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

ESTIMATIVA DOS PARÂMETROS DA RESISTÊNCIA DO SOLO AO CISALHAMENTO ATRAVÉS DE PEDOTRANSFERÊNCIA

TESE DE DOUTORADO

FABIANO DE VARGAS ARIGONY BRAGA

Santa Maria, RS, Brasil
2014

ESTIMATIVA DOS PARÂMETROS DA RESISTÊNCIA DO SOLO AO CISALHAMENTO ATRAVÉS DE PEDOTRANSFERÊNCIA

FABIANO DE VARGAS ARIGONY BRAGA

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, Área de Concentração Engenharia de Água e Solo, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de
Doutor em Engenharia Agrícola

Orientador: Dr. ADROALDO DIAS ROBAINA

Santa Maria, RS, Brasil
2014

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

de Vargas Arigony Braga, Fabiano
ESTIMATIVA DOS PARÂMETROS DA RESISTÊNCIA DO SOLO AO CISALHAMENTO ATRAVÉS DE PEDOTRANSFERÊNCIA / Fabiano de Vargas Arigony Braga.-2014.
98 p.; 30cm

Orientador: Adroaldo Dias Robaina
Coorientadora: Márcia Xavier Peiter
Tese (doutorado) - Universidade Federal de Santa Maria, Centro de Ciências Rurais, Programa de Pós-Graduação em Engenharia Agrícola, RS, 2014

1. Redes Neurais Artificiais 2. Regressão Linear Múltipla 3. Pedofunções 4. Coesão do solo 5. Ângulo de Atrito interno do solo I. Dias Robaina, Adroaldo II. Xavier Peiter, Márcia 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

ESTIMATIVA DOS PARÂMETROS DA RESISTÊNCIA DO SOLO AO CISALHAMENTO ATRAVÉS DE PEDOTRANSFERÊNCIA

elaborado por:
Fabiano de Vargas Arigony Braga

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

Comissão Examinadora:

Adroaldo Dias Robaina, Dr. (Presidente/Orientador)

Ricardo Luís Schons, Dr. (IFFarroupilha – Julio de Castilhos)

Fátima Cibele Soares, Dr. (UNIPAMPA – Alegrete)

João Fernando Zamberlan, Dr. (UNICRUZ)

Ana Rita Costenaro Parizi, Dr. (IFFarroupilha – Alegrete)

Santa Maria, RS, 11 de Julho de 2014.

Agradecimentos

Em primeiro lugar agradeço à Deus, força superior, que protege à mim e meus familiares me dando força a cada dia que passa para enfrentar alguns obstáculos que a vida oferece e me fazendo agradecer muito mais do que pedir.

À minha noiva-esposa Kelly Kercher Kettermann, pela paciência, amizade, amor, carinho e principalmente pelo maior presente de todos: a nossa filha Nicoly Kettermann Braga, minha princesa linda.

Aos meus queridos pais Osiris Braga e Sonia Braga e irmão Fabrício Braga, que servem de exemplo para mim e são a base da minha educação e em toda minha vida incentivaram ao estudo e a persistência.

À Universidade Federal de Santa Maria, pela oportunidade de concluir minha graduação em Agronomia, mestrado em Engenharia Agrícola e agora Doutorado em Engenharia Agrícola.

À CAPES, pela bolsa concedida.

Muito obrigado aos meus orientadores professor Adroaldo Dias Robaina e Márcia Xavier Peiter, pela orientação, carinho, amizade, parceria, sempre estando à disposição para colaborar com este trabalho da melhor forma possível.

Aos meus colegas de laboratório, pelo apoio, amizade e companheirismo em especial ao Tonismar dos Santos Pereira e Mario Santos Nunes.

Ao nosso amigão “Seu Luiz” por sempre estar disposto a ajudar seja qual for o problema.

Enfim, obrigado à todas as pessoas que de alguma forma, direta ou indiretamente contribuíram por esta nova vitória em minha vida.

Muito obrigado mesmo!!!

“...Te amo papai, te amo amor, te amo filho,
te amo irmão...” Família, base de tudo!!
Vontade de crescer e viver sempre!!
Obrigado senhor!

RESUMO

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

ESTIMATIVA DOS PARÂMETROS DA RESISTÊNCIA DO SOLO AO CISALHAMENTO ATRAVÉS DE PEDOTRANSFERÊNCIA

Autor: Fabiano de Vargas Arigony Braga
Orientador: Adroaldo Dias Robaina

Santa Maria, 11 de Julho de 2014

O crescimento da população mundial requer uma maior demanda de alimentos e uma das técnicas para suprir essa demanda é a irrigação. Uma das melhores alternativas para o armazenamento da água para utilizar na irrigação são as barragens de terra. A determinação precisa da coesão e do ângulo de atrito interno do solo é um critério essencial e de grande preocupação no processo de elaboração de projetos de barragens de terra, porém sua determinação é de alto custo e também um processo demorado. O objetivo deste trabalho é avaliar um modelo que permita uma estimativa da resistência do solo ao cisalhamento utilizando duas técnicas diferentes (análise multivariada e redes neurais artificiais) para a obtenção dos parâmetros de resistência (coesão e ângulo de atrito interno) em função da composição textural, densidade do solo, limites de Atterberg (plasticidade, liquidez e índice de plasticidade) e do grau de umidade do solo. Foram pesquisados na literatura diferentes banco de dados contendo as variáveis dependentes e independentes necessárias para realizar o estudo. Foram totalizados 6 conjunto de dados. Foram geradas FPTs por meio de regressão linear múltipla (RLM), método Stepwise, e redes neurais artificiais (RNA) com cada conjunto de dados. Por meio de RLM foram estimados coesão e ângulo de atrito separadamente, já pelas RNAs foram estimados de forma conjunta e de forma separada esses dois parâmetros mantendo a arquitetura (uma camada oculta) e variando a topologia das redes (10, 20, 30, 40, 50 e 70 neurônios na camada escondida). Após foi calculado o índice de desempenho (Id) e posterior classificação de cada FPT. Os resultados demonstraram a ineficiência nas RLMs para estimativa dos parâmetros e a superioridade das RNAs na predição da coesão e ângulo de atrito. A estimativa dos parâmetros conjuntamente mostra diferença nos resultados do que quando estimados de forma separada. Assim, a estimativa dos parâmetros cisalhantes do solo pelas RNAs, podem ser eficazes, para determinado conjunto de dados, nesse caso pertencentes às RNAs 3, 5 e 6.

Palavras-chave: Redes neurais. Pedofunções. Regressão linear múltipla.

ABSTRACT

Doctorate Thesis
Graduate Program in Agricultural Engineering

ESTIMATING OF THE SHEAR STRENGTH SOIL PARAMETERS THROUGH PEDOTRANSFER

Author: Fabiano de Vargas Arigony Braga
Advisor: Adroaldo Dias Robaina

Santa Maria, Jully 11th

The growing world population requires a higher demand for food and one of the techniques to meet this demand is irrigation. One of the best alternatives for the storage of water for use in irrigation are earth dams. The accurate determination of cohesion and angle of internal friction is an essential and of great concern in the drafting of earth dams process criteria, but their determination is expensive and also time consuming process. The objective of this study is to evaluate a model that allows an estimation of soil shear strength using two different techniques (multivariate analysis and artificial neural networks) to obtain the strength parameters (cohesion and angle of internal friction) as a function of textural composition , density, Atterberg limits (plasticity, liquidity and plasticity index) and the degree of soil moisture. Different database were searched in the literature with the dependent and independent variables needed to conduct the study. 6 dataset were totaled. PTFs were generated through multiple linear regression (MLR), stepwise, and artificial neural networks (ANN) with each data set. Through MLR were estimated friction angle and cohesion separately since the RNAs were estimated jointly and separately maintaining these two parameters form the architecture (one hidden layer) and varying the topology of the networks (10, 20, 30, 40 , 50 and 70 neurons in the hidden layer). After the performance index (Id) and subsequent classification of each FPT was calculated. The results demonstrated the inefficiency in MLRs to estimate parameters and the superiority of ANN to predict the cohesion and friction angle. Estimation of the parameters together shows different results than when estimated separately. Thus, the estimated shear the soil parameters RNAs can be effective for a given set of data, in this case belonging to RNAs 3, 5 and 6.

Keywords: Neural networks. Pedofuntions. Multiple linear regression.

LISTA DE TABELAS

Tabela 01 - Tipo de função de ativação, equação e sua representação gráfica……..... 43

Tabela 02 - Tipos de normalização utilizados nas RNAs..... 55

Tabela 03 - Neurônios ou variáveis independentes na camada de entrada.... 62

Tabela 04 - Classificação para o índice de desempenho do método proposto 66

Tabela 05 - Coeficiente de correlação (r) entre as variáveis independentes e a coesão e ângulo de atrito do solo para as Regressões Lineares Múltiplas 1, 2, 3, 4, 5 e 6..... 68

Tabela 06 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 1..... 71

Tabela 07 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 2..... 72

Tabela 08 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 3..... 74

Tabela 09 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 4..... 75

Tabela 10 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 5..... 76

Tabela 11 - Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 6..... 78

Tabela 12 - Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e classificação do desempenho, das diferentes RLMs utilizadas para estimativa da coesão e ângulo de atrito interno do solo..... 86

Tabela 13 - Valores do coeficiente de correlação (r), índice de concordância 88

(c), coeficiente de desempenho (id) e classificação do desempenho, das diferentes RNAs utilizadas para estimativa da coesão e ângulo de atrito interno do solo.....

LISTA DE FIGURAS

Figura 1 - Elementos característicos de uma barragem de terra 19

Figura 2 - Força P e suas componentes (Px tangencial e Py normal) e a força de resistência R..... 21

Figura 3 - Equipamento de cisalhamento direto..... 27

Figura 4 - Sistema de tensões no corpo de prova em ensaio triaxial..... 27

Figura 5 - Equipamento de ensaio triaxial..... 28

Figura 6 - Círculo de Mohr..... 30

Figura 7 - Aparelho para o ensaio de palheta..... 33

Figura 8 - Conjunto para cisalhamento de plástico torvane..... 34

Figura 9 - Estrutura simplificada de um neurônio biológico..... 38

Figura 10 - Modelo de neurônio base para projeto de uma RNA..... 41

Figura 11 - Redes neurais com duas camadas (simples) e múltiplas camadas.. 46

Figura 12 - Rede neural artificial multicamadas (Multilayer Perceptron)…….... 51

Figura 13 - Sentidos de cálculos do algoritmo backpropagation..... 52

Figura 14 - Exemplo de Arquitetura da rede neural utilizada..... 62

Figura 15 - Sequência de realização da rede neural..... 64

Figura 16 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM1 71

Figura 17 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM2 73

Figura 18 - Valores de coesão do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 3..... 74

Figura 19 - Valores de coesão do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 4..... 76

Figura 20 - Valores de ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 5..... 77

Figura 21 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM6 79

Figura 22 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b), para a RNA 1..... 80

Figura 23 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b), para a RNA 2..... 81

Figura 24 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b), para a RNA 3..... 82

Figura 25 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b), para a RNA 4..... 83

Figura 26 - Valores de ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial, para a RNA 5..... 84

Figura 27 - Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea e separada, para a RNA 6..... 85

SUMÁRIO

1 INTRODUÇÃO..... 15

2 REVISÃO DA LITERATURA..... 18

2.1 Barragens e estabilidade de taludes..... 18

2.2 Resistência do solo ao cisalhamento..... 22

2.3 Fatores que influenciam nos parâmetros de cisalhamento..... 23

2.4 Métodos de obtenção dos parâmetros (c, ϕ)..... 25

2.4.1 Métodos diretos de laboratório..... 26

2.4.2 Métodos diretos de Campo..... 32

2.4.3 Métodos indiretos..... 34

2.4.3.1 Regressão Linear Multipla (RLM)..... 35

2.4.3.2 Trabalhos de FTP - regressão linear múltipla..... 37

2.5 Estrutura de um neurônio biológico..... 37

2.6 Redes neurais artificiais..... 39

2.6.1 Vantagens da modelagem com redes neurais..... 40

2.6.2 Estrutura de um neurônio artificial..... 41

2.6.3 Arquitetura e topologia da rede neural artificial..... 44

2.6.4 Classificação das redes neurais..... 46

2.6.5 Aprendizado ou Treinamento..... 47

2.6.6 Regras de Aprendizagem..... 49

2.6.7 Rede Neurais Perceptron de Múltiplas Camadas (MLP)..... 50

2.7 Modelando Redes Neurais..... 53

2.7.1 Coleta de dados..... 53

2.7.2 Divisão dos dados..... 54

2.7.3 Normalização dos dados..... 54

2.7.4 Determinação das variáveis de entrada..... 55

2.7.5 Arquitetura da rede..... 56

2.7.6 Treinamento das redes..... 56

2.7.7 Verificação do desempenho..... 57

2.8 Aplicação das Redes Neurais Artificiais na geotecnia..... 57

3 MATERIAL E MÉTODOS..... 59

3.1 Coleta de dados..... 59

3.2 Pedotransferência com RLM..... 60

3.2.1 Ângulo de atrito interno do solo e Coesão do solo..... 60
3.3 Pedotransferência com RNA..... 61
3.3.1 Definição do problema..... 61
3.3.2 Seleção dos neurônios na camada de entrada (dados de entrada)..... 61
3.3.3 Definição do número de camadas escondidas e do número de neurônios..... 62
3.3.4 Definição do treinamento da rede neural e avaliação do desempenho... 63
3.3.5 Validação da rede neural..... 64
3.4 Análise dos dados..... 65
4 RESULTADOS E DISCUSSÃO..... 67
4.1 Correlação entre as variáveis independentes e os parâmetros cisalhantes do solo das diferentes RLMs..... 67
4.2 FPTs obtidas por Regressão Linear Múltipla (RLM)..... 70
4.2.1 Estimativa dos parâmetros de cisalhamento do solo – RLM 1..... 70
4.2.2 Estimativa dos parâmetros de cisalhamento do solo – RLM 2..... 72
4.2.3 Estimativa dos parâmetros de cisalhamento do solo – RLM 3..... 73
4.2.4 Estimativa dos parâmetros de cisalhamento do solo – RLM 4..... 75
4.2.5 Estimativa dos parâmetros de cisalhamento do solo – RLM 5..... 76
4.2.6 Estimativa dos parâmetros de cisalhamento do solo – RLM 6..... 77
4.3 FPTs obtidas pelas Redes Neurais Artificiais (RNA)..... 79
4.3.1 Rede neural artifical 1 – RNA 1..... 79
4.3.2 Rede neural artifical 1 – RNA 2..... 81
4.3.3 Rede neural artifical 1 – RNA 3..... 82
4.3.4 Rede neural artifical 1 – RNA 4..... 83
4.3.5 Rede neural artifical 1 – RNA 5..... 84
4.3.6 Rede neural artifical 1 – RNA 6..... 84
4.4 Desempenho das FPTs desenvolvidas através de RLM e RNA..... 86
4.4.1 Desempenho das RLMs..... 86
4.4.2 Desempenho das RNAs..... 87
5 CONCLUSÕES..... 89
6 REFERÊNCIAS BIBLIOGRÄFICAS..... 90

1 INTRODUÇÃO

O crescimento da população mundial requer uma maior necessidade por alimentos, com isso o setor agrícola está em busca de novas técnicas que permitam o aumento da qualidade e quantidade da produção. A irrigação é uma das ferramentas que vem sendo adotada para o aumento da produtividade, mas no entanto, o seu uso não racional associado à falta de fontes de armazenamento da água, limitam sua utilização na expansão da produção agrícola.

