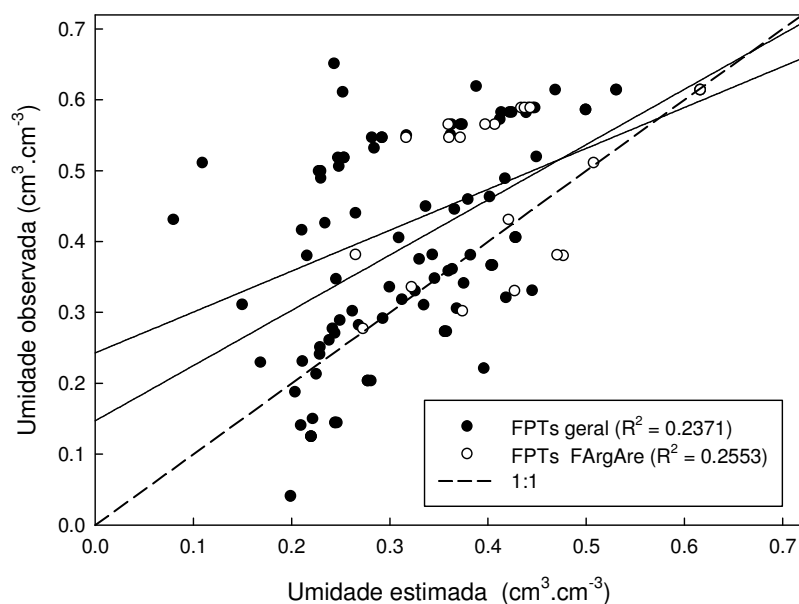


Figura 42 - Comparação entre valores de umidade do solo observados, na classe FArgS, e estimados pelas FPTs geral e FPTs FArgS




Figura 43 - Comparação entre valores de umidade do solo observados, na classe FArg, e estimados pelas FPTs geral e FPTs FArg




Figura 44 - Comparação entre valores de umidade do solo observados, na classe FS, e estimados pelas FPTs geral e FPTs FS




Figura 45 - Comparação entre valores de umidade do solo observados, na classe MArg, e estimados pelas FPTs geral e FPTs MArg

Observa-se a partir das figuras acima, que o agrupamento do conjunto total de dados em subconjuntos, por classes texturais dos solos do Estado do Rio Grande do Sul, geralmente produziu melhorias na capacidade preditiva das FPTs. Van Genuchten (1980); Wösten et al. (1990); Wösten et al. (1995); Salchow et al. (1996) e Pachepsky e Rawls (1999) concordam com a melhoria na predição da umidade com dados mais homogêneos, já que eles obtiveram consideráveis aumentos de coeficiente de predição após agruparem os solos em categorias mais uniformes.

Observa-se um melhor ajuste dos valores observados com os estimados pelas FPTs de cada classe textural, uma vez que os dados apresentam menor dispersão em relação a reta 1:1. Enquanto que para os valores estimados, em ambas as classes de solo, pelas FPTs do banco de dados geral, nota-se uma maior heterogeneidade em relação a reta 1:1, o que pode ser comprovado a partir dos valores dos coeficientes de determinação. No entanto, segundo a classificação de Garcia (1989), somente as FPTs, geradas para estimar a umidade de água nos solos arenoso e argilo siltoso, apresentaram um bom ajuste, com valor de R^2 superior a 70%.

4.4.2 FPTs por classes, obtidas por RNAs

São apresentados na Tabela 32, os valores do coeficiente de correlação, índice de concordância, índice e classificação do desempenho, obtidos a partir da comparação entre os valores de umidade de água no solo observados, em cada classe textural, com os estimados, para as respectivas classes, pelas redes treinadas em sua própria classe, e pela rede1, obtida no banco de dados geral.

Tabela 32 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, nos diferentes métodos de estimativa da retenção de água no solo

Método	c	r	id	Desempenho
Are x rede 1	0.8548	0.7806	0.6673	Bom
Are x rede 2	0.9993	0.9987	0.9980	Ótimo
AF x rede 1	0.8440	0.8505	0.7179	Bom
AF x rede 3	1.0000	1.0000	1.0000	Ótimo
ArgAre x rede 1	0.8862	0.8305	0.7360	Bom
ArgAre x rede 4	0.9858	0.9722	0.9584	Ótimo
ArgS x rede 1	0.8947	0.8403	0.7518	Bom
ArgS x rede 5	1.0000	1.0000	1.0000	Ótimo
Arg x rede 1	0.8922	0.8224	0.7338	Bom
Arg x rede 6	0.9141	0.8556	0.7821	Muito Bom
F x rede 1	0.8959	0.8176	0.7324	Bom
F x rede 7	0.9820	0.9664	0.9490	Ótimo
FAre x rede 1	0.8672	0.7843	0.6801	Bom
FAre x rede 8	0.9485	0.9056	0.8589	Ótimo
FArgAre x rede 1	0.8444	0.7549	0.6374	Bom
FArgAre x rede 9	0.9383	0.8863	0.8316	Muito Bom
FArgS x rede 1	0.7030	0.5075	0.3568	Péssimo
FArgS x rede 10	1.0000	1.0000	1.0000	Ótimo
FArg x rede 1	0.8793	0.7841	0.6895	Bom
FArg x rede 11	0.9608	0.9352	0.8986	Ótimo
FS x rede 1	0.9568	0.9194	0.8796	Ótimo
FS x rede 12	0.9939	0.9890	0.9830	Ótimo
MArg x rede 1	0.7797	0.6585	0.5134	Fraco
MArg x rede 13	0.9607	0.9241	0.8878	Ótimo

A partir da Tabela 32, nota-se em ambas as classes texturais, que as RNAs treinadas na própria classe, apresentam maior capacidade preditiva da umidade de água no solo, comparada com a estimativa utilizando a RNA treinada no banco de dados geral (rede1). Observa-se, que o treinamento de RNAs agrupadas por classes texturais semelhantes, se mostrou importante na estimativa da retenção de água em solos do Estado do Rio Grande do Sul. As estimativas da retenção de água, em todas as classes texturais, apresentaram maior desempenho quando estimadas pela rede treinada em sua própria classe de solo. Estas apresentaram desempenho “ótimo”, na aptidão de estimativa, exceto para as classes de solo argiloso e franco argilo arenoso que apresentaram desempenho “muito bom”. Enquanto, que o desempenho da rede1, para estimativa da variável nas diferentes classes texturais, obteve classificações, iguais e inferiores a “bom”, exceção feita para a classe franco siltoso onde o desempenho foi “ótimo”.

Estes resultados corroboram com a afirmativa de Tormasella e Hodnett (1998) e Tormasella et al. (2000), em que as FPTs tendem a ser mais apuradas quanto mais homogêneos forem os solos que compõem a base de dados. Bem como, com os resultados obtidos por Salchow et al. (1996) e Pachepsky e Rawls (1999), que obtiveram melhorias consideráveis após agruparem os solos em categorias mais uniformes. No entanto este resultados divergem dos encontrados por Oliveira et al. (2002), estes observaram que o agrupamento dos dados em subconjuntos mais homogêneos não acarretou em melhorias na capacidade preditiva das pedofunções.

As correlações lineares, observadas na Figura 46, Figura 47, Figura 48, Figura 49, Figura 50, Figura 51, Figura 52, Figura 53, Figura 54, Figura 55, Figura 56 e Figura 57, entre as umidades volumétricas medidas e preditas de ambas as RNAs treinadas, são outro indicativo do bom desempenho das redes treinadas por classes texturais.




Figura 46 - Comparação entre valores de umidade do solo observados, na classe Are, e estimados pela rede 1 e rede 2




Figura 47 - Comparação entre valores de umidade do solo observados, na classe AreF, e estimados pela rede 1 e rede 3




Figura 48 - Comparação entre valores de umidade do solo observados, na classe ArgAre, e estimados pela rede 1 e rede 4




Figura 49 - Comparação entre valores de umidade do solo observados, na classe ArgS, e estimados pela rede 1 e rede 5




Figura 50 - Comparação entre valores de umidade do solo observados, na classe Arg, e estimados pela rede 1 e rede 6




Figura 51 - Comparação entre valores de umidade do solo observados, na classe F, e estimados pela rede 1 e rede 7




Figura 52 - Comparação entre valores de umidade do solo observados, na classe FAre, e estimados pela rede 1 e rede 8




Figura 53 - Comparação entre valores de umidade do solo observados, na classe FArgAre, e estimados pela rede1 e rede9




Figura 54 - Comparação entre valores de umidade do solo observados, na classe FArgS, e estimados pela rede 1 e rede 10




Figura 55 - Comparação entre valores de umidade do solo observados, na classe FArg, e estimados pela rede 1 e rede 11




Figura 56 - Comparação entre valores de umidade do solo observados, na classe FS, e estimados pela rede 1 e rede 12




Figura 57 - Comparação entre valores de umidade do solo observados, na classe MArg, e estimados pela rede 1 e rede 13

Através das figuras acima, nota-se que o agrupamento dos dados em subconjuntos baseado na classe textural, produziu melhorias consideráveis na capacidade preditiva das pedofunções quanto à reunião dos dados num conjunto único, visto pelos elevados valores dos coeficientes de determinação observados em ambas as classes texturais.

Este aumento na exatidão da estimativa após a categorização dos dados, era esperado, uma vez que tal procedimento reuniu no mesmo grupo solos com similares relações de retenção de umidade (Pachepsky e Rawls, 1999). Tietje e Tapkenhinrichs (1993) sugeriram que o estabelecimento de PTFs separados para diferentes tipos de solo pode render maior desempenho.

Esta tendência confirma a obtida por Nascimento et al. (2010), que observaram melhorias na capacidade preditiva das FPTs a partir do agrupamento do conjunto total de dados em subconjuntos, por horizonte e por tipo de atividade química da argila (alta ou baixa). Tal efeito também foi constatado no trabalho de Costa (2012), o mesmo, notou, entre as diferentes FPTs gerada para os solos de Santa Catarina, as que melhor estimaram a retenção e disponibilidade de água foram aquelas ajustadas separadamente por classes texturais.

No entanto, pesquisadores como Oliveira et al. (2002) acharam que o agrupamento dos dados em subconjuntos baseado na classe textural, de maneira geral, não produziu melhorias consideráveis na capacidade preditiva das funções de pedotransferência. Da mesma forma, Peraza (2003) observou que o agrupamento dos dados em subconjuntos baseados na atividade da argila não produziu, melhorias consideráveis na correlação entre retenção de água com as variáveis granulométricas.

4.5 Comparação entre as FPTs desenvolvidas por RLM e RNAs

Na Tabela 33, é apresentada a comparação entre os métodos utilizados, para geração das FPTs, através dos valores de coeficiente de correlação, índice de concordância e índice de desempenho. Verifica-se pelos valores de desempenho que as RNAs apresentaram capacidade preditiva superior a RLM.

Tabela 33 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho, entre os diferentes métodos de estimativa da retenção de água no solo

Método	c	r	id	Desempenho
Are x RLM	0.8743	0.8470	0.7406	Bom
Are x RNAs	0.9993	0.9987	0.9980	Ótimo
AF x RLM	0.9091	0.4227	0.3842	Péssimo
AF x RNAs	1.0000	1.0000	1.0000	Ótimo
ArgAre x RLM	0.7302	0.5352	0.3908	Péssimo
ArgAre x RNAs	0.9858	0.9722	0.9584	Ótimo
ArgS x RLM	0.9343	0.8642	0.8075	Muito Bom
ArgS x RNAs	1.0000	1.0000	1.0000	Ótimo
Arg x RLM	0.8557	0.7586	0.6491	Regular
Arg x RNAs	0.9141	0.8556	0.7821	Muito Bom
F x RLM	0.8728	0.8104	0.7073	Bom
F x RNAs	0.9820	0.9664	0.9490	Ótimo
Fare x RLM	0.8315	0.7417	0.6167	Regular
FAre x RNAs	0.9485	0.9056	0.8589	Ótimo
FArgAre x RLM	0.7526	0.6278	0.4725	Muito Fraco
FArgAre x RNAs	0.9383	0.8863	0.8316	Muito Bom
FArgS x RLM	0.8386	0.5049	0.4234	Muito Fraco
FArgS x RNAs	1.0000	1.0000	1.0000	Ótimo
Farg x RLM	0.8286	0.7365	0.6103	Regular
FArg x RNAs	0.9608	0.9352	0.8986	Ótimo
FS x RLM	0.9082	0.8298	0.7536	Bom
FS x RNAs	0.9939	0.9890	0.9830	Ótimo
Marg x RLM	0.8550	0.7495	0.6408	Regular
MArg x RNAs	0.9607	0.9241	0.8878	Ótimo

Os resultados obtidos, para estimativa da retenção de água no solo nos potenciais de 0, -6, -10, -33, -100, -500 e -1500 kPa, indicam que o uso de regressão linear múltipla para desenvolver FPTs não foi uma boa escolha neste estudo (Tabela 33). Uma vez que o desempenho em ambas as classes texturais, teve classificações iguais e inferiores a “bom”, exceto para classe argilo siltoso em que o desempenho foi “muito bom”. Já para as estimativas da retenção de água no solo, obtidas por RNAs, o desempenho teve classificação “ótima”, na maioria das classes texturais estudadas, somente nas classes argiloso e franco argilo arenoso o desempenho foi inferior, sendo classificado como “muito bom”.