A construção de barragens, como obra da engenharia, é uma das alternativas para a captação de água em períodos de chuva abundante e mantê-la como reserva para situações de escassez de água, podendo assim ser utilizada na irrigação agrícola. Para garantir a segurança das barragens o seu projeto deve ser concebido para ser estável no tempo, aumentando a sua durabilidade e consequentemente a diminuição do seu custo anual. Dentre os problemas construtivos de uma barragem de terra um dos mais significativos se refere à estabilidade dos seus taludes (montante e jusante), que depende fortemente da resistência do solo utilizado para a construção. O planejamento (levantamento e projeto) de uma barragem de terra deve se basear nos tipos de solos disponíveis em qualidade e quantidade para sua construção.

A caracterização física do solo, como variável a serem considerados na construção de barragens, é de extrema importância, pois através do conhecimento dessas, serão determinadas a inclinação dos seus taludes em função da sua capacidade em resistir ao deslizamento, propriedade essa conhecida como resistência do solo ao cisalhamento. Além disso, os parâmetros do cisalhamento podem ser úteis para a avaliação da capacidade de suporte e da resistência à tração do solo e, conseqüentemente, na definição de máquinas e equipamentos mais apropriados para o manejo do mesmo; como indicador do estado de compactação; na avaliação da susceptibilidade à erosão e, portanto, no estudo de técnicas que visem a estabilidade de taludes naturais e artificiais.

Esses parâmetros são características intrínsecas do solo e podem ser obtidos no campo ou em laboratório, mas por sua determinação experimental ser demorada

e dispendiosa, muitas vezes os projetistas optam por não desenvolver esses ensaios o que aumenta os riscos de comprometer a obra.

Como alternativa para diminuir custos e tempo na obtenção de resultados desses ensaios, foram desenvolvidas em outras áreas da física do solo as funções de pedotransferência, que se caracterizam pela sua capacidade de estimar atributos de difícil determinação, a partir de atributos facilmente obtidos em análises de laboratório, como por exemplo, textura, densidade do solo, Limites de Atterberg, dentre outros.

Existem vários modelos para a determinação das funções de pedotransferência, variando de modelos lineares generalizados, regressão linear múltipla, modelos aditivos e generalizados, árvore de regressão, redes neurais, sistemas de lógica difusa entre outros.

As redes neurais artificiais têm sido desenvolvidas por serem mais precisas que as regressões estatísticas tradicionais, na estimativa da retenção de água, por exemplo.

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

Objetivo Geral

O objetivo deste trabalho é avaliar um modelo que permita uma estimativa da resistência do solo ao cisalhamento utilizando duas técnicas diferentes (análise multivariada e redes neurais artificiais) para a obtenção dos parâmetros de resistência do solo ao cisalhamento(coesão e ângulo de atrito interno).

Objetivos Específicos

1) Estabelecer e testar FPTs, que estimem os parâmetros cisalhantes (coesão e ângulo de atrito interno), por meio de regressão linear múltipla e redes neurais artificiais;
2) Testar várias topologias de RNAs alternando as variáveis de entrada e o número de neurônios na camada intermediária, bem como, estimar de forma conjunta e separada a coesão e o ângulo de atrito, verificando o modelo com melhor desempenho**;**
3) Disponibilizar um método, que auxilia na obtenção de valores de coesão e ângulo de atrito interno, sem a necessidade de realização de ensaios experimentais.

Hipótese

As Funções de Pedotransferência, desenvolvidas para estimar os parâmetros (coesão e o ângulo de atrito interno do solo) através da RLM e RNA, apresentam desempenho de estimativa satisfatório.

2 REVISÃO DE LITERATURA

Essa revisão tem a função de abordar temas referentes a barragens, a resistência do solo ao cisalhamento e seus parâmetros (coesão e ângulo de atrito interno) bem como suas formas de determinação diretas e indiretas de obtenção, através de funções de pedotransferência obtidas através de regressão linear múltipla (RLM) e redes neurais artificiais (RNAs).

2.1 Barragens de terra e estabilidade de taludes

Segundo RIO GRANDE DO SUL (1955), barragem é toda a obra destinada a realizar o armazenamento de água, cujo volume d'água armazenada seja superior a 500.000m^3 ou altura d'água (nível normal) superior a 1,5 m, podendo ser de terra, alvenaria, concreto armado ou simples, etc.

As barragens de terra, segundo Marangon (2004), são as mais elementares obras de barragens e normalmente se prestam para qualquer tipo de fundação, desde a rocha compacta até terrenos construídos de materiais não consolidados, sendo este último tipo de material o seu campo típico de aplicação. De acordo com esse autor existe uma certa variabilidade no tipo de secção transversal de barragens de terra, que poderá ser homogêneo (não zonado) ou heterogêneo (zonado).

Segundo Costa e Lança (2001), uma barragem de terra não é exigente nem nas fundações nem nos materiais. Ela molda-se a quase todas as fundações e, com modernas técnicas de mecânica dos solos e terraplanagens, aceita uma enorme variedade de solos.

Estas, de acordo com Ferreira et al. (2011), são apropriadas para locais onde haja disponibilidade de solos argilosos ou areno-siltoso/argilosos, além da facilidade de situar o vertedouro em uma das margens utilizando o solo escavado para a sua própria construção.

O desenvolvimento dos processos de estudo de fundações, os aperfeiçoamentos das técnicas de experimentações laboratoriais, os recursos das

teorias de equilíbrio e deformação, permitem a execução de projetos de barragens de terra, praticamente em qualquer lugar, nas mais diversas condições e desenvolvimento.

A Figura 1 mostra os principais elementos característicos de uma barragem de terra, onde pode-se destacar os seus taludes (inclinação de suas faces), divididos em: talude de montante (1) e talude de jusante (2).

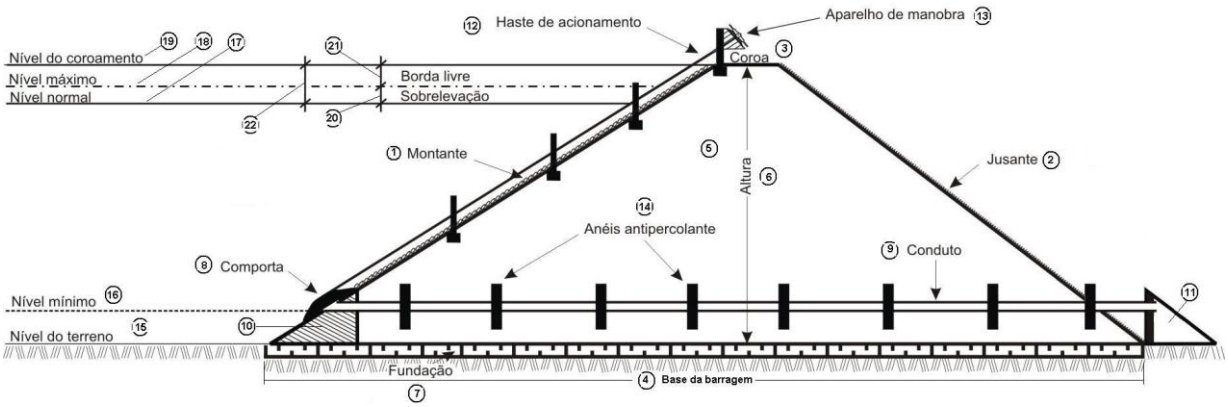

Figura 1 – Elementos característicos de uma barragem de terra
Fonte: Robaina e Peiter (2013).

As inclinações dos taludes de montante e de jusante dependem do tipo de solo utilizado em sua construção, que por sua vez apresentam diferentes resistências ao cisalhamento em virtude das suas propriedades mecânicas (coesão e o ângulo de atrito interno).

Segundo Robaina e Peiter (2013), as barragens de terra podem apresentar vários problemas construtivos, dentre os quais se podem destacar dois ligados ao solo como material de construção: a) falta de estabilidade da barragem devido a recalques excessivos ou ruptura de seus taludes; b) falta de estabilidade do solo da fundação, devido a recalques excessivos causando ruptura de obras de arte (estruturas auxiliares) e os causados pela ruptura do solo de fundação devido a baixa resistência à compressão.

De uma maneira geral, os recalques de uma obra de terra não ameaçam a estabilidade da mesma, mas prejudicam as estruturas auxiliares (como o conduto de

descarga), devido a diferença de comportamento dos materiais.

O problema ligado à ruptura de talude por deslizamento pode ser causado por taludes íngremes e falta de compactação adequada do material de construção da barragem de terra.

Além das rupturas por cisalhamento do maciço de terra, pode-se mencionar as rupturas que ocorrem entre o aterro e a base devido às pressões de cisalhamento que se desenvolvem sob a parte em talude do aterro, sendo o problema causado por falta de resistência do material da base (principalmente argilas moles) agravados pelo projeto de taludes íngremes.

Além dos problemas anteriores podem ser citados: a falta de estabilidade devido à percolação da água causada pela erosão interna no corpo da barragem e o solapamento da barragem; a falta de estabilidade devido à percolação da água em estruturas auxiliares, devido a fraca aderência na superfície de contato entre o material da tubulação de descarga e o material de construção da barragem; a falta de estabilidade devido ao transbordamento de água sobre a crista; a falta de estabilidade devido à erosão superficial dos taludes (montante e jusante).

Dentre os problemas construtivos das barragens de terra enumerados anteriormente, o que tem relação direta com esse trabalho é a falta de estabilidade da obra (barragem de terra) por ruptura de seus taludes, tanto o de montante quanto o de jusante.

Uma das mais importantes propriedades do solo para a engenharia é sua capacidade em resistir ao deslizamento em sua superfície interna dentro de uma massa. A estabilidade da estrutura construída depende da resistência oferecida pelo solo ao longo da superfície de deslizamento prováveis (MOLLAHASANI et al., 2011).

Do ponto de vista teórico, um talude se apresenta como uma massa de solo submetida a três campos de forças: aquelas devido ao peso, ao escoamento da água e à resistência do solo ao cisalhamento (CAPUTO, 1981).

De acordo, com Fiori e Carmignani (2009), o estudo da estabilidade de taludes deve, necessariamente, levar em conta o equilíbrio entre essas forças, uma vez que as duas primeiras se somam, e tendem a movimentar a massa de solo talude (ou encosta) abaixo, enquanto que a última atua como freio a essa movimentação.

Segundo os mesmos autores, a análise do equilíbrio-limite considera que as forças que tendem a induzir o movimento e a conseqüentemente ruptura são

exatamente balanceadas pelas forças resistentes. A fim de exemplificar, considere-se um bloco de solo apoiado sobre um plano inclinado de um ângulo θ, o que pode ser visto na Figura 2:

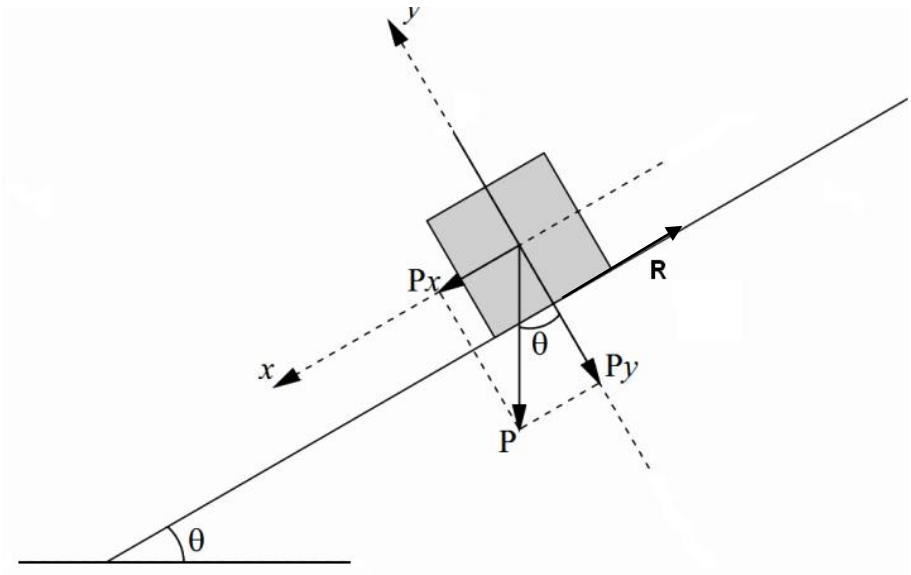

Figura 2 – Força P e suas componentes (Px tangencial e Py normal) e a força de resistência R.
Fonte: Pereira (2013), adaptado de Fiori e Carmignani (2009).

O bloco é solicitado por seu próprio peso P e a sua componente tangencial ($Px = P.\ sen\theta$) tende a causar o movimento. A componente normal do peso atuante perpendicularmente à base do bloco ou à superfície de escorregamento é dada por $Py = P.\ cos\ \theta$.

A força R resistente à movimentação é dada por R = τ. A, onde τ é a resistência do solo ao cisalhamento no contato bloco-plano inclinado.

Segundo Ortigão (1995), a resistência ao cisalhamento do solo pode ser expressa pela equação de Coulomb:

$$\tau = c + \sigma\ tg\ \phi \qquad (2.1)$$

onde τ é a resistência do solo ao cisalhamento (N/m^2), o parâmetro *c* (N/m^2) representa a coesão entre as partículas do solo e ϕ o coeficiente de atrito entre as partículas do solo.

A fim de comparar a estabilidade de um talude em condições diferentes de equilíbrio-limite, define-se um fator de segurança *Fs*, como a razão entre a resultante das forças resistentes ao escorregamento e a resultante das forças solicitantes ou favoráveis ao movimento (escorregamento) do talude. Neste caso, o fator de segurança *Fs* é dado por;

$$Fs = \frac{Forças\ resistentes}{Forças\ solicitantes} \tag{2.2}$$

Valores de *Fs* maiores que a unidade indicam que as forças resistentes são maiores que as forças solicitantes e, desse modo, o talude é considerado estável.

Segundo Caputo (1981), o talude é considerado estável se o seu valor é igual ou maior que 1,5 (valor adotado como referencia).

2.2 Resistência do solo ao cisalhamento

A resistência ao cisalhamento pode ser definida como a resistência que o solo oferece a uma nova deformação. Quando forças externas agem sobre o solo, ele sofre deformações de vários modos, conforme as tensões, a distribuição, a magnitude e a orientação dessas forças.

A coesão do solo é a força de atração entre as superfícies de suas partículas, podendo ser dividida em real ou aparente. A coesão real é resultado do efeito de agentes cimentantes, como teor de óxidos e de argilas silicatadas (MULLINS et al., 1990), bem como o resultado da atração entre partículas próximas por forças eletrostáticas (MITCHELL, 1976). A coesão aparente é resultado da tensão superficial da água nos capilares do solo, formando meniscos de água entre as partículas dos solos parcialmente saturados, que tendem a aproximá-las entre si. A

coesão aparente constitui uma parcela da resistência ao cisalhamento de solos parcialmente saturados (FREDLUND e RAHARDJO, 1993).

O ângulo de atrito interno do solo representa as características friccionais entre as partículas do solo, sendo definido como o ângulo máximo que a força transmitida ao solo pode fazer com a força normal à superfície de contato, sem que haja o cisalhamento do solo no plano de ruptura. O ângulo de atrito interno do solo depende de fatores como grau de compactação, percentagem e tipo de argila, tamanho e forma dos grãos de areia do solo (PINTO, 2000).

Segundo Baumgartl e Horn (1991), a resistência do solo tende a aumentar com o desenvolvimento de estrutura, uma vez que os parâmetros da resistência ao cisalhamento (c e ϕ) de agregados individuais são sempre maiores que os da massa do solo e, quanto mais agregado é o solo, mais negativa é a tensão capilar em um mesmo teor de água, e, portanto, menor é a atenuação da carga aplicada sobre ele. Análise semelhante a anterior foi feita por Horn et al. (1993).

Ekwue (1990) observou que a adição de turfa reduziu a resistência ao cisalhamento, mas que o aumento do teor de matéria orgânica em solo sob pastagem resultou em aumento da mesma, enquanto Ekwue e Stone (1995) verificaram que a adição de material orgânico reduziu a resistência do solo em baixa umidade e aumentou-a em alta umidade.

A determinação do cisalhamento do solo, segundo Ohu et al (1986), pode ser utilizada na agricultura para a avaliação da capacidade de suporte e segundo Balastreire (1987) serve para a avaliação da resistência à tração do solo.

Conforme Schjonning (1991), o conhecimento dessas características possibilita a definição de máquinas e equipamentos mais apropriados para o manejo do mesmo, como indicador do estado de compactação.

2.3 Fatores que influenciam nos parâmetros de cisalhamento

McCormack e Wilding (1979) citam que os fatores que determinam a resistência ao cisalhamento do solo são a forma e distribuição do tamanho de partículas do solo, o conteúdo de umidade, a estrutura, a densidade, o tipo de

mineral presente na argila, o tipo e quantidade de cátions trocáveis e as forças de atração e repulsão entre as partículas.

Segundo Horn et al.(1994), a textura influi fortemente na resistência ao cisalhamento, devido que a abundância de partículas finas afetam a intensidade de compactação, a qual tende a aumentar a resistência ao cisalhamento.

De acordo Al-Shayea (2001), a coesão do solo é fortemente influenciada pelo teor de argila do solo, devido a sua elevada área superficial específica. Ainda, segundo esse autor, trabalhando com solos com diferentes teores de argila, constatou um aumento da coesão de 40 kPa para 360 kPa em solos, respectivamente, com 10 e 40 % de argila, num teor de água de 0,10 kg kg^{-1}.

Para o ângulo de atrito interno, em determinadas situações pode diminuir com o aumento do teor de argila do solo, pois as partículas de argila revestem a superfície das partículas de areia, diminuindo a fricção entre elas.

Já em solos de textura arenosa, a resistência ao cisalhamento depende, basicamente, do atrito entre as partículas, cujo ângulo de atrito interno depende da forma do grão e do grau de compactação do solo (SILVA e CABEDA, 2005).

Os autores também verificaram que o ângulo de atrito interno do solo diminui com o aumento do teor de argila do solo, enfatizando que as partículas de argila revestem a superfície das partículas de areia, diminuindo a fricção entre estas.

O teor de água do solo tem grande influência no desenvolvimento da coesão entre as partículas. O aumento da coesão com a redução do teor de água do solo tem sido verificado por alguns autores (MCKYES et al., 1994; BOENI, 2000). Arvidsson et al. (2001) verificaram um aumento da coesão do solo de 87 kPa para 154 kPa em solo de textura média, quando diminuiu o teor de água no solo de 0,17 kg kg^{-1} para 0,11 kg kg^{-1}, evidenciando o grande efeito da umidade na coesão do solo.

De acordo com Fredlund e Rahardjo (1993), a diminuição do teor de água no solo reduz a distância entre as partículas, havendo um conseqüente aumento da atração entre elas, resultando num acréscimo da coesão do solo.

Segundo (Braida, 2004), há um aumento da coesão e do ângulo de atrito interno do solo, conforme ocorre a redução do teor de água e consequentemente, um incremento da resistência do mesmo ao cisalhamento.

Em elevada quantidade, a água atua como uma espécie de lubrificante entre as partículas do solo o que reduz a coesão e o ângulo de atrito interno, diminuindo a resistência do solo à deformação (CUNHA et al., 2002).

Al-Shayea (2001) demonstrou que a distância entre as partículas mostrou-se reduzida com a diminuição do teor de água do solo, resultando em uma maior atração entre elas e em conseqüente aumento da coesão.

O limite de liquidez de um solo é o teor de umidade que separa o estado de consistência líquido do plástico e para o qual o solo apresenta uma pequena resistência ao cisalhamento. O ensaio utiliza o aparelho de Casagrande, onde tanto o equipamento quanto o procedimento são normalizados (ABNT/NBR 6459/82).

No ensaio de limite de liquidez mede-se, indiretamente, a resistência ao cisalhamento do solo para um dado teor de umidade, através do número de golpes necessários ao deslizamento dos taludes da amostra; para um teor de umidade igual ao limite de liquidez foram encontrados valores iguais a 2,5 kPa, valores estes muito baixos, indicando a proximidade do estado líquido e sendo a maior parte desta resistência devida às forças atrativas entre as partículas que por sua vez estão relacionadas a atividade superficial dos argilo-minerais.

O aumento da densidade do solo, causado pela compactação implica no incremento da coesão e do ângulo de atrito interno e, consequentemente, da resistência do mesmo ao cisalhamento do solo, (SECCO, 2003).

Ferreira et al (2002) em seu trabalho observou que coesão do solo teve relação direta com a densidade do solo, onde à medida que o solo apresentou maiores valores de densidade do solo, maiores foram os valores de coesão.

Os solos mais compactados oferecem maior resistência ao cisalhamento em função da maior densidade e menor distância entre as partículas, (AZEVEDO, 1999).

2.4 Métodos de obtenção dos parâmetros (c, ϕ)

A determinação dos parâmetros (c e ϕ) do solo é importante para estudos de resistência do solo ao cisalhamento para os trabalhos de engenharia.

O ensaio para a obtenção desses parâmetros tem sido pouco usado nos estudos de solos agrícolas no Brasil (ROCHA et al, 2002; SILVA e CABEDA, 2005), sendo usualmente empregados na área de geotecnia, para a avaliação da resistência de taludes de barragens de terra ao deslizamento (ORTIGÃO, 1995; PINTO, 2000).

Os métodos de determinação dos parâmetros da resistência do solo ao cisalhamento podem ser feitos por métodos diretos no laboratório ou no campo e também através de métodos indiretos, utilizando FPTs.

2.4.1 Métodos diretos de laboratório

Os métodos de laboratório mais empregados para determinar os valores da coesão (c) e do ângulo de atrito interno (ϕ) são o método do cisalhamento direto e o método de compressão triaxial. Esses métodos envolvem mão-de-obra para a coleta das amostras em campo que são acondicionadas em recipientes e levadas ao laboratório, onde são processadas.

Caputo (1976) cita que as primeiras medidas dos parâmetros de resistência ao cisalhamento de argilas datam de 1930. Observa que as amostras utilizadas são não deformadas ou então, se deformadas devem reproduzir as condições que se pretende alcançar na obra.

Ensaio de cisalhamento direto

Segundo Craig (2004) no ensaio de cisalhamento direto o corpo-de-prova é confinado em uma caixa metálica (chamada também caixa de cisalhamento ou, em inglês, *shearbox*) de seção transversal quadrada ou circular, partida horizontalmente a sua meia-altura, mantida uma pequena folga entre as duas partes da caixa.

São colocadas placas porosas abaixo e acima do corpo-de-prova se ele estiver completo ou parcialmente saturado, a fim de permitir que a drenagem ocorra livremente: se o corpo-de-prova estiver seco, podem ser usadas placas de metal.

Os aspectos essenciais do equipamento são mostrados na forma de um diagrama, na Figura 3.

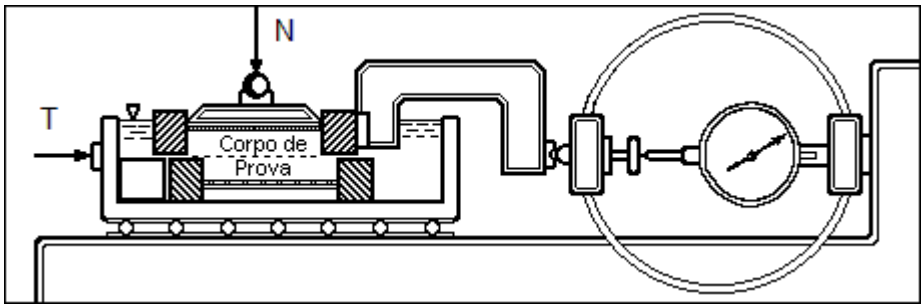

Figura 3 – Equipamento de cisalhamento direto
Fonte: adaptado de Silva et al (2004).

As vantagens do ensaio são a simplicidade e, no caso de areias, a facilidade de preparação do corpo-de-prova.

Cisalhamento triaxial

Segundo Craig (2004), esse é o ensaio de resistência ao cisalhamento mais largamente utilizado e é adequado para todos os tipos de solo.

É utilizado no ensaio de um corpo-de-prova cilíndrico, com diâmetros típicos de 38 e 100 mm, que é carregado sob condições de simetria axial demonstrada na Figura 4.

Figura 4 – Sistema de tensões no corpo de prova em ensaio triaxial.

As características principais do equipamento estão demonstradas na Figura 5. A base circular tem um pedestal central no qual o corpo-de-prova é colocado, e existe acesso através do pedestal para a drenagem e para a medida da pressão da água nos poros. Um cilindro de acrílico (Perspex), vedado entre um anel e a parte superior da célula circular, forma o corpo de célula. O topo da célula tem um canal central pelo qual passa o pistão de carregamento. O cilindro e o topo da célula são presos à base, e sua vedação é possibilitada por meio de um anel de borracha.

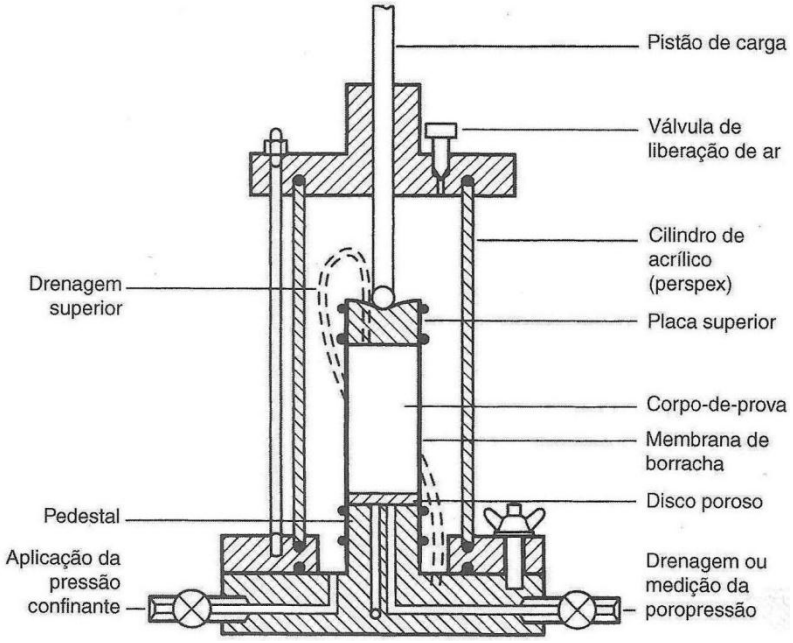

Figura 5 – Equipamento de ensaio triaxial
Fonte: Craig (2004).

O corpo de prova é colocado sobre um disco poroso ou sólido no pedestal do equipamento. É colocada uma placa de carregamento no topo do corpo-de-prova, e então é envolto em uma membrana de borracha. Usam-se anéis de borracha sob tensão para prender a membrana ao pedestal e à placa de carregamento e assim fornecer a vedação adequada. No caso de areias, o corpo-de-prova deve ser preparado em uma membrana de borracha dentro de um molde rígido que seja adequado ao pedestal. É aplicada uma pequena pressão negativa à água dos poros para manter a estabilidade do corpo de prova enquanto o molde é removido antes

da aplicação da pressão confinante. Também pode ser feita uma conexão ao topo do corpo-de-prova através da placa de carregamento, um tubo flexível de plástico ligando a placa de carregamento à base da célula; normalmente essa conexão é usada para aplicação da contrapressão.

Tanto o topo da placa de carregamento como a extremidade inferior do pistão de carregamento possuem superfícies cônicas, e a carga é transmitida por meio de uma esfera de aço. O corpo-de-prova fica sujeito a uma pressão fluida confinante, o adensamento pode ocorrer, caso seja adequado, e então a tensão axial é aumentada gradualmente pela aplicação da carga compressiva através do pistão até ocorrer a ruptura do corpo-de-prova, normalmente em um plano diagonal. A carga é medida por intermédio de um anel de carga ou de um transdutor colocado dentro ou fora da célula. O sistema para a aplicação da tensão confinante deve ser capaz de fazer a compensação de alterações da pressão devidas ao vazamento da célula ou à modificação do volume do corpo-de-prova.

No ensaio triaxial, o adensamento ocorre sob incrementos iguais da tensão normal total nas extremidades e na superfície lateral (circunferencial) do corpo-de-prova. A deformação lateral do corpo-de-prova *não* é nula durante o adensamento sob essas condições (diferentemente do ensaio oedométrico). A dissipação do excesso de água nos poros ocorre em conseqüência da drenagem através do disco poroso na superfície inferior (ou superior) do corpo-de-prova. A conexão de drenagem conduz a uma bureta externa, permitindo que o volume de água expelido do corpo-de-prova possa ser medido. A referência para o excesso de água nos poros, é portanto, a pressão atmosférica, uma vez admitindo que o nível de água na bureta está na mesma altura que no centro do corpo-de-prova. Algumas vezes, os drenos de filtro de papel, em contato com os discos porosos das extremidades, são colocados em torno da circunferência do corpo-de-prova; podem ocorrer tanto a drenagem vertical como a drenagem radial, e a taxa de dissipação do excesso de água nos poros é aumentada.