Os valores observados, nas estimativas por RNAs são semelhantes aos obtidos por Pachepsky et al. (1996). Estes autores quando compararam RNAs com equações de regressão para estimar a retenção de água, concluíram que as RNAs tiveram uma melhor performance que as regressões. Lakzian et al. (2010) observaram que a capacidade preditiva das RNAs foram superiores a RLM, quando desenvolveram FPTs comparando estas metodologias, para predição da umidade do solo nos potenciais de -33 e -1500 kPa, a partir das variáveis areia, silte argila e matéria orgânica.

Netto (2007) observou alto desempenho das RNAs na estimativa de retenção de água no solo, uma vez que estas conseguiram, explicar 93% da variação da retenção de água no solo. Resultados semelhantes aos de Picoli (2006) que estimou a produtividade da cana-de-açúcar com RNAs comparando-a com avaliações subjetivas dos técnicos da Usina. Esse autor concluiu que as RNAs estimaram com maior confiabilidade a produtividade agrícola, explicando 66% da variabilidade real. Silva (2002), treinando diferentes RNAs, observou que as mesmas mostram-se aplicáveis à previsão da evapotranspiração de referência.

Considerando a melhor capacidade preditiva das RNAs em relação a RLM, pode-se inferir que estas podem, assim como concluíram Minasny e McBratney (2002), serem aplicadas para predizer o conteúdo de água.

Estes resultados observados eram esperados, uma vez que em função de sua estrutura não-linear, as redes neurais artificiais conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais (GALVÃO et al., 1999). Para Sudheer et al. (2003), a maior vantagem das redes neurais artificiais sobre os métodos convencionais é que elas não requerem informação detalhada sobre os processos físicos do sistema a ser modelado.

Recentemente, com o advento das RNAs como técnicas de elevada capacidade preditiva, várias são as pesquisas, em que há comparação entre este método e os considerados tradicionais. Na literatura, embora escasso, encontra-se trabalhos com esses resultados, onde observa-se que as RNAs, em grande maioria das vezes superam as demais técnicas preditivas.

Em trabalho realizado por Cagliari (2010), o uso das redes neurais artificiais proporcionou melhores estimativas para o fósforo remanescente, do que a análise

de regressão linear múltipla, considerando-se um mesmo conjunto de dados e de variáveis preditoras.

Pachepsky et al. (1996) quando compararam RNAs com equações de regressão para estimar a retenção de água, concluíram que as RNAs tiveram uma melhor performance que as regressões.

Tamari et al. (1996) observaram maior eficiência da rede neural em relação à regressão multilinear quando os dados de condutividade hidráulica foram menores que $0,1 \text{ m s}^{-1}$, porém, acima de $0,2 \text{ m s}^{-1}$ foram menos eficientes que a regressão. Pachepsky et al. (1996) notaram que RNAs tiveram desempenho melhor que as regressões em potenciais matriciais entre $-0,1$ e -20 kJ m^{-3} ; no entanto, em potenciais maiores que esses as regressões foram melhores.

Resende e Oliveira (2010), obtiveram sucesso em seus estudos, quando buscaram aumentar a precisão da estimativa da evapotranspiração de referência, utilizando-se redes neurais artificiais para ajustar e prever a evapotranspiração de referência diária. França (2010) realizou uma classificação de uso do solo, visando uma política mais racional de planejamento territorial, urbano e ambiental, com a utilização de redes neurais artificiais, obteve índices de exatidão global satisfatórios.

Em Moreira e Cecílio (2008) foram desenvolvidas redes neurais artificiais para estimativa mensal e anual das temperaturas mínima, média e máxima do ar, na região Nordeste do Brasil. Em geral, as redes neurais artificiais desenvolvidas possibilitaram maior acurácia na estimativa das temperaturas do ar em comparação com as equações de regressão encontradas na literatura especializada.

A aplicação de redes neurais artificiais na tarefa de previsão da produção de álcool no Brasil, no ano de 2006, a partir de dados de produção anteriores, foi apresentada em Oliveira et al. (2010). Foi também apresentada uma comparação entre os resultados obtidos por meio da rede neural artificial com os obtidos utilizando-se técnicas de séries temporais, sendo que a rede neural artificial obteve melhores resultados.

Ainda, trabalhos publicados por Somaratne et al. (2005), apresentaram resultados semelhantes. Os autores compararam o desempenho das RNAs com o da RLM, na estimativa do teor de carbono orgânico em amostras de solo sob diferentes usos. Os resultados mostraram que a depender da forma de carbono considerada (total ou lábil) um procedimento de desenvolvimento (RNA ou RLM) pode ser mais indicado. No estudo de Parasuraman et al. (2007), o uso de RNA foi

comparado ao da programação genética (PG), para o desenvolvimento de uma FPT com o objetivo de estimar a condutividade hidráulica do solo. As variáveis preditoras utilizadas neste estudo foram: a densidade e os teores de areia, silte e argila dos solos. Os resultados do estudo mostraram que na etapa de treinamento e teste a RNA apresentou um desempenho melhor comparado à PG.

5 CONCLUSÃO

De acordo com a metodologia utilizada e para as condições em que o trabalho foi realizado pode-se concluir que:

- 1) A categorização dos dados de acordo com a classe textural produziu melhorias na capacidade preditiva das pedofunções, desenvolvidas tanto por regressão linear múltipla, quanto por redes neurais artificiais.
- 2) 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.
- 3) Para todas as redes neurais treinadas, a arquitetura com quatro neurônios na camada de entrada apresentou elevado índice de desempenho.
- 4) As arquiteturas das redes neurais artificiais com melhor desempenho nas etapas de treinamento e validação, nas diferentes classes texturais estudadas, apresentaram 4 neurônios na camada de entrada, 7 neurônios na camada de saída e diferentes neurônios na camada oculta, intermediária ou escondida.
- 5) O número de neurônios na camada oculta foram 15 para solo arenoso, 50 para solo arenoso franco, 50 para solo argilo arenoso, 24 para solo argiloso, 18 para solo argilo siltoso, 35 para solo franco, 40 para solo franco arenoso, 18 para solo franco argilo arenoso, 35 para solo franco argilo siltoso, 30 para solo franco argiloso, 30 para solo franco siltoso e 21 para solo muito argiloso.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, S. L.; REICHERT, J. M.; REINERT, D. J. Escarificação mecânica e biológica para a redução da compactação em Argissolo franco-arenoso sob plantio direto. **Revista Brasileira Ciência do Solo**, Viçosa, v. 28, p. 519-531, 2004.

AL-KHAFRAF, S.; HANKS, R. J. Evaluation of the filter paper method for estimating soil water potential. **Soil Science**, Philadelphia, v. 117, n. 4, p. 194-199, 1974.

ALTENDORF, C. T., et al. Development and validation of a neural network model for soil water content prediction with Comparison to Regression Techniques. **Transactions of the ASAE**, St. Joseph, v. 42, n. 3, p. 691-699, 1999.

AMERICAN SOCIETY FOR TESTING AND MATERIALS. **D5298-03: standard test method for measurement of soil potential (suction) using filter paper**. Philadelphia: [s.n.], 2003. 6 p.

ARRUDA, F. B.; ZULLO, L. R. J.; OLIVEIRA, J. B de. Parâmetros de solo para o cálculo da água disponível com base na textura do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v.11, p.11-15, 1987.

ARYA, L. M. et al. Scaling parameter to predict the soil water characteristic from particle-size distribution data. **Soil Science Society of America Journal**, Madison, v. 63, p.1063-1070, 1999.

ARYA, L. M.; PARIS, J. F. A physicoempirical model to predict the soil moisture characteristic from particle-size distribution and bulk density data. **Soil Science Society of America Journal**, Madison, v.45, p.1023-1030, 1981.

ASSAD, et al. Relação entre água retida e conteúdo de areia total em solos brasileiros. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 9, n. 3, p. 588-596, 2001.

ATTOH-OKINE, N. O.; FEKPE, E. K. Strength characteristics modeling of lateritic soils using adaptive neural networks. **Construction and building materials**, Great Britain, v.10, n. 8, p. 577-582, 1996.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. **Redes neurais com aplicações em controle e em sistemas especialistas**. 1º Ed. Florianópolis: Bookstore, 2000. 401p.

BAMBERG, A. L. **Atributos físicos, hídricos e químicos de solos em sistemas de produção de morando em Turuçu, RS**. 2010. 102 f. Tese (Doutorado em Agronomia)-Universidade Federal de Pelotas, Pelotas, 2010.

BARCELOS, A. A. **Infiltração de água em um latossolo, sob chuva de alta intensidade, em diferentes sistemas de manejo**. 1996. 112 f. Dissertação (Mestrado em Ciência do Solo)-Universidade Federal do Rio Grande do Sul, Porto Alegre, 1996.

BARLETTA, R. **An introduction to Case-based Reasoning**. *AI Expert*: August, 1991, 49 p.

BARRETO, J. M. Introdução às redes neurais artificiais, In: ESCOLA REGIONAL DE INFORMÁTICA DA SBC REGIONAL SUL, 5, 1997, Florianópolis. **Anais...** Florianópolis, Maringá, 1997, p. 41-71.

BATCHELOR, W. D.; YANG, X. B.; TSCHANZ, A. T. **Neural network approach for the prediction of soybean rust severity**. In: ICCTA 96/VIAS/NNAA CONGRESS ON ICT APPLICATIONS IN AGRICULTURE, 1996, Wageningen: [s.n.],. p. 16-19.

BATJES, N. Development of a world data set of soil water retention properties using pedotransfer rules. **Geoderma**, Amsterdam, v.71, p.31-52, 1996.

BAUER A., BLACK A. L. Organic carbon effects on available water capacity of three soil textural groups. **Soil Science Society of America Journal**, Madison, v.56, p.248-254, 1992.

BELL, M.; Van KEULEN. Soil pedotransfer functions for four Mexican soils. **Soil Science Society of America Journal**, Madison, v.59, p.865-871, 1995.

BELL, M. A. Organic matter, soil properties and wheat production in the High Valley of México. **Soil Science Society of America Journal**, Madison, v.156, p.86-93, 1993.

BENITE, M. **Aplicação de modelos de redes neurais na elaboração e análise de cenários macroeconômicos**. 2003. 123p. Dissertação (Mestrado em Engenharia) - Universidade de São Paulo, Escola de Engenharia de São Carlos, 2003.

BERNARDON, T. **Componentes da produtividade de grãos de milho (*Zea mays* L.), visando obter parâmetros para a agricultura de precisão**. 2005. 95 f. Dissertação (Mestrado em Geomática) Universidade Federal de Santa. Maria Santa Maria. 2005.

BERNOUX, M.; ARROUAYS, D.; CERRI, C.; VOLKOFF, B.; JOLIVET, C. BULK. Densities of Brazilian Amazon soils related to other soil properties. **Soil Science Society of America Journal**, Madison, v. 62, p.743-749. 1998.

BEUTLER, A. N.; CENTURION, J. F. Avaliação do estado de compactação de latossolos através de penetrômetros. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 31, 2002. Salvador. **Anais...** Salvador: Sociedade Brasileira de Engenharia Agrícola, 2002. 1 CD-ROM.

BLOEMEN, G. W. Calculation of hydraulic conductivities of soils from texture and organic matter content. **Zeitschrift fur Pflanzenernahrung und Bodenkunde**, Weinheim, v.143, n. 5, p. 581-605. 1980.

BOCANEGRA, C. W. R.. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 97 p. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2002.

BOUMA, J. Using soil survey data for quantitative land evaluation. **Soil Science Society of America Proceedings**, Madison, v. 9, p. 177-213, 1989.

BOUMA, J.; LANEN, H. A. J. Transfer functions and threshold values: from soil characteristics to land qualities. In: Beek, K., P. A. Barrough and D. D McCormack (Editors). Proc. WORKSHOP BY ISSS/SSSA ON QUANTIFIED LAND EVALUATION PROCEDURES, ITC publication. 6., Enschede. **Proceedings...** Netherlands, 1987. p.106-111.

BRADY, N. C; BUCKMAN, H. O. **Natureza e propriedades dos solos**. Trad. Antônio B. N. Figueiredo Filho. 7. ed. Rio de Janeiro: Freitas Bastos, 1989. 898 p.

BRAGA, A. P.; CARVALHO; A. P. L. F.; LUDEMIR; T. B. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.

_____. **Redes Neurais Artificiais. Teoria e a Aplicações.** Rio de Janeiro: Livros Técnicos e Científicos. 2007.300p.

BRANDT, A. A. **Carregamento estático e dinâmico e sua relação com tensão, deformação e fluxos no solo.** 2009. 162p. Tese (Doutorado em Engenharia Agrícola). Universidade Federal de Santa Maria, Santa Maria. 2009.