A pressão confinante é tomada como a tensão principal menor, e a soma da pressão confinante como a tensão axial aplicada é tomada como a tensão principal maior, admitindo que não há tensões de cisalhamento nas superfícies do corpo-de-prova. Assim, a tensão axial aplicada é denominada *diferença das tensões principais* (também conhecida como *acréscimo de tensão axial, tensão-desvio, tensão desviatória,* ou ainda, *tensão desviadora.* Pode-se ainda encontrar o termo em

inglês, *deviator stress*.

A tensão principal intermediária é igual à tensão principal menor; portanto, as condições das tensões na ruptura podem ser representadas por um círculo de Mohr (Figura 6).

O círculo de Mohr tem seu centro no eixo das abcissas. Desta forma, ele pode ser construído quando se conhecerem as duas tensões principais, ou as tensões normais e de cisalhamento em dois planos quaisquer.

Se forem ensaiados vários corpos-de-prova, cada um deles sujeito a um valor diferente de pressão confinante, pode ser desenhada a envoltória de ruptura e podem ser determinados os parâmetros de resistência ao cisalhamento.

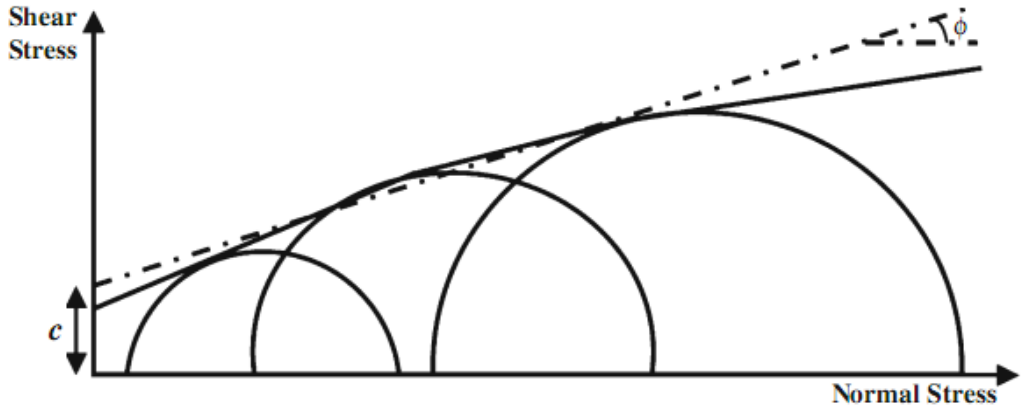

Figura 6 – Círculo de Mohr
Fonte: Murthy (2008).

O ensaio tem as vantagens de que as condições de drenagem podem ser controladas, permitindo que solos saturados de baixa permeabilidade sejam adensados, caso necessário, como parte do procedimento do ensaio, e que possam ser realizadas medidas de poropressão.

Pode-se medir a pressão neutra (poropressão) em um corpo-de-prova triaxial, permitindo que os resultados sejam expressos em termos da tensão efetiva; devem ser mantidas condições de *ausência de fluxo* saindo ou entrando no corpo-de-prova, caso contrário a pressão correta será modificada. Normalmente, a pressão neutra é medida por intermédio de um transdutor eletrônico de pressão.

Um caso especial do ensaio triaxial é o *ensaio de compressão simples* no

qual a tensão axial é aplicada a um corpo-de-prova sob pressão confinante nula (atmosférica), não sendo exigida membrana de borracha. Entretanto, o ensaio de compressão simples só é aplicável para ensaio de argilas intactas, completamente saturadas.

Os ensaios de cisalhamento, tendo em vista procurar reproduzir as diferentes condições de solicitação existentes nos maciços que se encontram na prática, podem ser classificados em três grupos: ensaio lento ou com drenagem, ensaio rápido ou com drenagem e ensaio rápido com pré-adensamento, (CAPUTO, 1976; VARGAS, 1978).

Segundo Craig (2004) são possíveis muitas variações de procedimentos para o ensaio com o equipamento triaxial, mas de acordo com Pinto (2002), no que se refere às condições de drenagem, três tipos de procedimentos nos ensaios são básicos: ensaio adensado drenado, ensaio adensado não drenado e ensaio não adensado não drenado.

No ensaio adensado drenado o corpo-de-prova está sujeito a uma pressão confinante especificada e então a diferença das tensões principais é aplicada imediatamente, sem que seja permitida drenagem em nenhum estágio do ensaio. Na fase de adensamento, são apresentadas as curvas tensão confinante, pressão neutra e variação de volume por tempo.

No ensaio adensado não drenado é permitida a drenagem do corpo-de-prova sob uma pressão confinante especificada até o adensamento estar concluído; a diferença das tensões principais é então aplicada sem que seja permitida drenagem. As medições de pressão de água nos poros podem ser feitas durante a parte não-drenada do ensaio.

No ensaio não adensado não drenado é permitida a drenagem do corpo-de-prova sob uma pressão confinante até o adensamento estar concluído; com a drenagem ainda sendo permitida, a diferença das tensões principais é então aplicada com uma velocidade suficientemente lenta para assegurar que o excesso de pressão neutra seja mantido nulo. O teor de umidade do corpo-de-prova permanece constante e pode-se medir as pressões neutras (tensões totais e efetivas).

Os parâmetros de resistência ao cisalhamento determinados por intermédio dos procedimentos de ensaios anteriores são aplicáveis em situações em que as condições de drenagem no campo correspondem às condições do ensaio.

2.4.2 Métodos diretos de Campo

Existem alguns equipamentos portáteis, que podem ser levados a campo com a finalidade de realizar os testes de cisalhamento sem a coleta de amostras de solo. Dentre estes equipamentos podemos citar o ensaio de palheta (Vane Shear Test) e o torvane.

Ensaio de palheta (Vane Shear Test)

Esse ensaio é usado para a determinação "*in situ"* da resistência não-drenada de argilas intactas e completamente saturadas; o ensaio não é adequado para outros tipos de solo. Em particular, esse ensaio é muito adequado para argilas moles, cuja resistência ao cisalhamento pode ser alterada significativamente pelo processo de amostragem e manipulação subseqüente. Geralmente, esse ensaio só é usado em argilas que apresentem resistência não-drenada menor do que 100 kN/m^2 . Esse ensaio pode não fornecer resultados confiáveis se a argila contiver laminações de areia e silte.

O equipamento consiste em uma palheta de aço inoxidável (Figura 7) de quatro lâminas retangulares finas, montadas na extremidade de uma haste de aço de alta resistência; a haste fica no interior de um tubo preenchido com graxa. O comprimento da palheta é igual a duas vezes seu diâmetro total, e suas dimensões típicas são 150 mm por 75 mm e 100 mm por 50 mm. De preferência, o diâmetro da haste não deve ser maior do que 12,5 mm.

A palheta e a haste são enterradas na argila abaixo da parte inferior de um furo de sondagem até uma profundidade de pelo menos três vezes o diâmetro do furo de sondagem; se forem tomadas as devidas precauções, isso pode ser feito sem causar perturbação significativa na argila. São usados suportes constantes para manter a haste e a luva centralizadas no revestimento do furo de sondagem. O ensaio pode ser realizado em argilas moles, sem um furo de sondagem, por penetração direta da palheta a partir do nível do solo; nesse caso, é exigida uma sapata para proteger a palheta durante a penetração.

O torque é aplicado gradualmente à extremidade superior da haste por intermédio de um equipamento adequado até a argila romper por cisalhamento em conseqüência da rotação da palheta. A ruptura por cisalhamento ocorre na superfície e nas extremidades de um cilindro com um diâmetro igual a largura total da palheta. A velocidade de rotação da palheta deve estar dentro do intervalo de 6-12 voltas por minuto. A resistência ao cisalhamento é calculada a partir da expressão

$$T = c\,\pi\left(\frac{d^2 h}{2} + \frac{d^3}{6}\right) \qquad (2.x)$$

na qual T é o torque na ruptura, *d* é o diâmetro total da palheta e *h* é o comprimento da palheta. Entretanto, a resistência ao cisalhamento segundo uma superfície cilíndrica vertical pode ser diferente daquela nas duas superfícies horizontais das extremidades, em conseqüência da anisotropia. Normalmente a resistência ao cisalhamento é determinada em intervalos ao longo da profundidade desejada. Se, após o ensaio inicial, a palheta for girada rapidamente, desenvolvendo várias revoluções, a argila ficará amolgada e a resistência ao cisalhamento nessas condições poderá ser determinada, se for necessário.

Figura 7 – Aparelho para o ensaio de palheta.
Fonte: Humboldt (2013).

Torvane

Outro aparelho para ensaio de cisalhamento direto à campo é chamado torvane (Figura 8), um aparelho portátil que possibilita realizar leituras rápidas, fazendo com que o solo se deforme sem drenagem, ou seja, não há tempo para expulsar a água dos poros. Nesse caso, é chamado de resistência ao cisalhamento sem drenagem, numericamente igual à coesão do solo, independentemente do ângulo de atrito (SMITH e SMITH, 1998).

Figura 8 – Conjunto para cisalhamento de plástico torvane.
Fonte: Humboldt (2013).

2.4.3 Método indireto

Funções de Pedotransferência

A pedotransferência é assunto relativamente novo no Brasil e um método pouco utilizado, embora existam casos de aplicações potenciais deste recurso quando se utilizam dados analíticos e morfológicos de solos para estimar, por exemplo, uma classe de aptidão agrícola ou uma classe de suscetibilidade a erosão.

Esse método está começando a ser utilizado em muitas áreas e com grande potencial de aplicação (FIORIN, 2008).

Segundo Michelon (2010), o termo funções de pedotransferência (FPTs) foi descrito pela primeira vez por Bouma (1989), com o significado de “transformando dados que possuímos em dados que necessitamos”, em referência a equações que relacionavam a retenção de água e a condutividade hidráulica a parâmetros disponíveis nos estudos de solos.

Conforme Pachepsky e Rawls (1999), o termo funções de pedotransferência foi usado para descrever as equações que expressam a dependência da retenção de água e a condutividade hidráulica do solo com parâmetros disponíveis nos estudos de solos e de acordo com Fiorin (2008), quando a pedotransferência é expressa de forma quantitativa, por meio de equações matemáticas, ela é denominada de funções de pedotransferência.

Atualmente, o termo funções de pedotransferência é usado para incluir as equações que estimam características edáficas de difícil obtenção por meio de outras que podem ser mais facilmente obtidas, como mencionado por Oliveira et al. (2002), Pachepsky et al. (2006), Nasta et al. (2009).

De acordo com Budiman et al (2003) as funções de pedotransferência são equações preditivas de certas propriedades dos solos a partir de outras facilmente medidas e rotineiramente obtidas a custos mais baixos. Ainda pode-se dizer que funções de pedotransferência são modelos matemáticos que se caracterizam pela sua capacidade de estimar atributos de difícil determinação, a partir de atributos facilmente obtidos em análises de laboratório ou de campo, como por exemplo, textura, densidade do solo, carbono orgânico, entre outros atributos do solo.

Elas foram desenvolvidas com o objetivo principal de diminuir o tempo e o custo na obtenção de características físicas do solo nos ensaios de campo ou de laboratório. As funções de pedotransferencia podem ser construídas por regressão linear multipla (RLM) e através de redes neurais artificias (RNA).

2.4.3.1 Regressão Linear Múltipla (RLM)

Hair et al. (2005), afirmam que a análise multivariada é um conjunto de

técnicas para análise de dados que está sempre em expansão e dentre as técnicas discutidas, por esses autores, podem ser citadas: a) a análise de componentes principais: b) regressão e correlação múltiplas; c) análise discriminante múltipla; d) análise multivariada de variância e covariância; e) análise conjunta; f) correlação canônica; g) análise de agrupamentos e h) escalonamento multidimensional. Ainda citam técnicas emergentes, como: i) análise de correspondência; j) modelos lineares de probabilidade, como logit e probit; k) modelagem de equações simultâneas.

Os mesmos autores citam que a regressão múltipla é o método de análise apropriado quando o problema de pesquisa envolve uma única variável dependente relacionada a duas ou mais variáveis independentes. O objetivo da análise de regressão múltipla é prever as mudanças na variável dependente como resposta a mudanças nas variáveis independentes, sendo esse objetivo alcançado por meio da técnica dos mínimos quadrados.

Sempre que o pesquisador estiver interessado em prever a quantidade ou a magnitude da variável dependente, a regressão múltipla será útil, como por exemplo, despesas mensais com jantares fora de casa (variável dependente) podem ser estimadas ou previstas a partir de informações referentes a renda familiar, tamanho da família e idade do chefe da família (variáveis independentes).

Segundo Soares (2013), a regressão linear múltipla foi introduzida por Sterberg et al. (1960). Essa técnica busca estabelecer uma relação linear entre a variável dependente e as independentes aplicando o método dos mínimos quadrados.

De acordo com Montgomery et al. citado por Chong e Jun (2005), o método de regressão stepwise é um procedimento para seleção de variáveis que combina dois outros métodos, o forward selection e 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.

Nunes (2008), descreve que no procedimento 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.

Segundo Michelon (2010), o modelo stepwise é um procedimento de seleção da melhor equação de regressão por inclusão e/ou substituição de sucessivas variáveis preditoras, sendo a sequência de inserção determinada pela medida da relevância das variáveis ainda não incluídas no modelo. O modo para determinar o nível de relevância é avaliado pelo coeficiente de correlação parcial.

2.4.3.2 Trabalhos de FTP - Regressão Linear Múltipla

Na área de ciência do solo, existe um grande número de funções de pedotransferência obtidas com o uso da regressão linear múltipla, para a obtenção da curva de retenção da água no solo, que representa a relação entre a umidade do solo e o potencial mátrico, (GUPTA e LARSON, 1979; RAWLS et al., 1982; VEREECKEN et al., 1989; VEREECKEN et al., 1990).

De acordo com Gupta e Larson (1979), a grande maioria das funções de pedotransferência são empíricas e, muitas vezes são obtidas pelo uso de equações lineares através da regressão múltipla. A Função de Pedotransferência desenvolvida por esses autores teve a finalidade de estimar a umidade no solo (variável dependente) em função de teor de areia, teor de silte, teor de argila, densidade do solo e matéria orgânica (variáveis independentes), evitando o uso da técnica tradicional no campo ou em laboratório.