_____. **Propriedades mecânicas de solo franco arenoso sob distintos sistemas de preparo, tráfego mecanizado e resíduos vegetais.** 2005. 89p. Dissertação (Mestrado em Engenharia Agrícola). Universidade Federal de Santa Maria, Santa Maria. 2005.

BROOKS, R. H.; COREY, A.T. Properties of porous media affecting fluid flow. **Journal of Irrigation and Drainage Division**, New York, v.92, p.61-88, 1964.

BRYSON, A. E.; HO. Y. **Applied Optimal Control**, Blaisdell. 1969.

BUCENE, L. C.; RODRIGUES, L. H. A. Utilização de redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.8, n.2/3, p.326-329, mar. 2004

BULUT, R.; LYTTON, R. L.; WRAY, W. K. Soil suction measurements by filter paper. In: GEO-INSTITUTE SHALLOW FOUNDATION AND SOIL PROPERTIES, 2001, Houston. **Proceedings...** Houston: Geo-Institute of the American Society of Civil Engineers, 2001. p. 243-261.

CAGLIARI, J. **Função de pedotransferência para estimar o fósforo remanescente em solos, utilizando rede neural artificial.** 2010. 104 f. Dissertação (Mestrado em Geologia) - Universidade do Vale do Rio dos Sinos, São Leopoldo, 2010.

CAMARA, R. K. **Influência da escarificação do solo sob sistema plantio direto nas propriedades do solo e na cultura da soja.** 2004. 96 f. Dissertação (mestrado em Agronomia). Universidade de Passo Fundo. Passo Fundo. 2004.

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

CANECA, A. R. et al. Assessment of infrared spectroscopy and multivariate techniques for monitoring the service condition of diesel-engine lubricating oils. **Talanta**, New York, v. 70, p. 339-344, 2006.

CARDOSO, C. D. V. **Probabilidade de ocorrência de deficiência hídrica nos solos da região central do Estado do Rio Grande do Sul**. 2005. 193 f. Tese (Doutorado em Agronomia). Universidade Federal de Santa Maria. Santa Maria. 2005.

CARLESSO, R.; ZIMMERMANN, F. L. **Água no solo: parâmetros para o dimensionamento de sistemas de irrigação**. Santa Maria: UFSM: Departamento de Engenharia Rural, 2000. 88 p.

CARPENEDO, V. **Compressibilidade de solos em sistemas de manejo**. 1994. 106 f. Tese (Doutorado em Ciências do Solo)-Universidade Federal do Rio Grande do Sul. 1994.

CÁSSARO, F. A. M.; PIRES, L. F.; SANTOS, R. A. dos; GIMÉNEZ, D.; REICHARDT, K. Funil de haines modificado: curvas de retenção de solos próximos à saturação. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, p. 2555-2562. 2008.

CASTRO, E. G. **Reconhecimento de Padrões em Tomada de Decisão Utilizando Redes Neurais Artificiais**. 1998. 98 f. Trabalho de Conclusão de Curso – Escola Politécnica – Universidade de São Paulo, São Paulo. 1998.

CENTURION, J. F.; ANDRIOLI, I. Regime hídrico de alguns solos de Jaboticabal. **Revista Brasileira de Ciência do Solo**, Viçosa, v.24, n.4, p.701-709, 2000.

CHAGAS, C. da S. et al. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 3, p. 319-327, 2009.

CHANDLER, R. J.; GUTIERREZ, C. I. The filter paper method of suction measurements, **Geotechnique**, London, v. 36, p. 265-268, 1986.

CHIBBER, R. Aggregate size distribution and water relationships amongst some typical Indian soils. **Institute Science India**, Bangalore, v.266, p.148-156, 1964.

CHILDS, E. C. The use of soil moisture characteristics in soil studies. **Soil Science**, Philadelphia, v.50, p.239-252. 1940.

CHONG, I.; JUN, C. Performance of some variable selection methods when multicollinearity is present. **Chemometrics and Intelligent Laboratory Systems**, 78: 103, 2005.

CICHOTA, R.; VAN LIER, Q. de J. Análise da variabilidade espacial de pontos amostrais da curva de retenção da água no solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 28, p. 585-596, 2004.

CINTRA, F. L. D. **Caracterização do impedimento mecânico em Latossolos do Rio Grande do Sul**. 1980. 89 f. Dissertação (Mestrado em Ciência do Solo)- Universidade Federal do Rio Grande do Sul, Porto Alegre, 1980.

CINTRA, F. L. D.; PORTELA, C. J.; NOGUEIRA, L. C. Caracterização física e hídrica em solos dos tabuleiros costeiros os no distrito de irrigação platô de neópolis. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.8, n.1, p.45-50, 2004.

COLLARES, G. L. **Compactação em latossolos e argissolo e relação com parâmetros de solo e planta**. 2005. 107 p. Tese (Doutorado em Ciência do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2005.

CORDEIRO, D. S. **Níveis de água em um solo hidromórfico (RGS) e seus efeitos no desenvolvimento da soja**. 1975. 84 p. Dissertação (Mestrado em Agronomia) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, São Paulo. 1975.

CORNELIS, W. M., J. et al. Evaluation of pedotransfer functions for predicting the soil moisture retention curve. **Soil Science Society of America Journal**, Madison, v.65, p.638–648, 2001.

COSTA, da A. **Retenção e disponibilidade de água em solos de Santa Catarina: Avaliação e geração de funções de pedotransferência**. 2012. 424 f. Tese (Doutorado manejo do solo) - Universidade do Estado de Santa Catarina, Lages, 2012.

COSTA, J. C. da et al. **Fundamentos neurobiológicos das epilepsias**. São Paulo: Lemos-Editorial, 1998. 1439 p.

COSTA, S. V. **Desenvolvimento e calibração de um mini-tanque evaporimétrico**. 2004. 80 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria. 2004.

COSTA, W. A.; OLIVEIRA, C. A. da S.; KATO, E. Modelos de ajuste e métodos para a determinação da curva de retenção de água de um Latossolo-vermelho-amarelo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, n. 2, p. 515-523, 2008.

CRESTANA, S. Técnicas recentes de determinação de características do solo. In: REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA, 10, Florianópolis- SC, 1994. **Anais...** Florianópolis: SBCS, 1994. p. 86-97.

CURI, N. **Relações genéticas e geomorfológicas em solos das encostas inferior e superior do nordeste do Rio Grande do Sul**. 1975. 149f. Dissertação (Mestrado em Agronomia). Universidade Federal do Rio Grande do Sul. Porto Alegre. 1975.

DALBIANCO, L. **Variabilidade espacial e estimativa da condutividade hidráulica e caracterização físico-hídrica de uma microbacia hidrográfica rural**. 2009. 116 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2009.

DALMAGO, G. A. **Dinâmica da água no solo em cultivos de milho sob plantio direto e preparo convencional**. 2004. 245 f. Tese (Doutorado em Fitotecnia) Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

DALMOLIN, R. S. D. **Matéria orgânica e características físicas, químicas, mineralógicas e espectrais de Latossolos de diferentes ambientes**. 2002. 151 f. Tese (Doutorado em Ciência do Solo) - Programa de Pós-graduação em Ciência do Solo, Universidade Federal do Rio Grande do Sul. 2002.

De JONG, R., CAMPBELL, C. A.; NICHOLAICHUK, W. Water retention equations and their relationship to soil organic matter and particle size distributions for disturbed samples. **Canadian Journal of Soil Science**, Canadá, v. 63, p. 291-302, 1983.

DEKA, R. N. et al. Use and accuracy of the filter-paper technique for measurement of soil matric potential. **European Journal of Soil Science**, Chichester, v. 46, p. 233-238, jun. 1995.

DIENE, A. A.; MAHLER, C. F. Um instrumento para medida de potencial matricial nos solos sem ocorrência de cavitação. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 1261-1270. 2007.

DIRKSEN, C. **Soil physical measurements**. Reiskirchen: Catena Verlag. 1999. 154 p.

DORAN, J. W.; PARKIN, T. B. Defining and assessing soil quality. In: DORAN, J.W.; COLEMAN, D.C.; BEZDICEK, D.F.; STEWART, B.A. (Eds.) **Defining soil quality for a sustainable environment**. Madison, Soil Science Society of America, 1994, p. 3-21. (Special Publication, 35).

DOURADO-NETO, D. et al. **Soil water retention curve, SWRC software (version 3.0 beta)**. Piracicaba: Universidade de São Paulo, 2001. CD-ROM.

EL-SWAIFY, S.A.; HENDERSON, D. W. Water retention by osmotic swelling of certain colloidal clays with varying ionic composition. **Journal of Soil Science**, Oxford, v.18, p.223-232. 1967.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Serviço Nacional de Levantamento e Conservação de Solos. **Manual de métodos de análise de solo**. 2.ed. Rio de Janeiro, RJ: [s.n], 1997. 212 p.

FAHLMAN, S.E. **An empirical study of learning speed in backpropagation networks**, Technical Report CMU-CS-88-162, School of Computer Science – Carnegie Mellon University, Pittsburgh, PA. 1988.

FAWCETT, R. G.; COLLIS-GEORGE, N. A filter-paper method for determining the moisture characteristics of soil. **Australian Journal of Experimental Agriculture and Animal Husbandry**, Collingwood, v. 7, p. 162-167, 1967.

FELICIANO, J. J. da S. **Métodos alternativos para obtenção da curva de retenção da água no solo**. 2005. 59 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel, 2005.

FERNANDEZ, B. M.; OLIVEIRA, R. C. J. Relações entre capacidade de campo determinada in situ e em laboratório em latossolo amarelo muito argiloso. **Revista Brasileira de Ciência do Solo**, Viçosa, v.11, p.91-95, 1987.

FIDALSKI, J.; TORMENA, C. A. Homogeneidade da qualidade física do solo nas entrelinhas de um pomar de laranjeira com sistemas de manejo da vegetação permanente. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 637-645, 2007.

FIORIN, T. T. **Estimativa da infiltração de água no solo a partir de pedofunções**. 2008. 116 f. Tese (Doutorado em Ciência do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2008.

FISCHER, I. et al. **Java Neural Network Simulator User Manual, Version 1.1**. [S.l.]: Wilhelm-Schickard-Institute for Computer Science, University Of Tubingen. 2001.

FONTANELA, E. T. **Parâmetros físico-hídricos de um latossolo sob diferentes sistemas de manejo e níveis de tráfego**. 2008. 78 f. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal de Santa Maria, Santa Maria, 2008.

FRANÇA, M. M. Análise do uso da terra no município de Viçosa-MG mediado por classificações supervisionadas com redes neurais artificiais e Maxver. **Revista Brasileira de Geografia Física**, América do Norte, v. 2, n. 3, p. 92-101, 2010.

FRANCO, A. N. P. **Caracterização física de um solo construído na área de mineração de carvão de Candiota - RS**. 2006. 122 f. dissertação (Mestrado em Agronomia) – Universidade Federal de pelotas, pelotas, 2006.

_____. **Erosão em entressulcos e qualidade física dos solos constituídos após mineração de carvão**. 2010. 108 f. Tese (Doutorado em Ciência do solo) – Faculdade de Agronomia - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

FREITAS JÚNIOR, E.; SILVA, E. M. da. Uso da centrífuga para determinação da curva de retenção de água do solo, em uma única operação. **Pesquisa Agropecuária Brasileira**, Brasília, v. 19, n. 11, p. 1423-1428, Nov. 1984.

FUKUDA, T.; SHIBATA, T. Theory and applications of neural networks for industrial control systems, **IEEE Transactions. on Industrial Electronics**. v. 39, p. 472-489. 1992.

GALO, M. L. B. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo**. 2000. 205p. Tese (Doutorado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, da Universidade de São Paulo, São Carlos, 2000.

GALVÃO, C. O.; VALENÇA, M. J. S. (org.) **Sistemas inteligentes: aplicações a recursos hídricos a ciências ambientais**. Porto Alegre: Editora da Universidade, UFRGS, ABRH, 1999. 246 p.

GALVÃO, C. O. et al. **Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: UFRGS/ABRH, 1999. 246p.

GARCIA, C. H. **Tabelas para classificação do coeficiente de variação**. IPEF – ESALQ, Piracicaba, Circular técnica, 171. 12p. 1989.

GARDNER, W. R. A method of measuring the capillary tension of soil moisture over a wide moisture range. **Soil Science**, Philadelphia, v. 43, n. 4, jan.-jun., p. 277-283.

GHOSH, R.K. Estimation of soil-moisture characteristics from mechanical properties of soils. **Soil Science**, Philadelphia, v.130, p. 60-63, 1980.

_____. Model of the soil moisture characteristics. Journal Indian Society **Soil Science**, Philadelphia, v.24, n.4, p.353-355, 1976.