Soares (2013), por meio de Regressão Linear Múltipla, testou e estabeleceu Funções de Pedotransferência Pontuais para poder então estimar a curva de retenção de água no solo para as distintas classes de solo para o estado do Rio Grande do Sul.

2.5 Estrutura de um neurônio biológico

Os neurônios podem ser divididos em três seções: o corpo celular, os

dendritos e a axônio (Figura 9), desempenhando, cada uma delas, funções específicas, porém complementares (BRAGA et al. 2000).

O perfeito funcionamento e integração entre os diversos setores de um organismo são garantidos pelo rápido recebimento, processamento e condução dos impulsos nervosos, por meio de células altamente especializadas na captura e transmissão dos impulsos nervosos, chamados neurônios.

A função dos dendritos é captar informações provenientes do meio externo ou de outros neurônios e conduzi-las ao corpo célula, que reúne as diferentes informações fornecidas pelos dendritos, e após processá-las gera um sinal constante que é conduzido por toda extensão do axônio. Os dendritos de outros neurônios que estivem conectados a este axônio perceberão o sinal emitido.

O ponto de contato entre a terminação axônica de um neurônio e os dendritos de outro é chamada de sinapse (Figura 9). Esta estrutura, que possui alta capacidade de aprendizado e adaptação, inspirou a criação de um sistema artificial capaz de simular o aprendizado e a generalização de uma rede neural biológica, podendo assim realizar tarefas que programas convencionais não conseguiriam (VALENÇA, 2010).

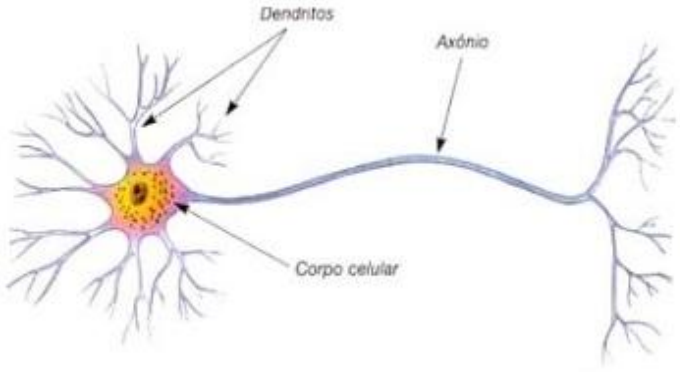

Figura 9 - Estrutura simplificada de um neurônio biológico.
Fonte: adaptado de Souza (2010).

Segundo Valença (2010), um dos aspectos importantes para o entendimento do funcionamento de um neurônio biológico é a Lei do Tudo ou Nada. Segundo essa lei, dependendo se a intensidade do estímulo for maior ou menor que limiar

excitatório, o neurônio dispara ou não um impulso nervoso. Portanto, se o estímulo for muito pequeno, sua intensidade será inferior ao limiar excitatório e não ocorrerá nenhum impulso nervoso. Por outro lado, passado esse limiar, o potencial de ação do neurônio será sempre o mesmo, qualquer que seja a intensidade do estímulo.

2.6 Redes neurais artificiais

Redes neurais artificiais se constituem em uma técnica de inteligência artificial cuja utilização prática está se tornando cada vez mais presente no nosso dia em áreas de pesquisa como: classificação, reconhecimento de padrões, processamento de séries temporais e aproximação de funções, (VALENÇA, 2005).

Segundo Fausett (1994), as redes neurais artificiais são uma forma de inteligência artificial, que, pela sua arquitetura, fazem uma tentativa de simular a estrutura biológica do cérebro humano e o sistema nervoso. Descrição semelhante é feita por Flood e Kartam (1994), Hecht-Nilsen (1990), Maren et al. (1990) e. Zurada (1992).

São técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência (HAYKIN, 2001; MEDEIROS, 2003; OSÓRIO e BITTENCOURT, 2000; NIEVOLA, 2004; SARLE, 2004; ZELL et al., 1998).

As redes neurais artificiais são modelos que simulam o comportamento dos neurônios naturais. De acordo com Haykin (2000), uma rede neural artificial se assemelha ao cérebro, por duas principais características: o conhecimento é adquirido através de um processo de aprendizagem e são utilizadas forças de conexão entre os neurônios, conhecidas como pesos sinápticos, para armazenar o conhecimento adquirido.

Neste sentido, Haykin (2001) define RNA como um processador que funciona de forma paralela e distribuída, constituído de unidades de processamento simples, que armazenam o conhecimento experimental e o tornam disponível para o uso.

Conforme Jackson (2002), rede neural artificial é uma classe de sistemas modelados segundo o cérebro humano. Assim como o cérebro humano é constituído de milhões de neurônios conectados por sinapses, as redes neurais são formadas

por um grande número de simuladores de neurônios, conectados de uma maneira similar aos neurônios do cérebro humano. A força destas conexões pode variar em resposta a estímulos, permitindo o aprendizado.

Segundo Cerqueira et al (2001), existem várias definições para redes neurais artificiais, mas adotam uma que lhes parece mais geral e aplicável a qualquer área da ciência. Para eles, redes neurais artificiais é o nome dado a um conjunto de métodos matemáticos e algoritmos especialmente projetados para simular o processamento de informações e aquisição de conhecimento do cérebro humano.

2.6.1 Vantagens da modelagem com redes neurais

A habilidade das redes neurais artificiais em solucionar problemas complexos e variados tem as tornado uma abordagem interessante que pode ser aplicada em diversas áreas de engenharia e ciências (SILVA, 2001b).

Segundo Jain et al (2010), o aumento do interesse pelas redes neurais entre os pesquisadores é devido ao seu excelente desempenho em modelagem de relações multivariadas não-lineares.

As funções de pedotransferencia também podem ser construídas por redes neurais artificiais, que de acordo com Haykin (1994) são descritas como funções aproximadoras universais, uma vez que pode "aprender" a aproximar qualquer função não-linear contínua.

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 funções de pedotransferência geradas por redes neurais, são freqüentemente melhores do que aquelas obtidas pelos métodos tradicionais.

Segundo vários autores (FAUSETT 1994; FLOOD e KARTAM 1994; HECHT-NILSEN 1990; MAREN et al, 1990;. ZURADA 1992) as redes neurais artificiais foram aplicadas extensivamente para muitas tarefas de predição, uma vez que têm a capacidade de modelar a relação não linear entre um conjunto de variáveis de entrada e as saídas correspondentes.

Segundo Galvão et al. (1999), as redes neurais artificiais têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas em

várias áreas do conhecimento e em função de sua estrutura não-linear, conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais.

As redes neurais artificiais extraem seu poder computacional da sua distribuição de estrutura maciçamente paralela e da sua habilidade de aprender/generalizar, tornando possível a resolução de problemas complexos nas mais diferentes áreas do conhecimento (HAYKIN, 2001).

2.6.2 Estrutura de um neurônio artificial

A primeira proposta de uma representação matemática para representar o neurônio biológico, conhecido como neurônio matemático, foi feita por McCulloch e Pitts (1943), onde de forma simples representava o neurônio biológico utilizando uma regra de propagação e uma função de ativação (VALENÇA, 2010).

O neurônio foi representado por vários sinais de entradas (x_1, x_2, x_3,...x_n) que representavam os dendritos e apenas um terminal de saída, o axônio, conforme Figura 10.

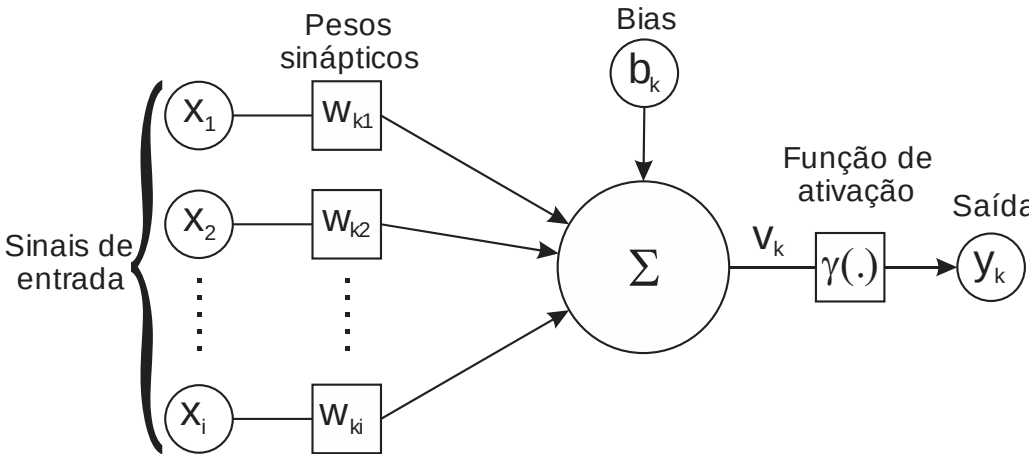

Figura 10 – Modelo de neurônio base para projeto de uma RNA.
Fonte: Soares (2013).

Segundo Haykin (2001) cada neurônio é constituído pelos seguintes

elementos básicos: a) Pesos sinápticos ou sinapses e bias; b) Somatório; c) função de ativação ou transferência.

As sinapses ou pesos sinápticos formam o conjunto de elos de conexão, caracterizada por um peso. Especificamente, a função do peso é ponderar o sinal de entrada da sinapse conectada ao neurônio.

As redes neurais artificiais podem apresentar também pesos adicionais, denominados de “bias”, que tem a função de evitar a geração de erros quando todos os dados de entradas são nulos. Segundo Soares (2013), neste modelo, o acréscimo de um bias, tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente,

O somatório ou junção aditiva agrega os dados das entradas ponderados pelos respectivos pesos. É um somador dos sinais de entrada, ponderados pelos respectivos pesos sinápticos, sendo que estas funções somadoras constituem uma combinação linear.

A função de ativação ou de transferência é uma função que 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].

Valença (2010), afirma que em uma rede neural artificial, cada unidade de processamento está associado a um estado de ativação que é determinado pela função de ativação, contínuo ou discreto, que se quer representar com o modelo. A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados.

Segundo Silva (2010), as funções de ativação podem ser divididas em dois tipos principais: funções parcialmente diferenciáveis e funções parcialmente diferenciáveis, considerando-se para tanto todo o domínio de definição das mesmas.

As funções de ativação parcialmente diferenciáveis são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes. As três principais funções desse grupo são: a função degrau, a função degrau bipolar e a função rampa simétrica.

A função degrau é a função utilizada para neurônios que tomam decisões binárias, limitado a saída do neurônio somente a dois valores, sendo assim, classificadora (SILVA et al, 2004). De acordo com Silva (2010), o resultado

produzido pela aplicação dessa função assumirá valores unitários positivos quando o potencial de ativação do neurônio for maior ou igual a zero e, caso contrário, o resultado assumirá valores nulos.

O resultado produzido pela aplicação da função degrau bipolar assumirá valores unitários positivos quando o potencial de ativação do neurônio for maior que zero; valor nulo quando o potencial de ativação for também nulo; e valores unitários negativos quando o potencial de ativação for menor que zero.

No caso da função rampa assimétrica os valores retornados são iguais aos valores dos potenciais de ativação quando estes definidos no intervalo (-a, +a), restringindo-se aos valores limites em caso contrário.

As funções de ativação totalmente diferenciáveis, ainda segundo Silva (2010), são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de aplicação. As quatro principais funções pertencentes a este grupo, e que podem ser empregadas em redes neurais artificiais são a função linear, a logística, a tangente hiperbólica e a gaussiana.

Na Tabela 1 podem ser vistas, para as três funções de ativação totalmente diferenciáveis mais utilizadas em RNA, sua equação representativa, a sua representação gráfica e seu campo de domínio.

Tabela 1–Tipo de função de ativação, equação e sua representação gráfica

Função	Equação	Representação gráfica
Linear	$f(n) = n$	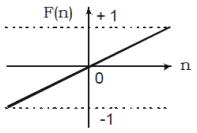
Sigmoide ou Logística	$f(n) = \frac{1}{1+e^{-n}}$	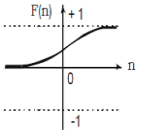
Tangente Hiperbólica	$f(n) = \frac{e^{n} - e^{-n}}{e^{n} + e^{-e}}$	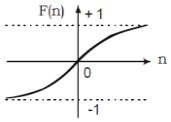

A função de ativação linear ou função identidade produz resultados idênticos aos valores do potencial de ativação. Segundo Silva et al. (2004), a função linear, é

a função que não limita a saída da rede neural artificial. É usada para armazenar entrada e saída de dados.

De acordo com Silva et al (2004) e Silva (2010), uma das aplicabilidades desta função está na utilização das redes neurais artificiais como aproximadoras universais de funções, visando mapear o comportamento entre variáveis de entrada e saída de processos.

Tanto a função logística como a função tangente hiperbólica pertencem à família das funções denominadas de sigmoidais.

Na aplicação da função logística ou sigmóide o resultado produzido assumirá sempre valores reais entre zero e um e na aplicação da função tangente hiperbólica o resultado de saída, diferentemente da função anterior, sempre assumirá valores reais no intervalo de -1 e +1.

Em relação à função gaussiana, a saída neurônio produzirá resultados iguais para aqueles valores de potencial de ativação que estejam posicionadas a uma mesma distância do seu centro (média), sendo a curva simétrica em relação a este.

De acordo com Reinke (2008), a função tangente hiperbólica e a função sigmoide ou logística são as mais utilizadas em redes neurais artificiais, pois apresentam diversas características favoráveis, por serem funções semi-lineares, contínuas, simétricas, deriváveis em toda sua extensão, crescente e limitadas por assíntotas horizontais.

2.6.3 Arquitetura e topologia da rede neural artificial

A arquitetura de uma rede neural artificial define como seus diversos neurônios estão arranjados ou dispostos, uns em relação aos outros. Esses arranjos são essencialmente estruturados através do direcionamento das conexões sinápticas dos neurônios. A topologia de uma rede neural, para uma determinada arquitetura, pode ser definida como sendo diferentes formas de composições estruturais que esta pode assumir. Por exemplo, pode-se ter duas topologias pertencentes a uma mesma arquitetura, sendo uma composta de 10 neurônios e a outra 20 neurônios; ou ainda, uma constituída de neurônios com função de ativação

logística, enquanto que os neurônios assumem a tangente hiperbólica como função de ativação, (SILVA, 2010).

De acordo com Kayadelen et al. (2009), o método das redes neurais artificiais baseia-se em operações de processamento de dados que ocorrem em uma espécie de caixa preta que contém algumas camadas. Uma estrutura de RNA simples consiste em três camadas conhecidas como camada de entrada, camada oculta e camada de saída. Uma rede neural artificial pode ser dividida em três partes, denominadas de camadas, as quais são nomeadas da seguinte forma: camada de entrada, camadas escondidas (intermediárias, ocultas ou invisíveis) e camada de saída, (SILVA, 2010).

A camada de entrada é a camada responsável pelo recebimento dos dados advindos do meio externo. Essas camadas de entradas são geralmente normalizadas em relação as faixas de variação produzidas pelas funções de ativação. Esta normalização implica em uma melhor precisão numérica frente às operações matemáticas realizadas pela rede.

As camadas escondidas são aquelas compostas de neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido. Quase todo o processamento interno da rede é realizado nessas camadas.

A camada de saída é também constituída de neurônios, sendo responsável pela produção e apresentação dos resultados finais obtidos pela rede neural, os quais são advindos dos processamentos efetuados pelos neurônios das camadas anteriores.

Segundo Kóvacs (2002), as redes neurais artificiais têm os seus neurônios dispostos em várias camadas. Os neurônios que recebem diretamente as entradas da rede constituem o que se chama de camada de entrada. Os neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim sucessivamente até a camada final que é a camada de saída. As camadas internas, que não são nem a de entrada e nem a de saída são geralmente referidas como camadas ocultas.

Conforme Braga et al. (2000), um fator que define diretamente a arquitetura ou a topologia que será utilizada em uma RNA é o problema que será tratado pela rede e, neste contexto, devem ser considerados os seguintes componentes:

quantidades de camadas, números de neurônios em cada camada e tipo de conexão entre os neurônios.

2.6.4 Classificação das redes neurais

De acordo com Artero (2009), as redes neurais artificiais podem ser classificadas segundo diferentes critérios como, por exemplo, quanto ao número de camadas, quando é possível ter redes de duas camadas (simples) ou múltiplas camadas (Figura 11), considerando que a primeira não é uma camada processadora, mas apenas uma camada distribuidora.

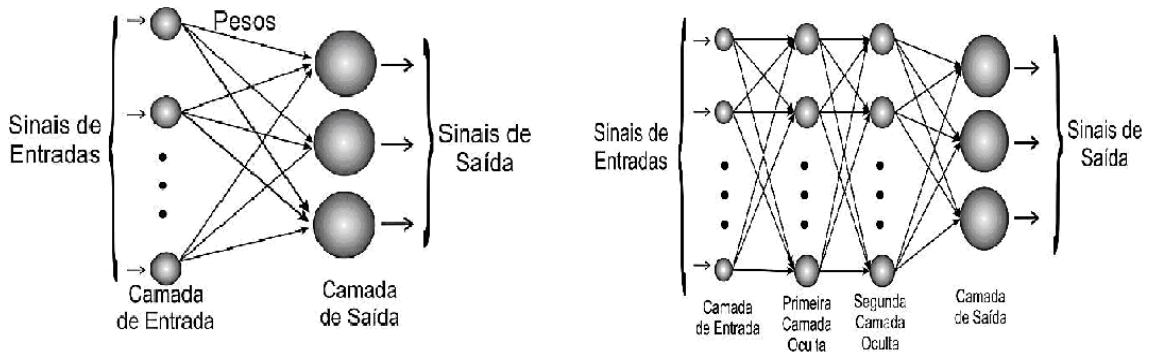

Figura 11 – Redes neurais com duas camadas (simples) e múltiplas camadas
Fonte: Adaptado de Ferraz (2013).

Ainda, segundo Artero (2009), outra possibilidade para classificar uma rede neural é de acordo com o fluxo dos sinais processados, que pode ser sempre da entrada para a saída, no caso das redes com alimentação adiante (feed-forward), ou também usando uma realimentação (feed-backward), quando alimentação vem também de neurônios de camadas posteriores.

Uma rede pode ser classificada de acordo com o tipo de processamento que realiza e o modo como é treinada. O treinamento (ou aprendizado) consiste em apresentar padrões à entrada da rede, para que ela possa ir modificando seus pesos, de modo que as suas saídas apresentem uma resposta adequada quando as entradas receberem valores parecidos, mas não necessariamente iguais, com os usados no treinamento (ARTERO, 2009).

2.6.5 Aprendizado ou Treinamento

O aprendizado natural pode ser definido como a capacidade de se adaptar, de modificar e melhorar seu comportamento e suas respostas sendo, portanto, uma das propriedades mais importantes dos seres ditos inteligentes, sejam eles humanos ou não, (OSÓRIO e BITTENCOURT, 2000).

Do ponto de vista computacional, o aprendizado de máquina tenta fazer com que os programas de computador “aprendam” com os dados que eles “estudam”, tal que esses programas tomem decisões diferentes baseadas nas características dos dados estudados, usando a estatística para os conceitos fundamentais, e adicionando heurística avançada da inteligência artificial aos algoritmos para alcançar os seus objetivos (GUIMARÃES et al, 2001; GUIMARÃES, 2005).

A aprendizagem em redes neurais artificiais foi definida, de acordo com Mendel e Mclaren (1972) apud Braga et al. (2000), como um processo pelo qual os parâmetros livres (pesos) de uma rede neural são adaptados por meio de um processo de estimulação pelo ambiente no qual a rede está inserida e o tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

O conjunto de treinamento, de acordo com Tafner et al. (1996), é de extrema importância, pois corresponde aos dados que serão apresentados como entrada e utilizados para o aprendizado da rede neural artificial. Essas informações são as fontes do conhecimento de rede neural e todas as generalizações que for capaz de realizar dependem do seu aprendizado.

Segundo Adeloye e Munari (2005), a seleção dos dados de entrada deve ser estudada, de modo que contenha dados com qualidade e em quantidade apropriada. Em relação à quantidade, cabe salientar que se deve dar preferência a dados reais e que possuam credibilidade; dados simulados só devem ser aplicados em situações especiais que os exijam. Além disso, a seleção das variáveis utilizadas exige atenção, pois a inclusão de uma variável pode não fazer diferença ou piorar o desempenho da rede, (ROHN e MINE, 2003).

Após a definição da arquitetura de redes neurais artificiais, a rede é treinada pelo conjunto de dados apresentado a partir da camada de entrada e, em seguida, testado por outro conjunto de dados para a validação. Algumas funções especiais de

treinamento e algoritmos são usados para o treinamento. A formação inicialmente começa por atribuir aleatoriamente os pesos ajustáveis e limiares para cada conexão entre os neurônios.

Segundo Tatibana e Kaetsu (2012), de 50 a 90% do total de dados deve ser separado para o treinamento da rede, dados estes escolhidos aleatoriamente, afim de que a rede "aprenda" as regras associadas ao processo. O restante dos dados só é apresentado à rede neural na fase de testes afim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

Rohn e Mine (2003) destacam que, 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.

O algoritmo de aprendizagem deve ser responsável pela adaptação dos parâmetros da rede, para um determinado conjunto de dados, de modo que haja convergência para uma solução, em um número finito de iterações. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado. Em geral o aprendizado é um processo gradual e iterado, onde os pesos são pouco a pouco modificados várias vezes, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados. Cada iteração deste processo gradativo de adaptação dos pesos de uma rede neural, onde é feita uma apresentação completa do conjunto de dados, é chamada de época ou ciclo de aprendizado, (REZENDE, 2003).

Basicamente, considera-se que o processo de aprendizado tem como característica a ocorrência de estímulo da rede pelo meio externo através da apresentação do conjunto de dados. Como conseqüência deste estímulo, o algoritmo de aprendizado provoca mudança nos parâmetros da rede e, finalmente, a mudança nos parâmetros acarreta em mudança no comportamento da RNA.

Braga et al. (2000) destacam que diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não-supervisionado.

O método supervisionado, de acordo com Braga et al. (2000), é o mais comum no treinamento das redes neurais artificiais, assim denominado pelo fato de as entradas e saídas desejadas serem fornecidas para a rede por meio de um supervisor externo. A rede neural tem sua saída corrente comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual, e a

cada padrão de entrada a rede compara a resposta desejada ajustando-se os pesos das conexões para minimizar o erro.

Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado em redes neurais de camada única são a regra delta (WIDROW e HOFF, 1960) e o algoritmo backpropagation (generalização da regra delta) para aprendizado supervisionado em redes de múltiplas camadas, (RUMELHART et al., 1986).

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.

No aprendizado não-supervisionado, segundo Braga et al. (2000), a rede neural artificial aprende com os próprios dados de entrada (somente as entradas são mostrados à rede), ou seja, este algoritmo não requer o conhecimento das saídas. Um exemplo de rede que utiliza esse aprendizado é a rede de Kohonen.

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 as características da entrada e, deste modo, criar novas classes 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).

2.6.6 Regras de Aprendizagem

As regras de aprendizagem estão relacionados ao ajuste dos pesos e podem ser implementados por diferentes métodos, segundo o tipo de regra de aprendizado que for utilizado.

Segundo Ribeiro (2003) e Osório e Bittencourt (2000), as regras de aprendizagem se constituem como elementos básicos para o projeto de redes neurais artificiais. As regras de aprendizado mais usadas, segundo estes autores, são: aprendizagem por correção de erro, aprendizagem baseada em memória e aprendizagem competitiva.

Na 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.

Na 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.

Na aprendizagem competitiva, a camada de saída da rede neural, 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.

2.6.7 Rede Neurais Perceptron de Múltiplas Camadas (MLP)

A rede perceptron de múltiplas camadas é um sistema de neurônios ligados por conexões sinápticas dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios ocultos, internos ou escondidos e neurônios de saída, que se comunica com o exterior (BEALE e JACKSON, 1994).

Segundo Valença (2010), as redes neurais MLP tradicionais apresentam as seguintes características: uma camada de entrada, uma camada intermediária e camada de saída. Na camada de entrada, cada neurônio desta camada corresponde a uma variável de entrada do problema; uma camada intermediária é a camada responsável pela não linearidade da rede e permitem que as redes MLP sejam capazes de resolver problemas reais. Os neurônios desta camada possuem, normalmente, uma função de ativação sigmóide logística ou tangente hiperbólica; e, uma camada de saída, recebe a resposta da rede neural e representa a variável desejada.

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).

A Figura 12 mostra um exemplo da estrutura de redes neurais de múltiplas camadas.

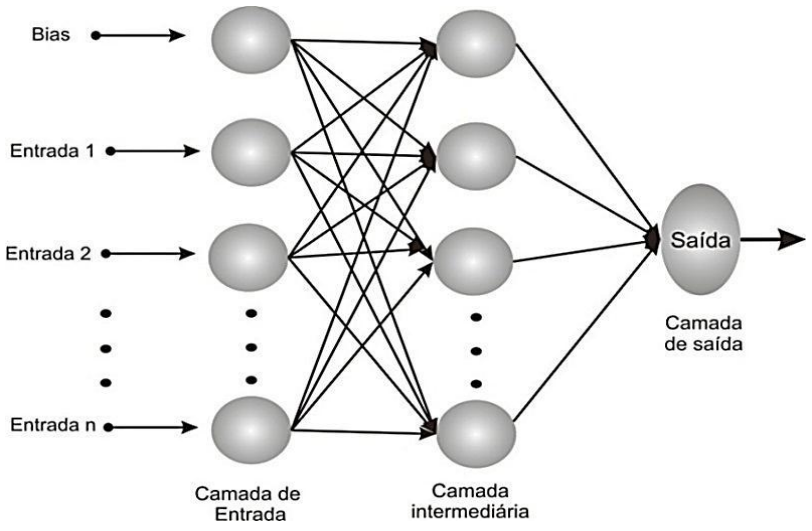

Figura 12 - Rede neural artificial multicamadas (Multilayer Perceptron)
Fonte: Ferraz (2013).

A rede neural artificial passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas fixadas e algoritmos.

As redes MLP são também redes de treinamento supervisionado, logo, o algoritmo backpropagation realiza a propagação recursiva dos erros (VALENÇA, 2010).

Segundo Haykin (1999) o algoritmo backpropagation é baseado em uma regra de aprendizagem que corrige o erro durante o treinamento das redes neurais artificias.

Para as redes neurais artificiais Multilayer Perceptron (MLP) o algoritmo de treinamento ou aprendizagem mais conhecido é o backpropagation, segundo citam

Rumelhart e Mcclell (1986).

As redes neurais com algoritmo backpropagation podem fornecer aproximações precisas para qualquer função contínua com os neurônios suficientes (HORNIK et al.; 1989).

Segundo Valença (2010), esse algoritmo foi originado no trabalho desenvolvido por Paul Werbos, em 1974, mas sua popularização ocorreu apenas na década de 80 através dos trabalhos de Geofrey Hinton, David Rumelhart e Ronald Williams.

O algoritmo de treinamento consiste basicamente em dois passos: no primeiro, propagam-se os sinais no sentido progressivo (da camada de entrada para a camada de saída), calculando-se o sinal de saída e o erro. Os pesos permanecem fixos; no segundo passo, os erros são propagados recursivamente (da camada de saída para a camada de entrada) através da rede e os pesos são ajustados através da regra de ajustes de pesos.

Segundo Andrade et al. (2003), o backpropagation é um algoritmo de aprendizagem eficiente e muito utilizado, porém, sua implementação normalmente exige muitos passos e, assim, um tempo de treinamento longo. Há muitos estudos baseados em heurísticas e em técnicas de otimização, para apressar a convergência do algoritmo, com o objetivo de melhorar sua eficiência em relação ao tempo de treinamento.

De acordo com Braga et al. (2000), os processos de ida e volta dos sinais dos neurônios também são conhecidos como Passo Forward (sinais para frente) e Backward (sinais para trás) e o sentido do fluxo dos cálculos pode ser visualizado na Figura 13.

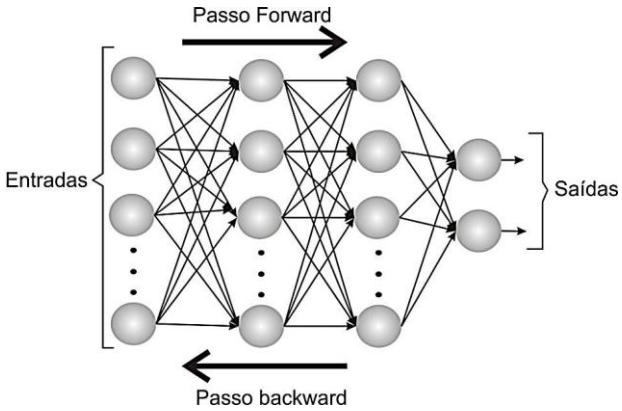

Figura 13 – Sentidos de cálculos do algoritmo backpropagation
Fonte: Ferraz (2013)

Dentre as características que norteiam o funcionamento do algoritmo de aprendizado backpropagation, um detalhe importante é a repetição (ciclos) em um determinado número de vezes (***x***) que o par amostra-resultado (saída) é submetida para que a rede possa, efetivamente, aprender. Estas repetições são chamadas *épocas* de treinamento (ciclos).