GIAROLA, N. F. B.; SILVA, A.P.; IMHOFF, S. Relações entre propriedades físicas e características de solos da região sul do Brasil. **Revista Brasileira de Ciência do Solo**, Viçosa, v.26, p.885-893, 2002.

GOMES, A. S. **Relações solo-água em solos argilosos-escuros da Campanha Sudoeste do Rio Grande do Sul**. 1972. 94f. Dissertação (Mestrado em Ciência do Solo)-Universidade Federal do Rio Grande do Sul, Porto Alegre, 1972.

GONÇALVES, J. L. M. Interpretação de levantamentos de solo para fins silviculturais. **Instituto de Pesquisas e Estudos Florestais**, Piracicaba, n. 39, p. 65-72, agos.1988.

GONÇALVES, M. C.; PEREIRA, L. S. E LEIJ, F. J. Pedo-transfer functions for estimating unsaturated hydraulic properties of portuguese soils. **Soil Science**, Philadelphia, v. 48, n. 3, p. 387-400, Sep. 1997.

GONÇALVES, M. L. **Uma Arquitetura Neural Modular para Classificação de Imagens Multiespectrais de Sensoriamento Remoto**. 1997. 112 f. Dissertação (Mestrado Engenharia Elétrica)-Faculdade Estadual de Campinas, Campinas, 1997.

GUPTA, S. C.; LARSON, W. E. Estimating soil water retention characteristics from particle size distribution, organic matter content, and bulk density. **Water Resources Research**, v.15, p.1005-1013, 1979.

HAGAN, M. T.; MENHAJ, M. B. "Training Feedforward Networks with the Marquardt Algorithm". **IEEE Transactions on Neural Networks**, v.5, n.6. 1994.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. Neural network design. Boston, PWS Publishing Company, Não paginado. 1996.

HAYKIN, S. **Neural networks: A Comprehensive Foundation**. New York: IEEE Press, 1994.

_____. **Neural Networks: a comprehensive foundation**. 2. ed. Saddle River: Prentice Hall, 1999.

_____. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900 p.

HELLING, C.S.; CHESTER, G.; COREY, R.B. Contribution fo organic matter and clay to soil cation Exchange capacity as affected by pH of the saturating solution. **Soil Science Society of America Proceedings**, Madison, v.28, p.517-520, 1964.

HILL, J.N.; SUMNER, M. E. Effect of bulk density on moisture characteristics of soil. **Soil Science**, Philadelphia, v. 103, n. 4, p.235-38. 1967.

HILLEL, D. **Solo e Água; fenômeno e princípios físicos**. Porto Alegre: UFRGS, 1970. 231p.

_____. **Soil and water: Physical principles and processes**. New York : Academic Press, 1971. 288p.

_____. **Environmental soil physics**. New Cork: Academic Press, 1998. 771 p.

_____. **Introduction to soil physics**. London: Academic Press, 1982. 364 p.

HILLEL, D. A.; KRENTOS, V. K.; STILIANOV, Y. Procedure and test of an internal drainage method for measuring soil hydraulic characteristics in situ. **Soil Science**, Philadelphia, v. 114, p. 395-400, 1972.

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**, Amsterdam, v. 108, p.155-180, 2002.

HOUSTON, S. L.; HOUSTON, W. R.; WAGNER, A. M. Laboratory filter paper measurements. **Geotechnical Testing Journal**, West Conshohocken, v. 17, p. 185-194, 1994.

IBICIT – Instituto Brasileiro de Informação em Ciência e Tecnologia. 2005. Disponível em <<http://www.ibict.br/>>. Acesso em: abr. 2011.

JAMISON, V. C. Changes in air-water relationships due to structural improvement of soils. **Soil Science**, Philadelphia, 76:143-51. 1953.

JAMISON, V. C.; KROTH, E. M. Available Moisture Storage Capacity in Relation to Texture Composition and Organic Matter Content of Several Missouri Soils. **Soil Science Society of America Journal**, Madison, v. 22, n. 3, p. 189-192. 1958.

JANA, R. B., MOHANTY, B. P. SPRINGER, E. P. Multiscale Pedotransfer Functions for Soil Water Retention, **Vadose Zone Journal**, Madison, v. 6, n. 4, p. 868-878. 2007.

_____. Multiscale Bayesian Neural Networks for Soil Water Content Estimation, **Water Resources Research**, v. 44, W08408, doi: 10.1029/2008WR006879. 2008.

JANA, R. B., MOHANTY, B. P. Enhancing PTFs with Remotely Sensed Data for Multi-Scale Soil Water Retention Estimation, **Jornal of Hydrology**, v. 399, p. 201–211, 2011.

JANA, R. B., MOHANTY, B. P.; Z. SHENG. Upscaling soil hydraulic parameters in the Picacho Mountain region using Bayesian Neural Networks, **Transactions of the ASABE**, v. 55, n. 2, p. 463-473. 2012.

JANA, R. B.; MOHANTY, B. P. A Comparative Study of Multiple Approaches to Soil Hydraulic Parameter Scaling Applied at the Hill-Slope Scale, **Water Resources Research**, v. 48, W02520, doi:10.1029/2010WR010185. 2012.

_____. Topography-Based Scaling Algorithm for Soil Hydraulic Parameters at Hill-Slope Scales: Field Testing, **Water Resources Research**, v. 48, W02519, doi:10.1029/2011WR011205. 2012.

JURY, W. A.; GARDNER, W. R.; GARDNER, W. H. **Soil physics**. 5. ed. New York: John Wiley, 1991. 328 p.

KAISER, D. R. **Estrutura e água em argissolo sob distintos preparos na cultura do milho**. 2010. 151f. Tese (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2010.

KERN, J. S. Evaluation of soil water retention models based on basic soil physical properties. **Soil Science Society of America Journal**, Madison, v. 59: 1134-1141, 1995.

KLAR, A. E. **A água no sistema-solo-planta-atmosfera**. 2ª ed. São Paulo. Nobel 1988.

KLEIN, V. A. **Propriedades físico-hídrico-mecânica de um latossolo roxo, sob diferentes sistemas de uso e manejo**. 1998. 150f. Tese (Doutorado em Agronomia) - Curso de Pós-graduação em Solos e Nutrição de Plantas, ESALQ/Universidade de São Paulo, São Paulo, 1998.

KNES, A. E. **Temperatura e umidade de um solo franco arenoso cultivando milho**. 2010. 104f. Dissertação (Mestrado em Ciência do Solo) -Universidade Federal de Santa Maria, Santa Maria, 2010.

KOCHHANN, R. A. **Levantamento detalhado e classificação de capacidade de uso de irrigação dos solos do posto agropecuário de Carazinho – RS 1971**. 100 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 1971.

KUNZ, M. **Comportamento físico de um latossolo sob integração lavoura-pecuária**. 2009. 70 f. Dissertação (Mestrado em Engenharia Agrícola) -Universidade Federal de Santa Maria, Santa Maria, 2009.

LAKZIAN, A.; BANNAYAN AVAL, M. M.; GORBANZADEH, N. Comparison of Pattern Recognition, Artificial Neural Network and Pedotransfer Functions for Estimation of Soil Water Parameters. **Notulae Scientia Biologicae**, Cluj-Napoca, v. 2, n. 3, p. 114-120. 2010

LASSEM, L. et al. **Algunas relaciones entre planta, suelo y agua en el manejo de cuencas**. Some soil-plant-water relations in watershed management. México, Centro Regional de Ayuda Técnica, 1965. 68p. (Circular, 910).

LECUN, Y. A learning procedure for assymmetric threshold network. **Proceedings of Cognitiva**. Paris, v. 85. p. 599-604. 1985.

_____. **Generalisation and Network Design Strategies**. [S.L. : s.n.]. Technical Report CRG-TR-89-4, Department of Computer Science, University of Toronto, 1989.

LEONG, E. C.; HE, L.; RAHARDJO, H. Factors affecting the filter paper method for total and matric suction measurements. **Journal of Geotechnical Testing**, West Conshohocken, v. 25, n. 3, p. 322-333, 2002.

LEVINE, E. R.; KIMES, D. S.; SIGILLITO, V. G. Classifying soil structure using neural networks. **Ecological Modelling**, [S.L.], v. 92, p.101-108, 1996.

LIBARDI, P.L. **Dinâmica da água no solo**. 2. ed. Piracicaba: Edição do autor, 2000. 509p.

_____. **Dinâmica da água no solo**. Piracicaba: EDUSP, 2005. 335 p.

LIN, H.S. et al. Effects of soil morphology on hydraulic properties: II. Hydraulic pedotransfer functions. **Soil Science Society of America Journal**, Madison, v. 63, p. 955-961, 1999.

LOSENKANN, M. E. **Caracterização, classificação e indicadores de qualidade do solo em localidades de agricultura familiar do Estado do Rio Grande do Sul**. 2009. 88 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

MACEDO, A.; CRESTANA, S.; VAZ, C.M.P. X-ray microtomography to investigate thin layers of soil clod. **Soil and Tillage Research**, v.49, p.249-253, 1998.

MACHADO, F. W. **Modelagem chuva-vazão mensal utilizando redes neurais artificiais**. 2005. 174 f. Tese (Doutorado em Recursos Hídricos e Ambiental) – Universidade Federal do Paraná, Curitiba, 2005.

MACHADO, J. L. et al. Inter-relações entre as propriedades físicas e os coeficientes da curva de retenção de água de um latossolo sob diferentes sistemas de uso. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 32, p. 495-502, 2008.

MALCOM, J. R.; ANDRÉE, D. C. Water release characteristics. In: SMITH, K. A.; MULLINS, C. E. (Ed.). **Soil analysis: physical methods**. New York: M. Dekker, 1991. p. 111-160.

MALLMANN, F. J. K. **Simulação do transporte vertical de zinco, chumbo e cobre em solos contaminados**. 2009. 147 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2009.

MARCIANO, C. R. et al. Variabilidade do potencial mátrico e do conteúdo de água no solo em experimento de manejo de irrigação. **Revista Brasileira de Ciência do solo**, Viçosa, v 22. p.563-571, n4, 1998.

MARCOLIN, C. D. **Propriedades físicas de nitossolo e latossolos argilosos sob plantio direto**. 2006. 110 f. Dissertação (Mestrado em Agronomia) - Faculdade de Agronomia e Medicina Veterinária, Universidade de Passo Fundo, Passo Fundo, 2006.

_____. **Uso de funções de pedotransferência entre atributos físicos de solos sob plantio direto**. 2009. 202 f. Tese (Doutorado em Agronomia) - Faculdade de Agronomia e Medicina Veterinária, Universidade de Passo Fundo, Passo Fundo, 2009.

MARINHO, F. A. M.; OLIVEIRA, O. M. The filter paper method revisited. **Geotechnical Testing Journal**, West Conshohocken, v. 29, n. 3, p. 1-9, 2006.

MASUTTI, M. M. **Caracterização da água disponível a partir de parâmetros físico-hídricos em solos da zona da mata do Estado de Pernambuco**. 1997. 69 f. Dissertação (Mestrado em Ciência do solo). Universidade Federal Rural de Pernambuco - Recife, 1997.

MATHIAS, I. M. **Aplicação de redes neurais artificiais na análise de dados de molhamento foliar por orvalho**. 2006. 120 f. Tese (doutorado em Agronomia) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2006.

MATHIAS, I. M.; CATANEO, A.; GUIMARÃES, A. M. Redes neurais artificiais aplicadas ao tratamento de dados de molhamento foliar por orvalho. **Revista Energia na Agricultura**, Botucatu, vol. 24, n.2, p.119-137. 2009.

MAYR, T., JARVIS, N. J., Pedotransfer functions to estimate soil water retention parameters for a modified Brooks– Corey type model. **Geoderma**, Amsterdam, v.91, p.1-9, 1999.

McBRATNEY, A. B. et al. From pedotranfer functions to soil inference systems. **Geoderma**, Amsterdam, v.109, p.41-73, 2002.

McCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, vol.5, p.115-133, 1943.

MEDEIROS, L. F. **Redes Neurais em Delphi**. Visual Books. Editora. Florianópolis, 116p. 2003.

MEDEIROS, P. S. C. **Processo pedogenéticos, caracterização e classificação de solos em toposequência granítica na região Sudoeste de Porto Alegre**. 2010. 79 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

MELLO, C. R. et al. Modelo para determinação dos parâmetros da equação de Van Genuchten para um Cambissolo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 9, n.1. p. 23-29, 2005.

MENEZES, F. P. **Substancias húmicas em solos de diferentes feições geomorfológicas no rebordo do planalto do Rio Grande do Sul**. 2008. 112f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2008.

MENG, T.P. et al. Models to predict water retention in semiarid sandy soils. **Soil Science Society of America Journal**, Madison, v. 51, p. 1563- 565, 1987.

MENTGES, M. I. **Implicações do uso do solo nas propriedades físico-hídricas e mecânicas de um argissolo vermelho-amarelo e de um gleissolo háplico**. 2010. 108f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2010.

MICHELON, C. J. et. al. Funções de pedotransferência para estimativa da retenção de água em alguns solos do Rio Grande do Sul. **Revista Ciência Rural**, Santa Maria, vol. 40, n.4, p. 848-853, 2010.