Na atualização dos pesos sinápticos, o algoritmo fornece uma aproximação, cujo parâmetro é um índice variando entre 0 (zero) e 1 (um), chamado de *taxa de aprendizagem*. Quanto menor for este parâmetro, menores serão as variações dos pesos sinápticos da rede, de uma iteração para a outra, e mais suave será a trajetória no espaço de pesos. Esta melhoria, entretanto, é obtida à custa de uma evolução de aprendizagem lenta. Por outro lado, caso utilize-se um parâmetro muito alto, para acelerar a aprendizagem, as grandes modificações nos pesos resultantes podem tornar a rede instável oscilatória (HAYKIN, 2001).

2.7 Modelando Redes Neurais

Para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais são necessárias diversas etapas, descritas conforme Caudill (1990): definição do problema; coleta dos dados de treinamento e de teste; pré e pós-processamento dos dados; projeto da estrutura da rede; treinamento; teste e validação.

Segundo Haykin, (1994), alguns passos devem ser seguidos para a adequada aplicação da abordagem neural, podendo então efetuar o mapeamento do processo através das redes neurais artificiais.

Ainda para Valença, (2010) Para realizar a modelagem da RNA, é preciso fazer a divisão dos dados, selecionar as variáveis de entrada e saída, determinar a arquitetura de rede, treinar e validar o desempenho.

2.7.1 Coleta de dados

Segundo Silva (1997) e Valença (2005), a coleta dos dados relacionados com

o problema é o primeiro passo para o desenvolvimento das RNAs. É muito importante minimizar a ambigüidade e erro dos dados, para isso, uma análise cuidadosa deverá ser feita na busca e coleta dos mesmos. Além disso, os dados não devem cobrir apenas as operações normais ou rotineiras, e sim, devem ser significativos, cobrindo amplamente o problema e também as exceções e as condições nos limites do domínio do problema.

2.7.2 Divisão dos dados

Conforme Valença (2005), O conjunto de dados deverá ser dividido em três subconjuntos independentes: um conjunto para verificação, um conjunto para validação e um conjunto para ajustar os pesos durante o treinamento.

Os conjuntos são normalmente divididos em 50% da amostra para treinamento, 25% para validação e 25% para realizar a verificação do desempenho do modelo, (VALENÇA, 2005).

É importante lembrar que, como qualquer modelagem, os conjuntos de dados utilizados para os modelos de redes neurais devem ser estatisticamente representativos da mesma amostra populacional.

2.7.3 Normalização dos dados

É muito importante que a normalização dos dados seja feita, para que as variáveis em diferentes intervalos tenham a mesma atenção durante o treinamento. Quando os dados não são divididos adequadamente e possuem intervalos distintos de variação para os subconjuntos a modelagem ficará prejudicada.

Deve-se normalizar as variáveis de forma que seus valores sejam proporcionais aos limites das funções de ativação usada na camada de saída. Os tipos de normalização mais utilizados são mostrados na Tabela 2.

Tabela 2: Tipos de normalização utilizados nas RNAs

Transformação linear	Normalização estatística	Normalização simples
$y = \frac{(b-a)(xi - x_{min})}{x_{max} - x_{min}} + a$	$y = \frac{x_i - \bar{x}}{s}$	$y = \frac{x_i}{x_{max}}$

Onde:

Y = valor normalizado;

x_i = valor original;

x_{min} = valor mínimo da variável;

x_{max} = valor máximo da variável;

$\bar{x}$ = valor médio da variável;

a e ***b*** = limites

S = desvio padrão.

2.7.4 Determinação das variáveis de entrada

O conhecimento do modelador sobre os dados trabalhados e o problema a ser solucionado influem na quantidade de neurônios na camada de entrada e de saída. No entanto, em alguns casos, a seleção das variáveis de entrada é feita com base em análise estatística, tais como, redes polinomiais, análise de componentes principais, técnica de stepwise e correlação. As técnicas estatísticas tradicionais conseguem captar apenas características lineares, não sendo o método mais adequado em muitas aplicações onde os fenômenos são tipicamente não lineares (VALENÇA, 2005).

Segundo Valença (2007), a complexidade da rede aumenta com uma grande quantidade de entrada e também aumenta a quantidade de dados requeridos para

estimar seus pesos. A inclusão de entradas irrelevantes pode prejudicar o processo de treinamento, tendo por resultado correlações espúrias que estão sendo modelados

2.7.5 Arquitetura da rede

É necessário definir uma arquitetura quando vai se modelar uma RNA, sendo que para as redes Multi-Layer Perceptron (MLP), define-se a quantidade de neurônios nas camadas intermediárias.

A quantidade de neurônios na camada intermediária, segundo Valença (2005), é um fator importante a ser determinado, pois, quanto maior a quantidade de neurônio, maior será sua capacidade de mapeamento não linear da rede. Porém uma quantidade excessiva de neurônios exige mais cuidado na modelagem, pois, pode levar a perda da capacidade de generalização da rede, fator econhecido como rede superajustada (*overffiting*). A rede, no entanto, quando possui um número pequeno de neurônios, perde sua capacidade de aproximação, ficando subajustada *(underfitting).*

Na camada intermediária das redes multicamadas o processo de tentativa e erro, nos diz, o número ótimo de neurônios a ser usado. Contudo, o treinamento de diversas redes com diferentes quantidades de neurônios na camada intermediária se torna uma maneira prática para se determinar o número de neurônios da camada. É definida uma métrica para a avaliação do erro de cada uma das redes e é escolhida a que apresentar menor erro.

Buscando solucionar essa questão, foram realizados estudos utilizando fórmulas empíricas para determinar o número de neurônios na camada intermediária. As que se destacam são: regra de Baum-Haussler e a regra de Hetcht-Nielsen.

2.7.6 Treinamento das redes

Segundo Valença, (2007), o treinamento da rede neural baseia-se no

estabelecimento dos valores dos pesos entre as conexões. Isto é equivalente a determinação dos parâmetros dos modelos estatísticos. A função que será minimizada durante o treinamento é a função erro. A função mais usada é a função erro médio quadrático, no entanto podem ser usadas outras funções de erros

O uso do erro médio quadrático tem como vantagens suas características matemáticas, tais como: facilidade de cálculo, métrica que penaliza erros grandes e cálculo simples das derivadas parciais em relação aos pesos.

Para evitar que a rede perca a sua capacidade de generalização, utilizamos a validação cruzada, que com um conjunto de dados informa quando devemos parar de treinar a rede neural. A validação é uma técnica que tem por objetivo evitar o treinamento em excesso.

2.7.7 Verificação do desempenho

O conjunto de verificação é aquele que deve ser separado para avaliar o desempenho do modelo ajustado, sendo que esse conjunto de dados não deve ser utilizado para o ajuste dos pesos nem para validade cruzada.

Para Valença (2005), são empregadas mais freqüentemente as medidas de erros citadas a seguir: erro médio quadrático (EMQ), o erro médio absoluto (EMA), erro relativo percentual médio absoluto (EPMA), o erro padrão de predição (EP), coeficiente da eficiência (CE) e o coeficiente da determinação (r^2).

Ainda Valença (2005), cita que, em alguns casos de previsão, utilizam-se outros índices: índice de concordância, índice de ajuste volumétrico e o índice de erro relativo do pico.

2.8 Aplicação das Redes Neurais Artificiais na geotecnia

Muitos engenheiros estão interessados em estimar os parâmetros de cisalhamento utilizando métodos indiretos.

Durante a última década, as redes neurais artificiais têm sido aplicadas a

muitos problemas geotécnicos, tais como previsão do comportamento do solo, estruturas de contenção de terra, estabilidade de taludes, estimativa da resistência ao cisalhamento, entre outros (DIHORU et al., 2005).

Kayadelen et al. (2009) usaram Programação de Expressão Genética (PEG), Rede Neural Artificial (RNA) e Neuro difusa Adaptativa (ANFIS) para a previsão do ângulo efetivo de atrito interno da resistência ao cisalhamento do solo.

Chang e Chao (2006) investigaram a aplicação de redes backpropagation na previsão de fluxos de detritos e seus resultados indicaram que a previsão RNAs tem precisão aceitável.

Gomez e Kavzoglu (2008) utilizaram redes neurais artificiais, para avaliar a suscetibilidade ao deslizamento de terra rasa da bacia hidrográfica de Jabonosa (Venezuela).

Nefeslioglu et al. (2008) utilizaram regressão logística e redes neurais artificiais para a elaboração de mapas de susceptibilidade à escorregamentos.

Das e Basudhar (2008) usaram redes neurais artificiais para predição do ângulo de atrito residual de argilas.

3 MATERIAIS E MÉTODOS

3.1 Coleta de dados

Para o desenvolvimento deste trabalho foram utilizados dados secundários a partir de uma pesquisa da literatura nacional e internacional de trabalhos (teses, dissertações, artigos, tcc's, etc.) sobre resistência ao cisalhamento do solo

Nesses trabalhos buscou-se dados de coesão e ângulo de atrito interno, bem como seus fatores influenciáveis: argila, silte, areia, densidade do solo, umidade do solo, Limite de Liquidez, Limite de Plasticidade, e Índice de Plasticidade.

A busca por esses trabalhos foi feita por meio digital, em bibliotecas digitais (Biblioteca brasileira de teses e dissertações, Portal domínio público), periódicos das seguintes Universidades: Universidade Federal de Santa Maria (UFSM), Universidade Federal do Rio grande do Norte (UFRN), Universidade Federal do Rio grande do Sul (UFRGS), Universidade de São Paulo (USP), Universidade de Brasília (UNB), Universidade Estadual de Minas Gerais (UEMG), Universidade Federal de Lavras (UFLA), Universidade Federal de São Carlos (UFSCAR), UEC, SV University, KSI University. O banco de dados agrupado totalizou 30 trabalhos para a estimativa das FPTs.

Os dados foram organizados em planilha eletrônica chamada "Banco de Dados".

Os diferentes bancos de dados foram obtidos de trabalhos provenientes dos autores listados a seguir: Braga (2011); Rosa (2007); Pires (2007); Bassol (2013); Pinheiro (1991); Emmer (2013); Nunes (2010); Carvalho (2010); Fernandes (2011); Braida (2004); Secco (2003); Silva (2003); Jesus (2008); Feuerharmel (2007); Matos (2009); Neto (2008); Gomes (2003); Lukiantchuki (2007); Rocha (2002); Escobar (2011); Prasadi (2013); Kayadelen (2009); Mousavi (2011).

A partir dessas informações foi estudada a possibilidade de desenvolver funções de pedotransferência, com o objetivo de se estimar valores de coesão e do ângulo de atrito interno a partir daquelas características do solo, utilizando as técnicas de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA).

3.2 Pedotransferência com RLM

O desenvolvimento das funções de pedotransferência foi baseado na modelagem dos dados através da regressão linear múltipla.

As funções de pedotransferencia permitiram obter estimativas dos parâmetros cisalhantes do solo (c e Φ) em função de valores de propriedades básicas de solo, como por exemplo, os teores de argila, de silte e de areia, limites de Atterberg, densidade e teor de água.

3.2.1 Ângulo de atrito interno do solo e Coesão do solo

A partir dos valores do ângulo de atrito e coesão do solo (variáveis dependentes) no banco de dados obtido, foram feitas análises de regressão múltipla para a obtenção das funções de pedotransferência usando a opção “stepwise” do software IBM SPSS (Statistical Package for the Social Sciences). O programa computacional selecionou as variáveis que entrarão nas equações de regressão, estimando os parâmetros para as variáveis independentes incluídas no modelo.

Foi ajustado um modelo matemático para a estimativa do parâmetro modelado, ângulo de atrito interno ou coesão do solo, gerado para cada conjunto de dados estudado. São 6 conjunto de dados, com diferentes variáveis independentes de entrada denominados: RLM 1 (Argila, Silte, Areia, Ds e IP), RLM 2 (ArgSil, Areia, Ds e IP), RLM 3 (Argila, Silte, Areia, Ds e LL), RLM 4 (ArgSil, Areia, Ds e LL), RLM 5 (ArgSil, Areia, Ds e LL) e RLM 6 (ArgSil, Areia, Ds, LL e W)

Para formar o banco de dados denominado RLM 5, foram encontrados na literatura somente dados de ângulo de atrito do solo como variável dependente, portanto sem a variável dependente coesão.

Deve-se observar que a modelagem dos dados por regressão linear múltipla só permite que se faça um estudo de uma variável dependente por vez, ou seja, modela-se para coesão e ângulo de atrito separadamente.

3.3 Pedotransferência com RNA

As funções de pedotransferencia permitiram obter estimativas dos parâmetros cisalhantes do solo (c e Φ) em função de valores de propriedades básicas de solo baseados na técnica de modelagem de redes neurais artificiais.

Para a modelagem de dados com redes neurais artificiais, conforme Reinke (2008), foram seguidos alguns passos básicos:

3.3.1 Definição do problema

Apesar de, ao contrário da modelagem com RLM, se pode estimar os dois parâmetros da resistência ao cisalhamento (coesão e ângulo de atrito) simultaneamente com o uso de redes neurais. Foi feita uma investigação de 3 arquitetura de redes neurais: uma com um neurônio na camada de saída (coesão), a segunda com um neurônio na camada de saída (ângulo de atrito) e a terceira tendo dois neurônios na camada de saída (coesão e ângulo de atrito interno).

3.3.2 Seleção dos neurônios na camada de entrada (dados de entrada)

Para a seleção dos neurônios de entrada da rede foram escolhidas seis diferentes banco de dados para as redes neurais artificiais (Tabela 3). Essas RNAs foram treinadas e testadas, logo após foi verificado qual delas teve o melhor desempenho nas funções de pedotransferência. Foram escolhidas as seguintes variáveis de entrada para a formulação das redes: Argila (Arg), Areia (Are), Silte (Sil), Limite de Plasticidade (LP), Limite de liquidez (LL), Índice de Plasticidade (IP), densidade do solo (Ds) e umidade do solo (w). Lembrando que as saídas das redes que foram testadas, são: ângulo de atrito e coesão do solo; somente a coesão do solo e somente o ângulo de atrito do solo.

Para a RNA 5, foram encontrados na literatura somente dados de ângulo de atrito do solo como variável dependente, portanto sem a variável dependente coesão.

Tabela 3. – Neurônios ou variáveis independentes na camada de entrada

	Neurônios ou variáveis de entrada (independentes)								
	Arg	Arg+Sil	Sil	Are	LP	LL	IP	Ds	w
RNA 1	X		X	X			X	X	
RNA 2		X		X			X	X	
RNA 3	X		X	X		X		X	
RNA 4		X		X		X		X	
RNA 5		X		X		X		X	X
RNA 6		X		X		X		X	X

3.3.3 Definição do número de camadas escondidas e do número de neurônios

A arquitetura da rede neural utilizada neste trabalho é composta de uma camada de entrada, uma camada escondida e uma camada de saída (Figura 14).