MICHELON, C. J. **Pedofunções para retenção de água de solos do rio grande do sul irrigados por aspersão**. 2010. 111 f. Tese (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria. Santa Maria, 2010.

MILONE, G.; ANGELINI, F. **Estatística geral**. São Paulo: Atlas, 1993.

MINASNY, B.; McBRATNEY, A. B. The neuro-m methods for fitting neural network parametric pedotransfer functions. **Soil Science Society of America Journal**, Madison, v. 66, p. 352-361, 2002.

MINASNY, B.; McBRATNEY, A. B.; BRISTOW, K. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. **Geoderma**, Amsterdam, v.93, p.225-253, 1999.

MINASNY, B. et al. **Revisão sobre funções de pedotransferência e novos métodos de predição de classes e atributos do solo**. Rio de Janeiro: Embrapa Solos - Documentos, n. 45. 2003, 50p.

MONTENEGRO, J. **Características físicas e fator de erodibilidade de solos de depressão central do Rio Grande do Sul**. 1976. 93 f. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal de Santa Maria, Santa Maria, 1976.

MORAES, S. O.; LIBARDI, P. L.; DOURADO NETO, D. Problemas metodológicos na obtenção da curva de retenção da água pelo solo. **Scientia Agricola**, Piracicaba, v. 50, n. 3, p. 383-392, 1993.

MOREIRA, M. C. et al. Desenvolvimento e análise de uma rede neural artificial para estimativa da erosividade da chuva para o Estado de São Paulo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 30, p. 1069-1076, out. 2006.

MOREIRA, M. C.; CECÍLIO, R. A. Estimativa das temperaturas do ar utilizando redes neurais artificiais, para a região Nordeste do Brasil. **Revista Brasileira de Agrometeorologia**, Piracicaba, v. 16, n. 2, p. 181-188, 2008.

MOREIRA, M. C. et al. Redes neurais artificiais para estimativa mensal da erosividade da chuva no estado de minas gerais. **Engenharia na Agricultura**, Viçosa, v.17, n.1, 75-83 Jan./Fev. 2009.

NAGAOKA, M. E. **Uma abordagem baseada em redes neurais artificiais para a estimação de densidade de solo**. 2003. 144 f. Tese (doutorado em Agronomia) - Universidade estadual paulista “Júlio de Mesquita Filho”, Botucatu, 2003.

NAGAOKA, M. E.; SILVA, I, N da.; LANÇAS, K. P. Um método para estimar densidade de solo utilizando redes neurais artificiais. **Energia na Agricultura**, Botucatu, vol. 20, n. 4, p.53-68, 2005.

NAIME, J. M.; VAZ, C. M. P.; MACEDO, A. Automated soil particle size analyzer based on gamma-ray attenuation. **Computers Electronics in Agriculture**, v. 31, p. 295-304, 2001.

NAJJAR, Y. M.; BASHEER, I. A.; NAOUSS, W. A. On the identification of compaction characteristics by neuronets. **Computers and Geotechnics**, Great Britain, v.18, n. 3, p.167-196, 1996.

NASCIMENTO, E. R. F. **Desenvolvimento de modelos neurais para o processamento de sinais acústicos visando a medição de propriedades topológicas e escoamento multifásicos**. 2007. 114 f. Tese (Doutorado em Engenharia Mecânica) - Universidade de São Paulo, São Paulo, 2007.

NASCIMENTO, G. B. do. et al. Funções de pedotransferência do conteúdo de água em Latossolos Amarelos e Argissolos Amarelos. **Revista Brasileira de Ciência Agrária**, Recife, v. 5, n.4, p.560-569, 2010.

NASCIMENTO, P. dos S. **Análise do uso da curva de retenção de água no solo determinada por diferentes métodos e planilha para manejo da irrigação**. 2009. 97 f. Dissertação (Mestrado em Ciências Agrárias) - Universidade Federal do Recôncavo da Bahia, Cruz das Almas, 2009.

NAVARINI, L. L. **Manejo do solo e utilização de bioestimulantes na cultura do trigo (*Triticum aestivum* L.)**. 2010. 96 f. Dissertação (Mestrado em Agronomia) - Faculdade de Agronomia e Medicina Veterinária, Universidade de Passo Fundo, Passo Fundo, 2010.

NEBEL, A. L. C. **Funções de pedotransferência e estrutura de variabilidade espacial da retenção de água em solos de várzea do Rio Grande do Sul**. 2009. 142 f. Tese (Doutorado em Solos) – Universidade Federal de Pelotas, Pelotas, 2009.

NETO, O. C. P.; JORGE, L. A. DE C.; GUIMARÃES, M. DE F. Quantificação de plantas daninhas em soja através de classificador digital por redes neurais. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 5., 2005, Londrina. **Anais... SBI-AGRO**, v. 1, 2005.

NETTO, A. A. **Estimativa da retenção de água no solo a partir do uso de equipamentos não convencionais, redes neurais artificiais e funções de pedotransferência**. 2007. 176 f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Universidade de São Paulo, São Paulo, 2007.

NEURAI, Web: Disponível em <<http://www.din.uem.br/ia/neurais>>. Acesso em set. 2011.

NIEVOLA, J. C. Redes neurais artificiais. In: XII Escola regional de informática – ERI 2004, Guarapuava. **Anais...**Guarapuava: Universidade Estadual do Centro-Oeste – UNICENTRO, 2004. p.01-50.

NUNES, M. C. M. Erosão **hídrica em entressulcos de latossolos do Rio Grande do Sul**. 2006. 175 f. Tese (Mestrado em Ciência do Solo) – Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

NUNES, P. G. A. **Uma nova técnica para seleção de variáveis em Calibração multivariada aplicada às espectrometrias UV-VIS e NIR**. 2008. 106 p. Tese (Doutorado em Química) – Universidade Federal da Paraíba, João Pessoa. 2008.

NUNES, T. V. L. **Método de previsão de defeitos em estradas vicinais de terra com base no uso das redes neurais artificiais: trecho de Aquiraz-CE**. 2003. 118 p. Dissertação (Mestrado em Engenharia de Transportes) – Universidade Federal do Ceará, Fortaleza, 2003.

OLIVEIRA, A. C. S. de. et al. Aplicação de redes neurais artificiais na previsão da produção de álcool. **Ciência e Agrotecnologia**, Lavras, v. 34, n. 2, p. 279-284, 2010.

OLIVEIRA, L. B. et al. Funções de pedotransferência para predição da umidade retida a potenciais específicos em solos do Estado de Pernambuco. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 26, n. 26, p. 315-323, jan. 2002.

OLIVEIRA, L. F. C.; SARVASI, F. O. C. Determinação da curva de retenção de umidade de um latossolo vermelho-escuro da região de Alfenas por tensiometria. **Ciência e Agrotecnologia**, Lavras, v. 21, p. 91-95, 1997.

ORTIGÃO, J. A. R. **Introdução à mecânica dos solos dos estados críticos**. 3. ed. Rio de Janeiro: Terratek, 2007. 386 p.

OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas Inteligentes baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens, In: I Workshop de inteligência artificial, 2000, **apostila-seminário**, Santa Cruz do Sul, UNISC – Universidade de Santa Cruz do Sul - Departamento de Informática, 2000.

PACHEPSKY, Y. A.; RAWLS, W. J. Accuracy and reliability of pedotransfer functions as affected by grouping soils. **Soil Science Society of America Journal**, Madison, v. 63, n. 6, p. 1748-1757, 1999.

PACHEPSKY, Y. A.; TIMLIN, A D. Neural networks to estimate transport phenomena in soils, Agronomy Abstract, p. 239, **American Society of Agronomy**, Madison, WI, 1994.

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

PACHESPY ,Y. et al. Use of abductive networks to predict soil water retention. **American Society of Agronomy**, Madison, p. 178, 1997.

PARASURAMAN K., ELSHORBAGY A., SI B.C. Estimating saturarated hydraulic conductivity using genetic programming. **Soil Science Society of America Journal**, Madison, v. 71, p. 1676-1684, 2007.

PARKER, D. **Learning Logic: Casting the Cortex of the Human Brain in Silicon**. Technical Report, Center for Computational Research in Economics and Management Science, MIT. 1985.

PARMAR, R. S, et al. Estimation of aflatoxin contamination in preharvest peanuts using neural networks. **Transactions of the ASAE**, St. Joseph, v. 40, n. 3, p. 809-13, 1997.

PAULETTO, E. A. et al. Determinação da condutividade hidráulica de solos a partir da curva de retenção de água. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 12, p. 189-195, 1988.

PEARLMUTTER, B. Gradient Descent: Second Order Momentum and Saturation Erro. In MOODY, J. E.; HANSON, S.; LIPPMANN. R. editors, **Advances in Neural Information Processing Systems 2**. San Francisco: Morgan Kaufmann, 1992. p. 887-894.

PERAZA, J. E. S. **Retenção de água e pedofunções para solos do Rio Grande do Sul**. 2003. 117 f. Dissertação (Mestrado Engenharia Agrícola) - Curso de Pós-graduação em Engenharia Agrícola, Universidade Federal de Santa Maria, 2003.

PEREIRA, E. M. **Estudo do comportamento à expansão de materiais sedimentares da formação Guabirotuba em ensaios com sucção controlada.** 2004. 253 f. Tese (Doutorado em Engenharia Geotécnica)- Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2004.

PEREIRA, G. C. **Mineração de dados para análise e diagnóstico ambiental.** 2005. 194 p. Tese (Doutorado em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

PETRY, M. T. **Interação solo-planta e disponibilidade de água no solo às plantas de sorgo e soja.** 2000. 127 f. Dissertação (Mestrado em Agronomia). Universidade Federal de Santa Maria, Santa Maria, 2000.

PICOLI, M. C. A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: estudo de caso Usina Catanduva.** 2006. 95 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2006.

Portal Domínio Público. 2011. Disponível em <<http://www.dominiopublico.gov.br>>. Acesso em: mar. 2011.

POTES, M. L. **Matéria orgânica e sua distribuição em compartimentos físicos em neossolos litólico sob pastagem e mata nativa nos campos de cima da serra, Rio Grande do Sul.** 2009. 101 f. Dissertação (Mestrado em Ciência do Solo). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

PREVEDELLO, C. L. **Física do solo.** Curitiba: SAEAFS, 1996. 446 p.

PREVEDELLO, J. **Preparo do solo e crescimento inicial de Eucalyptus grandis Hill ex Maiden. em argissolo.** 2008. 86 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal de Santa Maria, Santa Maria, 2008.

RAJKAI, K. K. S; VAN GENUCHTEN, M. T. H; JANSSON, P. Estimation of water-retention characteristics from the bulk density and particle-size distribution of Swedish soils. **Soil Science**, Philadelphia, v. 161, p. 832-845. 1996.

RAMON Y CAJAL, S. **Histologie du System Nerveux de l'Homme et des Vertebres.** Paris: Maloine, 1911. 330p.

RAWLS, W. J.; PACHEPSKY, Y. A.; RITCHIE, J. C.; SOBECKI, T. M.; BLOODWORTH, H. Effect of soil organic carbon on soil water retention. **Geoderma**, Amsterdam, v. 116, 2003, p. 61 – 76.

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

RAWLS, W. J.; GISH, T. J.; BRAKENSIEK, D. L. Estimating soil water retention from soil physical properties and characteristics. **Advances in Soil Science**, v. 16, p.213-234, 1991.

REEVE, M. J.; SMITH, P. D.; THOMASSON, A.J. The effect of density on water retention properties of field soils. **Journal of Soil Science**, Oxford, v.24, p.355-367, 1973.

REFENES, A.N., AZEMA-BARAC, M., TRELEAVEN, P.C. **Financial Modelling using Neural Networks**. London: Department of Computer Sciences, University College London, p. 1-31, 1993.

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

_____ **Dinâmica da matéria e da energia em ecossistemas**. 2 ed Piracicaba: USP/ESALQ. Depto. Física e Meteorologia,. Piracicaba, 1996. 505p.

REICHARDT, K.; TIMM, L. C. **Solo, planta e atmosfera: conceitos, processos e aplicações**. São Paulo: Manole. 2004. 478 p.

REICHERT, J. M. et al. Estimation of water retention and availability in soils of Rio Grande do Sul. **Revista Brasileira de Ciência do Solo**, Viçosa, v.33, p.1547:1560, 2009.

RESENDE, M.; OLIVEIRA, A. Comparação de diferentes estratégias de programação de irrigação suplementar em milho. **Revista Brasileira de Milho e Sorgo**, América do Norte, v. 4, 2010.

RIBEIRO, S. R. A. **Integração de Imagens Landsat TM e dados auxiliares para a delimitação automática de unidades fisionômicas usando Redes Neurais Artificiais**. 2003, 160 f. Tese (Doutorado em Ciências Geodésicas) - Setor de tecnologia - Universidade Federal do Paraná, Curitiba, 2003.

RIEDMILLER, M. RPROP. Description and implementation details. Technical Report. Universitat Karlsruhe, 1994. Disponível em: <<http://citeseer.ist.psu.edu/riedmiller94rprop.html>>. Acesso em 20 dez. 2011.

RIGHES, A.; LOVATO, T.; SOARES, E. Caracterização física, química e microbiológica de planossolo da unidade de mapeamento Vacacai, RS, **Ciência Rural**, Santa Maria, v.13, n.1, p.25-45, 1983.

RIQUELME, U. F. B. **Propriedades físicas e hídricas do solo em sistemas de manejo do feijoeiro**. 2004. 79 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Santa Maria, Santa Maria, 2004.

RIVERS, E.D.; SHIPP, R.F. Soil water retention as related to particle size in selected sands and loamy sands. **Soil Science**, Philadelphia, v.126, p.94 -100, 1978.

ROHN, M. da C.; MINE, M. R. M. Uma aplicação de redes neurais artificiais à previsão de chuvas de curtíssimo prazo. In: XV Simpósio brasileiro de recursos hídricos. 2003. **Anais....** Curitiba, Associação Brasileira de Recursos Hídricos, 2003, CD-ROM.

ROJAS, C. A. L. **Alterações físico-hídricas de um podzólico em função do manejo de solo**. 1998. 77 f. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 1998.

ROSA, V. T. **Tempo de implantação do sistema plantio direto e propriedades físico-mecânicas de um latossolo**. 2009. 94 p. Tese (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, 2009.

ROSENBERG, N. O. Response of plants to the physical effects of soil compaction. In: NORMAN, A.G., ed. **Advances in Agronomy**. New York, Academic Press, 1964. p.181-96.

ROYER, J.M.; VACHAUD, G. Field determination of hysteresis in soil-water characteristics. **Soil Science Society of America Proceedings**. Madison, v.39, p.221-223, 1975.

RUMELHART, D. E., HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In Rumelhart, D. E., McClelland, J. L.; the PDP Research Group, editors, **Paralled Distributed Processing. Explorations in the Microstructure of Cognition**. v. 1, p. 318-362. 1986.

RUMELHART, D. E.; MCCLELLAND, J. L. On learning the past tenses of English verbs. In: MCCLELLAND, J. L.; RUMELHART, D. E. (Eds.). **Parallel distributed processing**. Cambridge: MIT Press, p. 216-271. 1986.

SALCHOW, E.; LAL, R.; FAUSEY, N.; WARD, A. Pedotransfer functions for variable alluvial soils in southern Ohio. **Geoderma**, Amsterdam, v.73, p.165-181, 1996.

SALTER, P. J.; WILLIAMS, J. B. The influence of texture on the moisture characteristics of soils. Part I: A critical comparison of techniques for determining the available water capacity and moisture characteristic curve of a soil. **Journal of Soil Science**, Oxford, v. 16, p.1-15, 1965.

SALTON, J. C. **Relações entre sistemas de preparo, temperatura e umidade do solo**. 1991. 104 f. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 1991.

SARLE, W. S. Web. 2004. Disponível em: <<ftp://ftp.sas.com/pub/neural/FAQ.html.zip>>. Acesso em set. de 2011.

SAS Institute Inc. **SAS Online Doc 9.1.3**. Cary: SAS Institute Inc. 2004

SAXTON, K. E. et al. Estimating generalized soil-water characteristic from texture. **Soil Science Society of America Journal**, Madison, v. 50, p. 1031-1036, 1986.

SAXTON, K. E.; RAWLS, W.R. Soil water characteristic estimates by texture and organic Matter for hydrologic solutions. **Soil Science Society of America Journal**, Madison, v. 70, p. 1569-1578, 1986.

SCHAAP, M. G.; BOUTEN, W. Modeling water retention curves of sandy soils using neural networks. **Water Resources Research**, v. 32, p. 3033-3040, 1996.

SCHAAP, M. G.; LEIJ, F. L.; VAN GENUCHTEN, M. T. H. Neural network analysis for hierarchical prediction of soil hydraulic properties. **Soil Science Society of America Journal**, Madison, v. 62, p. 847-855, 1998.

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

SCHUH, W. M.; CLINE R. L.; SWEENEY, M. D. Comparison of laboratory procedure and a texture model predicting in situ soil water retention. **Soil Science Society of America Journal**, Madison, v. 52, p. 1218-1227, 1988.

SCOPEL, I. **Características físicas de solos da região litoral-norte do Rio Grande do Sul**. 1977. 120 f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 1977.

SCOTT, D. H. **Soil water principles**. In: Soil physics: agricultural and environmental applications. Ames: Iowa State University Press, 2000. p. 165-212.

SEVERO, C. R. S. **Disponibilidade de água e de nutrientes do solo e desenvolvimento do eucalipto em uma microbacia hidrográfica no município de Pinheiro Machado - RS**. 2009. 143f. Tese (Doutorado em Agronomia) - Universidade Federal de Pelotas, Pelotas, 2009.

SHARMA, M. L.; UEHARA, G. Influence of soil structure on water relation in low humic latosols. I. Water retention. **Soil Science Society of America Journal**, Madison, v. 32, p.765-770, 1968.

SILVA A. J. N. **Alterações físicas e químicas de um argissolo amarelo coeso sob diferentes sistemas de manejo com caba-de-açucar**. 2003. 135 f. Tese (Doutorado em Ciência do solo) - Universidade Federal do Rio Grande do Sul, porto Alegre, 2003.

SILVA, A. de S. S.; BRITO, L. T. de L.; OLIVEIRA, C. A. V. de; MOITA, A. W. Parâmetros de solo em função da umidade na capacidade de campo em áreas irrigáveis do trópico semi-árido brasileiro. **Pesquisa Agropecuária Brasileira**, Brasília, v.25, p.103- 16, 1990.

SILVA, A. F. da. **Previsão da evapotranspiração de referência utilizando redes neurais**. 2002. 68 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2002.

SILVA, A. P. et al. Funções de pedotransferência para as curvas de retenção de água e de resistência do solo à penetração. **Revista Brasileira de Ciência do Solo**, Viçosa, v.32, p.1-10, 2008.

SILVA, E. M. da; AZEVEDO, J. A. de. Influência do período de centrifugação na curva de retenção de água em solos de Cerrado. **Pesquisa Agropecuária Brasileira**, Brasília, v.37, p.1487-1494, 2002.

SILVA, I. N. da. et al. Projeto e análise de uma rede neural para resolver problemas de programação dinâmica. **Revista Controle e Automação**, v.12, n.1, p.1-10, 2001.

SILVA, I. N. **Uma abordagem neuro-nebulosa para otimização de sistemas e identificação robusta**. 1997. 145 f. Tese (Doutorado em Engenharia Elétrica/Automação) – Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, 1997.

SILVA, S. H. M. G. da. et al.. Redes neurais artificiais e agricultura de precisão para recomendação de adubação da cultura da goiabeira. **Revista Brasileira de Agrocomputação**, Ponta Grossa, v.2, n.1, p.37-42, Jun. 2004.

SOLANO, P. J. E. **Retenção de água e pedofunções para solos do Rio Grande do Sul**. 2003, 117f. Dissertação (Mestrado em Ciência do Solo)- Universidade Federal de Santa Maria, Santa Maria, 2003.

SOMARATNE, S., SENEVIRATNE G., COOMARASWAMY U. Prediction of soil organic carbon across different land-use patterns: a neural network approach. **Soil Sci. Soc. Am. J.**, 69:1580-1589, 2005.

SPERA, S. T. et al. Características físicas de um Latossolo Vermelho-Escuro no cerrado de Planaltina, DF, submetido à ação do fogo. **Pesquisa Agropecuária Brasileira**, Brasília, v.35, p.1817-1824, 2000.

SPOHR, R. B. **Influência das características físicas do solo nas perdas de água por escoamento superficial no sul do Brasil e no Uruguai**. 2007. 105 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Santa Maria. Santa Maria, 2007.

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

STRECK, C. A. **Índices e fluxo de água e ar em solos do sul do Brasil**. 2007. 95f. Tese (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria. Santa Maria, 2007.

STRECK, E. V. et al. **Solos do Rio Grande do Sul**. 2 ed. Porto Alegre.: EMATER/RS; UFRGS. 2008. 222p

STRINI, E. J. **Previsão da incidência de dengue por meio de redes neurais artificiais**. 2006. 52 p. Monografia (Curso de Informática Biomédica) – Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2006.

STURMER, S. L. K. **Infiltração de água em neossolos regolíticos do rebordo do planalto do Rio Grande do Sul**. 2008. 104f. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria. Santa Maria, 2008.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. **Journal of Irrigation and Drainage Engineering**, v. 129, n. 3, p. 214-218, 2003.

TAMARI, S.; WÖSTEN, J. H. M.; RUIZ-SUÁREZ, J. C. Testing an artificial neural network for predicting soil hydraulic conductivity. **Soil Science Society of America Journal**, Madison, v. 60, p. 1732- 1741, 1996.

TAVARES, M. H. F.; FELICIANO, J. J. da S.; VAZ, C. M. P. Análise comparativa de métodos para determinação da curva de retenção de água em solos. **Irriga**, Botucatu, v. 13, n. 4, p. 517-524, 2008.

TEIXEIRA, C. F. A.; MORAES, S. O.; SIMONETE, M. A. Desempenho do tensiômetro, TDR e sonda de nêutrons na determinação da umidade e condutividade hidráulica do solo. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 161-168, 2005.

TESSIER, D.; BIGORRE, F.; BRUAND, A., La capacité d'échange: outil de prévision des propriétés physiques des sols. **Académie d'Agriculture, France**, v.85, p.37–46, 1999.

THOMAS, G. W.; MOODIE, J. E. Chemical relationships affecting the water-holding capacities of clays. **Soil Science Society of America Proceedings**, Madison v.33, p.645-651. 1962.

TIETJE, O.; HENNINGS, V. Accuracy of the saturated hydraulic conductivity prediction by pedo-transfer functions compared to the variability within FAO textural classes. **Geoderma**, Amsterdam, v. 69, p. 71-84, 1996.

TIETJE, O.; TAPKENHINRICH, M. Evaluation of pedo-transfer functions. **Soil Science Society of America Journal**, Madison, WI, v.57, p.1088-1095, 1993.

TIMM, L. C. et al. Neural network and state-space models for studying relationships among soil properties. **Scientia Agricola**, Piracicaba, v. 63, p. 386-395, 2006.

TOMASELLA, J.; HODNETT, M.G.; ROSSATO, L. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. **Soil Science Society of America Journal**, Madison, v.64, p.327- 338, 2000.

TOMASELLA, J.; HOODNETT, M. G.. Estimating soil water characteristics from limited data in Brazilian Amazonia. **Soil Science**, Philadelphia, v.163, p.190- 202, 1998.

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**, Viçosa, v.26, n.2, p.305-314, 2002.

TYLER, S.W.; WHEATCRAFT, S.W. Application of fractal mathematics to soil water retention estimation. **Soil Science Society of America Journal**, Madison, v.53, p.987-996, 1989.

UHDE, S. L. T. **Sistema pedológico de um ambiente antropizado da depressão central do RS**. 2009. 226 f. Tese (Doutorado em Ciência do Solo) - Universidade Federal de Santa Maria. Santa Maria, 2009.

ULSON, J. A. C. et al. Sistema de controle inferencial baseado em redes neurais artificiais para aplicação de fertilizante fluido a taxas variáveis. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 33. 2001, Foz do Iguaçu. **Anais...** Foz do Iguaçu: Sociedade Brasileira de Engenharia Agrícola, 2001. 1 CD-ROM.

URACH, F. L. **Estimativa da retenção de água em solos para fins de irrigação**. 2007, 78 f. Dissertação (Mestrado em Ciência do Solo)- Universidade Federal de Santa Maria, Santa Maria, 2007.

VAN den BERG, M. et al Pedotransfer functions for the estimation of moisture characteristics of Ferralsols and related soils. **Geoderma**, Amsterdam, v.78, p.:161-180, 1997.

VAN DIEPEN. et al. Land evaluation: From intuition to quantification. **Advances in Soil Science**, Philadelphia, v.15, p.139-204, 1991.

VAN GENUCHTEN, M. T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, Madison, v.44, p.892-898, 1980.

VASCONCELOS, E. B. **Levantamento dos atributos físicos e hídricos de três solos de várzea do Rio Grande do Sul**. 1993. 79 p. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Pelotas, Pelotas, 1993.

VAZ, C .M. P.; NAIME, J. M.; MACEDO, A. Soil particle size fractions determined by gamma-ray attenuation. **Soil Science**, Philadelphia, v. 164, p. 403-410, 1999.

VAZ, C. M. P.; NAIME, J. M.; MACEDO, A. **Analizador granulométrico de solos**. São Carlos, EMBRAPA/CNPDIA- comunicado técnico, n.5. 1996, 5p.

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

VERECKEN, H.; FEYEN, J.; MAES, J. Estimating the soil moisture retention characteristic from texture, bulk density and carbon content. **Soil Science**, Philadelphia, v.148, p.389–403, 1989.

VERECKEN, H.; MAES, J.; FEYEN, J. Estimating unsaturated hydraulic conductivity from easily measured soil properties. **Soil Science**, Philadelphia, v. 149, p. 389–403. 1990

VIEIRA, M. L. **Propriedades físico-hídrico-mecânicas do solo e rendimento de milho submetido a diferentes sistemas de manejo**. 2006.115 f. Dissertação (Mestrado em Agronomia)- Universidade de Passo Fundo, Passo Fundo, 2006.

VIEIRA, T. G. C.; LACERDA, W. S.; BOTELHO, T. G. Mapeamento de áreas cafeeiras utilizando redes neurais artificiais: Estudo de caso na região de Três Pontas, Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009. **Anais...** Natal. INPE, 2009. p. 7947-7954.

VOMOCIL, J. A. Porosity. In: Black, C.A.(ed.) **Methods of soil analysis. Part 1. Physical and mineralogical properties, including statistics of measurement and sampling**. Madison: **American Society of Agronomy**, p.499-510. 1965.

WASSERMAN, P. D. **Neural Computing : Theory and Practice**. New York : Van Nostrand Reinhold, 1989.

WEBER, L. S. **Integração de dados espectrais e indicadores meteorológicos por meio de redes neurais para a estimativa de produtividade de cana-de-açúcar**. 2005, 128 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 2005.

WERBOS, P. **Beyond Regression: New Tools For Prediction and Analysis in the Behavioral Sciences**. PhD thesis, Harvard University, 1974.

WIDROW, B.; HOFF, M. E. Adaptive switching circuits. Institute of Radio Engineers. **Western Electronic Show and Convention**. v. 4, p. 96–104. 1960.

WILLIAMS, R. D.; AHUJA, L. R.; NANEY, J. W. Comparison of methods to estimate soil water characteristics from soil texture, bulk density, and limited data. **Soil Science**, Philadelphia, v.153, p.172-184, 1992.

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

WOSTEN, J. H. M.; VAN GENUCHTEN, M. T. Using texture and other soil properties to predict the unsaturated soil hydraulic functions. **Soil Science Society of America Journal**, Madison, v. 52, p. 1762- 1770, 1988.

WÖSTEN, J. H. M. et al. Functional sensitivity analysis of four methods to generate soil hydraulic functions. **Soil Science Society of America Journal**, Madison, v.54, p.832-836, 1990.

WÖSTEN, J.; FINKE, P.; JANSEN, M. Comparison of class and continuous pedotransfer functions to generate soil hydraulic characteristics. **Geoderma**, Amsterdam, v.66, p.227-237, 1995.

WÖSTEN, J. H. M. et al. **Using existing soil data to derive hydraulic parameters for simulation model in environmental studies and in land use planning**: Final Report on the European Union Funded Project, DLO Staring Centre, Wageningen, 1998. 106p. (Report 156).

WÖSTEN, J. H. M. et al. Development and use of database of hydraulic properties of European soils. **Geoderma**, Amsterdam, v. 90, p. 169–185. 1999.

WÖSTEN, J. H. M.; PACHEPSKY, Y. A., RAWLS, W.J. Pedotransfer functions: bridging gap between available basic soil data and missing soil hydraulic characteristics. **Journal of Hydrology**, Amsterdam, v. 251, p.123-150, 2001.

YANG, C. C.; LACROIX, R; PRASHER, S.;O. The use of back-propagation neural networks for the simulation and analyses of time-series data in subsurface drainagesystems. **Transactions of the ASAE**, St. Joseph, v. 41, n. 4, p. 1181-1187, 1998.

YOUNG, M. I.; CRAWFORD, J. M.; RAPPOLDT, C. New methods and models for characterizing structural heterogeneity of soil. **Soil & Tillage Research**, Texas, v. 61, n.1, p. 33-45, 2001.

ZELL, A. et al. **SNNS – Stuttgart Neural Network Simulator v.4.2, user manual**. Stuttgart: University of Stuttgart/University of Tübingen, 1998. 338p.

APÊNDICES

Apêndice A – Treinamento de diferentes arquiteturas para estimativa da umidade do solo arenoso nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.009956	0.099056	0.000198	0.050189	0.000173	0.122544	0.000919	0.102416
0.110489	0.110489	0.000751	0.016269	0.000122	0.044631	0.000527	0.119976
0.000124	0.054679	0.000508	0.061317	0.000110	0.024854	0.000263	0.110178
0.683959	0.683959	0.000138	0.029853	0.002565	0.019176	0.000263	0.024842
0.003579	0.180249	0.000211	0.043743	0.001205	0.037550	0.000222	0.034604
0.000137	0.112057	0.000447	0.012050	0.001793	0.287995	0.000239	0.087491
0.007445	0.053484	0.004403	0.084326	0.005204	0.030818	0.000236	0.094896
0.014988	0.010337	0.000294	0.031262	0.000330	0.151705	0.000202	0.083677
0.030667	0.059013	0.000213	0.032544	0.000555	0.051508	0.001944	0.065004
0.684403	0.004127	0.000013	0.020580	0.000015	0.021629	0.002278	0.017904
0.000805	0.166758	0.001618	0.022463	0.000628	0.048611	0.117307	0.003816
0.112057	0.001351	0.005545	0.063309	0.000159	0.109891	0.037328	0.017603
0.053484	0.014988	0.000132	0.315444	0.000310	0.042790	0.022514	0.012618
0.052816	0.008227	0.000042	0.404938	0.000154	0.049248	0.022514	0.003048
0.000056	0.001677	0.000880	0.043386	0.000341	0.305183	0.021812	0.009954
0.166758	0.001442	0.001139	0.013791	0.001282	0.141922	0.027989	0.004948

Apêndice B – Treinamento de diferentes arquiteturas para estimativa da umidade do solo arenoso franco nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.001927	0.257148	0.000434	0.063197	0.000670	0.056626	0.000836	0.040878
0.000538	0.154127	0.001103	0.010363	0.001818	0.080620	0.000842	0.106107
0.002221	0.084961	0.001037	0.047989	0.002457	0.057639	0.002943	0.506872
0.003234	0.198602	0.000334	0.039207	0.002080	0.068764	0.000367	0.021665
0.000208	0.036663	0.000142	0.157169	0.000338	0.113961	0.000326	0.032725
0.000572	0.047210	0.000120	0.012008	0.000595	0.021310	0.001403	0.565008
0.000159	0.027899	0.000147	0.021775	0.000439	0.108132	0.000253	0.002852
0.000010	0.001306	0.000379	0.213621	0.000290	0.001357	0.000734	0.040970
0.000235	0.045476	0.001321	0.061590	0.001146	0.003580	0.000166	0.065831
0.000000	0.050192	0.000227	0.122860	0.003745	0.000196	0.000399	0.000155
0.000576	0.001371	0.000269	0.003096	0.000128	0.809648	0.000172	0.141988
0.000341	0.003188	0.000192	0.003010	0.000249	0.000140	0.000245	0.198066
0.005992	0.515591	0.000352	0.001031	0.005240	0.740700	0.000249	0.050311
0.002605	0.004229	0.000579	0.004520	0.000443	0.057957	0.000165	0.000411
0.000036	0.056926	0.005842	0.039361	0.006734	0.017298	0.000165	0.067961
0.001927	0.257148	0.000220	0.010467	0.008349	0.054246	0.000167	0.000000

Apêndice C – Treinamento de diferentes arquiteturas para estimativa da umidade do solo argiloso nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.002427	0.178561	0.002561	0.181404	0.002606	0.181404	0.002784	0.161774
0.002354	0.129633	0.002063	0.118423	0.002373	0.126583	0.003079	0.132404
0.002378	0.125368	0.002290	0.149020	0.002397	0.151826	0.002936	0.142972
0.002330	0.112627	0.001924	0.123473	0.002193	0.133626	0.002988	0.139302
0.002169	0.116008	0.002419	0.184204	0.002446	0.120707	0.002762	0.178941
0.002115	0.111108	0.002244	0.133659	0.002309	0.118325	0.002452	0.142185
0.002137	0.131760	0.002211	0.150794	0.002161	0.150794	0.002534	0.127279
0.002099	0.136445	0.002201	0.128474	0.002463	0.128611	0.002792	0.142519
0.002007	0.137116	0.002172	0.127185	0.002059	0.137217	0.002256	0.133921
0.002003	0.160973	0.002182	0.137217	0.002146	0.130626	0.002599	0.140517
0.001943	0.125802	0.002016	0.136395	0.001912	0.140192	0.002777	0.114157
0.002352	0.120024	0.001908	0.120114	0.001813	0.128327	0.002860	0.134506
0.002316	0.124723	0.002001	0.123729	0.001621	0.133299	0.002811	0.127279
0.002010	0.132191	0.001764	0.121623	0.002884	0.111895	0.002504	0.142784
0.002018	0.146724	0.001836	0.117671	0.002886	0.117534	0.002840	0.136545
0.002081	0.161251	0.001793	0.112306	0.001830	0.159242	0.002603	0.119516

Apêndice D – Treinamento de diferentes arquiteturas para estimativa da umidade do solo franco nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.003080	0.156359	0.003732	0.248712	0.003927	0.193072	0.004690	0.260281
0.003824	0.166032	0.003159	0.113667	0.003340	0.174874	0.004644	0.155458
0.003147	0.132180	0.002895	0.149933	0.003765	0.204060	0.004271	0.162900
0.003379	0.221153	0.003440	0.128330	0.003718	0.157734	0.003554	0.169924
0.002016	0.127791	0.002556	0.175998	0.003038	0.195552	0.003703	0.130328
0.003808	0.198533	0.003111	0.172025	0.003110	0.135464	0.003921	0.219024
0.003267	0.147680	0.003144	0.116035	0.003995	0.162635	0.003825	0.177846
0.003669	0.162970	0.003370	0.152287	0.003455	0.163021	0.003491	0.185617
0.003875	0.134748	0.003212	0.211194	0.002999	0.195155	0.003876	0.172066
0.002606	0.159394	0.002597	0.135015	0.002922	0.151610	0.003702	0.189902
0.003859	0.130542	0.002624	0.145209	0.003961	0.226463	0.003795	0.203364
0.002665	0.162231	0.002749	0.149148	0.003360	0.213511	0.003902	0.162702
0.002243	0.143617	0.002217	0.141195	0.003133	0.180768	0.004679	0.208436
0.002483	0.115220	0.001410	0.203967	0.003470	0.183303	0.001987	0.094662
0.003200	0.260985	0.002613	0.127448	0.002910	0.247682	0.003006	0.162206
0.003155	0.153888	0.003311	0.196442	0.003108	0.135997	0.003054	0.168456

Apêndice E – Treinamento de diferentes arquiteturas para estimativa da umidade do solo franco siltoso nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.001212	0.113385	0.001427	0.151037	0.001318	0.138199	0.001710	0.152383
0.001167	0.119560	0.000981	0.096615	0.001689	0.115810	0.002227	0.100878
0.001490	0.109801	0.001124	0.090581	0.001338	0.109328	0.001662	0.144999
0.001282	0.097945	0.001604	0.120184	0.001304	0.130193	0.001891	0.129129
0.001233	0.120743	0.001138	0.112035	0.001231	0.081031	0.001873	0.143933
0.000973	0.090578	0.001236	0.110574	0.001430	0.098133	0.001873	0.088566
0.001436	0.107955	0.000923	0.091438	0.000996	0.075714	0.001751	0.109651
0.000400	0.078320	0.000935	0.163281	0.001257	0.108543	0.001695	0.108841
0.000799	0.086289	0.000704	0.180607	0.001123	0.080485	0.001881	0.141890
0.000402	0.075691	0.000755	0.059192	0.000675	0.119002	0.001383	0.100784
0.000856	0.080298	0.000736	0.070758	0.000730	0.100037	0.001581	0.112707
0.000736	0.060425	0.000380	0.088925	0.001063	0.053317	0.001866	0.114718
0.000541	0.091533	0.001142	0.074270	0.000948	0.053861	0.000809	0.056268
0.001164	0.077872	0.000389	0.130410	0.000260	0.056515	0.001488	0.074667
0.000678	0.061802	0.001063	0.066310	0.000879	0.123033	0.001516	0.173749
0.000304	0.057932	0.000453	0.056611	0.000351	0.077592	0.000624	0.129986

Apêndice F – Treinamento de diferentes arquiteturas para estimativa da umidade do solo muito argiloso nos diferentes potenciais

Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Erro quadrático médio (treinamento)	Erro relativo médio (validação)
7 variáveis de entrada		6 variáveis de entrada		5 variáveis de entrada		4 variáveis de entrada	
0.002054	0.100656	0.002353	0.115032	0.001388	0.108306	0.003353	0.118428
0.001572	0.104180	0.002355	0.112095	0.001993	0.105006	0.002984	0.113551
0.002109	0.105956	0.001844	0.106707	0.001680	0.106699	0.002225	0.100161
0.001774	0.110261	0.001347	0.106729	0.001862	0.090945	0.002551	0.115493
0.001585	0.097953	0.001400	0.099820	0.002156	0.103852	0.002376	0.128295
0.001373	0.087161	0.001544	0.105638	0.001744	0.097137	0.002710	0.094185
0.001457	0.088874	0.001568	0.095085	0.001571	0.107556	0.002163	0.103834
0.001694	0.076482	0.001666	0.096952	0.001982	0.089729	0.001672	0.133210
0.001140	0.079231	0.001449	0.101963	0.001564	0.084751	0.002503	0.129417
0.000815	0.094195	0.001058	0.084284	0.001393	0.085005	0.002774	0.070005
0.001248	0.075954	0.001250	0.070142	0.001205	0.075021	0.002238	0.138821
0.001598	0.089172	0.001491	0.093103	0.000956	0.076016	0.002351	0.101081
0.000892	0.084414	0.000884	0.070382	0.000977	0.071342	0.002457	0.096962
0.001356	0.075776	0.001266	0.074005	0.001729	0.073861	0.002187	0.080415
0.001488	0.084829	0.001068	0.086342	0.000794	0.077215	0.001828	0.085947
0.001327	0.072397	0.001092	0.074218	0.001183	0.073441	0.001623	0.088533

Apêndice G - Resultados da rede-2, para estimativa da umidade do solo arenoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.000919	0.102416	0.045013
4-6-7	0.000527	0.119976	0.030998
4-7-7	0.000263	0.110178	0.032559
4-8-7	0.000263	0.024842	0.096734
4-9-7	0.000222	0.034604	0.070404
4-10-7	0.000239	0.087491	0.042573
4-13-7	0.000236	0.094896	0.047684
4-15-7	0.000202	0.083677	0.030464
4-18-7	0.001944	0.065004	0.055771
4-21-7	0.002278	0.017904	0.091004
4-24-7	0.117307	0.003816	0.098425
4-27-7	0.037328	0.017603	0.089011
4-30-7	0.022514	0.012618	0.071387
4-35-7	0.022514	0.003048	0.110804
4-40-7	0.021812	0.009954	0.083635
4-50-7	0.027989	0.004948	0.093778

Apêndice H - Resultados da rede-3, para estimativa da umidade do solo arenoso franco nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.000836	0.040878	0.055373
4-6-7	0.000842	0.106107	0.016364
4-7-7	0.002943	0.506872	0.126008
4-8-7	0.000367	0.021665	0.021461
4-9-7	0.000326	0.032725	0.057812
4-10-7	0.001403	0.565008	0.058919
4-13-7	0.000253	0.002852	0.088528
4-15-7	0.000734	0.040970	0.063389
4-18-7	0.000166	0.065831	0.061914
4-21-7	0.000399	0.000155	0.065066
4-24-7	0.000172	0.141988	0.072213
4-27-7	0.000245	0.198066	0.054971
4-30-7	0.000249	0.050311	0.098702
4-35-7	0.000165	0.000411	0.145133
4-40-7	0.000165	0.067961	0.038138
4-50-7	0.000167	0.000000	0.024638

Apêndice I - Resultados da rede-4, para estimativa da umidade do solo argiloso arenoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.001949	0.101101	0.036239
4-6-7	0.002549	0.170644	0.022354
4-7-7	0.002594	0.182816	0.021045
4-8-7	0.002725	0.106420	0.039815
4-9-7	0.002761	0.202860	0.014007
4-10-7	0.002526	0.113610	0.041373
4-13-7	0.002846	0.100054	0.040075
4-15-7	0.002469	0.107225	0.027899
4-18-7	0.002736	0.134395	0.051249
4-21-7	0.001908	0.134536	0.022555
4-24-7	0.001577	0.212801	0.013658
4-27-7	0.001977	0.145847	0.029533
4-30-7	0.003066	0.174207	0.031317
4-35-7	0.001909	0.171303	0.015478
4-40-7	0.001900	0.139314	0.034858
4-50-7	0.001277	0.060055	0.021503

Apêndice J - Resultados da rede-5, para estimativa da umidade do solo argiloso siltoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.003829	0.140370	0.038242
4-6-7	0.002984	0.162862	0.098242
4-7-7	0.002485	0.158817	0.121812
4-8-7	0.015342	0.057182	0.278920
4-9-7	0.005018	0.201794	0.055257
4-10-7	0.013135	0.038432	0.232681
4-13-7	0.002554	0.154114	0.057604
4-15-7	0.010475	0.083697	0.270262
4-18-7	0.000691	0.000009	0.029011
4-21-7	0.004656	0.060627	0.150301
4-24-7	0.004941	0.126858	0.026251
4-27-7	0.007954	0.021890	0.303239
4-30-7	0.005309	0.305937	0.083491
4-35-7	0.004683	0.003451	0.098942
4-40-7	0.001252	0.024514	0.232232
4-50-7	0.007357	0.003566	0.153941

Apêndice K - Resultados da rede-6, para estimativa da umidade do solo argiloso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.002784	0.161774	0.030985
4-6-7	0.003079	0.132404	0.033971
4-7-7	0.002936	0.142972	0.037165
4-8-7	0.002988	0.139302	0.025664
4-9-7	0.002762	0.178941	0.039211
4-10-7	0.002452	0.142185	0.048201
4-13-7	0.002534	0.127279	0.038317
4-15-7	0.002792	0.142519	0.041435
4-18-7	0.002256	0.133921	0.030204
4-21-7	0.002599	0.140517	0.038627
4-24-7	0.002777	0.114157	0.034644
4-27-7	0.002860	0.134506	0.035182
4-30-7	0.002811	0.127279	0.037522
4-35-7	0.002504	0.142784	0.040635
4-40-7	0.002840	0.136545	0.036884
4-50-7	0.002603	0.119516	0.044977

Apêndice L - Resultados da rede-7, para estimativa da umidade do solo franco nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.004690	0.260281	0.018502
4-6-7	0.004644	0.155458	0.029545
4-7-7	0.004271	0.162900	0.050606
4-8-7	0.003554	0.169924	0.032945
4-9-7	0.003703	0.130328	0.023752
4-10-7	0.003921	0.219024	0.031465
4-13-7	0.003825	0.177846	0.036697
4-15-7	0.003491	0.185617	0.037210
4-18-7	0.003876	0.172066	0.030701
4-21-7	0.003702	0.189902	0.021682
4-24-7	0.003795	0.203364	0.015998
4-27-7	0.003902	0.162702	0.017529
4-30-7	0.004679	0.208436	0.020507
4-35-7	0.001987	0.094662	0.027025
4-40-7	0.003006	0.162206	0.034372
4-50-7	0.003054	0.168456	0.015765

Apêndice M - Resultados da rede-8, para estimativa da umidade do solo franco arenoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.002991	0.231299	0.012211
4-6-7	0.002856	0.220143	0.012119
4-7-7	0.002892	0.248814	0.010346
4-8-7	0.003267	0.211930	0.014359
4-9-7	0.003453	0.174201	0.021006
4-10-7	0.003547	0.236179	0.009931
4-13-7	0.003819	0.214722	0.013432
4-15-7	0.002653	0.229548	0.016573
4-18-7	0.003656	0.246622	0.012174
4-21-7	0.003055	0.249896	0.012496
4-24-7	0.002899	0.221392	0.010097
4-27-7	0.003806	0.191952	0.015588
4-30-7	0.002524	0.229548	0.017802
4-35-7	0.002776	0.191952	0.009832
4-40-7	0.003644	0.186559	0.009123
4-50-7	0.003593	0.240990	0.020185

Apêndice N - Resultados da rede-9, para estimativa da umidade do solo franco argilo arenoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.003783	0.210013	0.016104
4-6-7	0.004278	0.266307	0.009544
4-7-7	0.004131	0.212392	0.009879
4-8-7	0.003500	0.221162	0.029375
4-9-7	0.002988	0.185116	0.015917
4-10-7	0.003261	0.206814	0.012603
4-13-7	0.005025	0.218922	0.016510
4-15-7	0.003285	0.180587	0.016203
4-18-7	0.002979	0.171858	0.009601
4-21-7	0.003793	0.275840	0.019250
4-24-7	0.002870	0.192784	0.016137
4-27-7	0.003188	0.208235	0.008598
4-30-7	0.003018	0.235793	0.019607
4-35-7	0.002937	0.177558	0.021502
4-40-7	0.003007	0.254708	0.031273
4-50-7	0.002565	0.179496	0.015166

Apêndice O - Resultados da rede-10, para estimativa da umidade do solo franco argilo siltoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.004785	0.114642	0.127262
4-6-7	0.002840	0.079612	0.091432
4-7-7	0.000956	0.083625	0.129970
4-8-7	0.000855	0.005948	0.177989
4-9-7	0.001014	0.101945	0.113018
4-10-7	0.000660	0.029579	0.079031
4-13-7	0.002121	0.124543	0.136392
4-15-7	0.000767	0.002146	0.091927
4-18-7	0.000309	0.010229	0.130778
4-21-7	0.000431	0.002125	0.188765
4-24-7	0.000593	0.006221	0.113590
4-27-7	0.000172	0.002942	0.164308
4-30-7	0.000271	0.024067	0.228580
4-35-7	0.000119	0.000072	0.080389
4-40-7	0.003231	0.026363	0.148418
4-50-7	0.002202	0.003085	0.150252

Apêndice P - Resultados da rede-11, para estimativa da umidade do solo franco argiloso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.004096	0.165009	0.016814
4-6-7	0.004455	0.219320	0.026523
4-7-7	0.003659	0.190476	0.038213
4-8-7	0.003480	0.151840	0.025827
4-9-7	0.002827	0.227612	0.015495
4-10-7	0.002486	0.233298	0.026971
4-13-7	0.003509	0.157570	0.028231
4-15-7	0.002656	0.179382	0.024336
4-18-7	0.003395	0.174117	0.030621
4-21-7	0.002837	0.139288	0.040790
4-24-7	0.002483	0.104899	0.048052
4-27-7	0.002158	0.191509	0.047133
4-30-7	0.002521	0.148539	0.029058
4-35-7	0.001456	0.184236	0.052983
4-40-7	0.002603	0.172967	0.033526
4-50-7	0.002104	0.159007	0.059832

Apêndice Q - Resultados da rede-12, para estimativa da umidade do solo franco siltoso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.001710	0.152383	0.036662
4-6-7	0.002227	0.100878	0.069878
4-7-7	0.001662	0.144999	0.080356
4-8-7	0.001891	0.129129	0.036858
4-9-7	0.001873	0.143933	0.040213
4-10-7	0.001873	0.088566	0.054773
4-13-7	0.001751	0.109651	0.041244
4-15-7	0.001695	0.108841	0.047680
4-18-7	0.001881	0.141890	0.022438
4-21-7	0.001383	0.100784	0.041617
4-24-7	0.001581	0.112707	0.039264
4-27-7	0.001866	0.114718	0.055227
4-30-7	0.000809	0.056268	0.011589
4-35-7	0.001488	0.074667	0.044543
4-40-7	0.001516	0.173749	0.026877
4-50-7	0.000624	0.129986	0.070794

Apêndice R - Resultados da rede-13, para estimativa da umidade do solo muito argiloso nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.003353	0.118428	0.118428
4-6-7	0.002984	0.113551	0.126880
4-7-7	0.002225	0.100161	0.118209
4-8-7	0.002551	0.115493	0.112004
4-9-7	0.002376	0.128295	0.113039
4-10-7	0.002710	0.094185	0.125576
4-13-7	0.002163	0.103834	0.133210
4-15-7	0.001672	0.133210	0.159034
4-18-7	0.002503	0.129417	0.110084
4-21-7	0.002774	0.070005	0.070005
4-24-7	0.002238	0.138821	0.112755
4-27-7	0.002351	0.101081	0.109863
4-30-7	0.002457	0.096962	0.084044
4-35-7	0.002187	0.080415	0.099491
4-40-7	0.001828	0.085947	0.085947
4-50-7	0.001623	0.088533	0.068955

Apêndice S - Resultados da rede-1, para estimativa da umidade do solo para o banco de dados geral, nos diferentes potenciais

Arquitetura	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
4-5-7	0.003968	0.212555	0.020400
4-6-7	0.003915	0.190184	0.015399
4-7-7	0.003914	0.206286	0.017469
4-8-7	0.004074	0.185819	0.022562
4-9-7	0.003834	0.190388	0.019149
4-10-7	0.003796	0.195381	0.022840
4-13-7	0.003456	0.192597	0.023143
4-15-7	0.003393	0.184382	0.021299
4-18-7	0.003629	0.203360	0.024695
4-21-7	0.003559	0.187545	0.017242
4-24-7	0.003577	0.221376	0.023248
4-27-7	0.003325	0.185390	0.016659
4-30-7	0.003581	0.236646	0.024506
4-35-7	0.003028	0.206337	0.020755
4-40-7	0.003594	0.187705	0.031462
4-50-7	0.003351	0.176653	0.023008