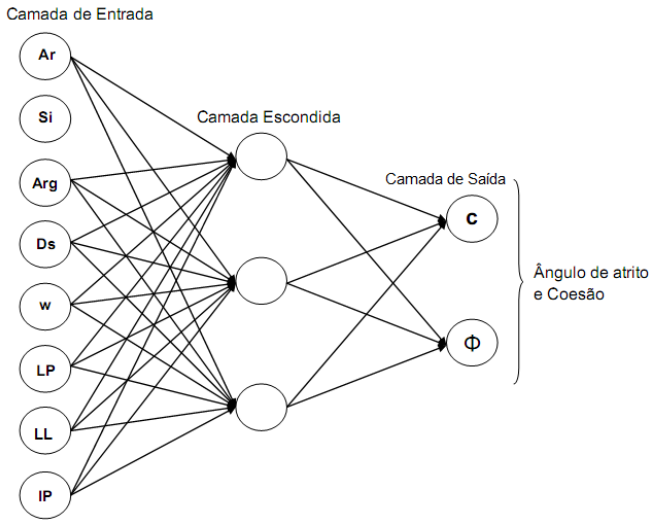

Figura 14 – Desenho de arquitetura da rede neural utilizada.

Para uma mesma arquitetura foram utilizadas diferentes topologias, isto é, foram feitas variações nos neurônios da camada de entrada (mudança de variáveis independentes). Foram feitas variações nos neurônios da camada escondida e por último foram feitas variações nos neurônios de saída (variáveis dependentes).

Como dito anteriormente, apesar da modelagem por redes neurais permitir obter-se mais de um neurônio (mais de uma variável dependente) na camada de saída, foram analisadas três formas de composição do número de neurônios nessa camada: 1) um neurônio (coesão); 2) um neurônio (ângulo de atrito) e, 3) dois neurônios (coesão e ângulo de atrito).

Em relação á camada escondida foi feita variação na quantidade de neurônios nesta camada (10, 20, 30, 40 e 50 neurônios) a fim de verificar para qual topologia se obteve os melhores resultados.

3.3.4 Definição do treinamento da rede neural e avaliação do desempenho

Foi utilizado para treinamento das redes neurais, em torno de 70% do conjunto total de dados. Essa parcela do conjunto de dados foi selecionada de modo aleatório, isto é, sorteio das séries que irão compor essa amostra.

O treinamento das redes neurais artificiais multicamadas foi feito com o módulo Neural Network Toolbox, componente do software Matlab (versão 7.12.0.635).

Esse módulo tem implantado internamente como algoritmo de treinamento o “backpropagation” e como rotina de otimização a de Levemberg-Marquadt. O treinamento foi feito variando as variáveis de entrada e o número de neurônios na camada escondida. Como os pesos são elementos iniciados com valores aleatórios, para cada treinamento obtêm-se valores diferentes.

Cada topologia foi treinada de 10 a 15 vezes e então foi escolhida como melhor resultado aquela com o melhor coeficiente de correlação (R^2) entre os dados obtidos na literatura e os dados estimados pelo conjunto de dados da Rede Neural Artificial

A sequência de organização e realização da rede neural artificial é conforme o diagrama demonstrado na Figura 15.

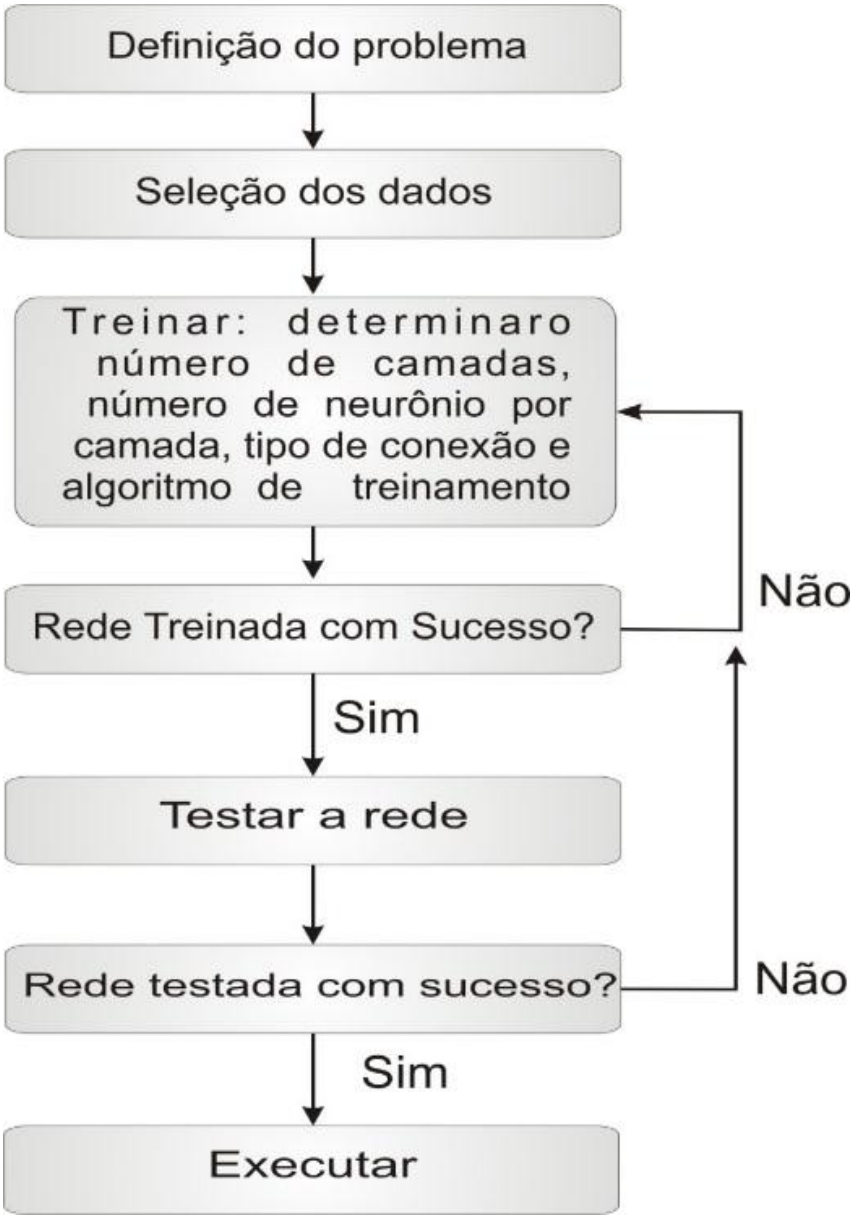

Figura 15 – Sequência de realização da rede neural.
Ferraz (2013)

3.3.5 Validação da rede neural

Foi utilizado para validação da arquitetura e da topologia da rede neural mais adequada os restantes 30% do total do conjunto de dados que foram objetos de seleção aleatório para a fase de treinamento.

3.4 Análise dos dados

A eficiência das funções de pedotransferência foi analisada 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); erro médio (ME) e raiz quadrada do erro médio ao quadrado (RMSE).

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 *r*, que pode ser interpretado como uma medida de precisão será estimado por:

$$r = \frac{\sum_{i=1}^{n}(E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^{n}(E_i - E)\,][\,\sum_{i=1}^{n}(O_i - O)]}} \qquad (3.1)$$

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 à 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 de Willmot (1981), que pode ser interpretado como uma medida de exatidão será calculado pela expressão:

$$c = 1 - \frac{\sum_{i=1}^{n}(E_i - O_i)^2}{\sum_{i=1}^{n}(\,|E_i - O| + |O_i - O|\,)^2} \qquad (3.2)$$

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), pode ser calculado por: $Id = r\ c$.

O índice Id tem a finalidade de avaliar o desempenho do método utilizado, considerando as seguintes classes de interpretação (Tabela 4), de acordo com Costa (2004).

Tabela 4 - Classificação para o índice de desempenho do método proposto.
Costa (2004)

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

4 RESULTADOS E DISCUSSÃO

Neste capítulo foram abordados e discutidos os resultados do trabalho desenvolvido nesta tese. Foram apresentados em tabelas e gráficos as funções de pedotransferência geradas por regressão linear múltipla para os seis conjuntos de dados obtidos denominados RLM 1, RLM 2, RLM 3, RLM 4, RLM 5 e RLM 6, bem como também os valores de coeficiente de correlação total e parcial (R^2). Também foram apresentados os resultados das redes neurais artificiais para cada conjunto de dados (RNA 1, RNA 2, RNA 3, RNA 4, RNA 5 e RNA 6) para os parâmetros de resistência ao cisalhamento do solo – coesão e ângulo de atrito interno do solo – que foram preditos de forma conjunta e separada pelas RNAs.

4.1 Correlação entre as variáveis independentes e os parâmetros cisalhantes do solo das diferentes RLMs.

As correlações entre as variáveis independentes, areia, silte, argila, argisil (silte+argila), densidade do solo (ds), índice de plasticidade (IP), limite de liquidez (LL), umidade do solo (w) e os parâmetros cisalhantes do solo, ângulo de atrito e coesão, estão expressos na tabela a seguir deste subitem para os diferentes conjuntos de dados. Para McCormack e Wilding (1979) esses são os principais fatores influentes que determinam os parâmetros de resistência ao cisalhamento do solo, sendo muito importantes na determinação da coesão e do ângulo de atrito interno. Na Tabela 5, estão demonstradas as correlações entre as variáveis pertencentes às regressões lineares múltiplas RLM 1, RLM 2, RLM 3, RLM 4, RLM 5 e RLM 6. Segundo Milone e Angelini (2003), o coeficiente de correlação de Pearson (r) indica a força e a direção do relacionamento linear entre duas variáveis, sendo que esses valores variam de -1 a 1. O valor -1 indica uma relação linear perfeita, mas inversa, ou seja, quando uma das variáveis aumenta a outra diminui. O valor 0 (zero) indica que não há relação linear e o valor 1 indica uma relação linear perfeita. Quanto mais próximo estiver de 1 e -1, mais forte é a associação linear entre as duas variáveis.

Tabela 5 – Coeficiente de correlação (r) entre as variáveis independentes e a coesão e ângulo de atrito do solo para as Regressões Lineares Múltiplas 1, 2, 3, 4, 5 e 6.

RLM	Variáveis Independentes	Variáveis Dependentes		Média	DP
		Coesão (kPa)	Ângulo de Atrito (^{0})		
1	Argila	0,13	0,123	55,03	11,94
	Silte	-0,255	-0,272	26,3	6,53
	Areia	0,011	0,027	18,67	11,33
	Ds	0,541	0,102	1,37	0,19
	IP	-0,11	-0,212	13,17	3,99
2	ArgSil	-0,011	-0,027	81,33	11,3
	Areia	0,011	0,027	18,67	11,33
	Ds	0,541	0,102	1,37	0,19
	IP	-0,11	-0,212	13,17	3,99
3	Argila	-0,294	0,016	29,2	14,89
	Silte	0,36	-0,295	30,78	11,69
	Areia	0,01	0,19	40,02	16,91
	Ds	0,582	0,162	1,61	0,23
	LL	0,071	-0,263	45,57	11,06
4	ArgSil	-0,145	0,067	79,42	23,51
	Areia	0,162	-0,017	27,19	22,19
	Ds	0,391	0,016	1,62	0,14
	LL	0,281	0,008	34,23	11,99
5	ArgSil	-	-0,24	59,08	19,85
	Areia	-	0,24	40,93	19,86
	Ds	-	0,793	1,79	0,14
	LL	-	-0,374	41,61	11,4
6	ArgSil	-0,042	0,102	76,32	22,23
	Areia	0,042	-0,102	23,68	22,23
	Ds	0,273	-0,035	1,62	0,11
	W	-0,344	-0,495	0,17	0,06
	LL	0,161	-0,03	31,12	10,28

Argila (%), Silte (%), Areia (%), ArgSil - Argila+Silte (%), Ds – Densidade do solo ($gmcm^{-3}$), IP – Índice de Plasticidade (%), LL – Limite de Liquidez (%), w – Umidade do solo (%) e DP – Desvio Padrão

Na RLM 1 foram verificadas correlações positivas entre a coesão e os parâmetros independentes argila, areia e densidade do solo, sendo de maior e menor valor a densidade do solo (0,541) e areia (0,011), respectivamente. Com valores de correlação negativos, sendo inversamente proporcionais à coesão, foram apresentadas as seguintes variáveis independentes: silte, índice de plasticidade, sendo de maior e menor valor respectivamente silte (-0,255) e índice de plasticidade (0,110). O ângulo de atrito foi correlacionado positivamente com argila (0,123 –

maior valor), areia (0,027 – menor valor) e densidade do solo (0,102) e negativamente com silte (-0,272) e índice de plasticidade (-0,212), sendo maior e menor valor respectivamente.

Os valores de correlação apresentados para RLM 2 indicam correlação positiva entre as variáveis independentes areia (0,011 – menor valor) e densidade do solo (0,541 – maior valor) e a variável dependente coesão. A correlação negativa foi observada entre coesão e argsil (-0,011 – menor valor) e índice de plasticidade (-0,110 – maior valor). Para ângulo de atrito as correlações foram positivas com a areia (0,027 – menor valor) e densidade do solo (0,102 – menor valor) e negativas para os parâmetros argsil (-0,027 – menor valor) e índice de plasticidade (-0,212 – maior valor).

O fato da densidade do solo se correlacionar positivamente com esses parâmetros do solo corrobora com o trabalho de Silva et al (2007), que observaram aumento nos valores da coesão e ângulo de atrito interno devido ao aumento da densidade do solo.

Os valores do coeficiente de correlação (*r)* apresentados para RLM 3 demonstram correlação positiva entre a variável dependente coesão e as variáveis independentes silte (0,360), areia (0,010 – menor valor), ds (0,582 – maior valor) e LL (0,071) e correlação negativa para a variável argila (-0,294). O Ângulo de atrito apresentou correlação positiva com as variáveis argila (0,016 – menor valor), areia (0,190 – maior valor) e ds (0,162) e correlação negativa com silte (-0,295) e LL (-0,263).

Na RLM 4, somente a soma argsil (-0,145) apresentou correlação negativa com a coesão, sendo que as outras variáveis areia (0,162 – menor valor), ds (0,391 – maior valor) e LL (0,281) tiveram correlação positiva. Para o ângulo de atrito, a variável que se correlacionou negativamente foi a Areia (-0,017) e positivamente as variáveis argsil (0,067 – maior valor), ds (0,016) e LL (0,008 – menor valor).

Os valores das variáveis independentes da RLM 5 que se correlacionaram positivamente com o ângulo de atrito foram: areia (0,240) e ds (0,793), e negativamente correlacionaram-se as variáveis argsil (-0,240) e LL (-0,374). A ds teve maior valor de correlação e, portanto, maior influência no ângulo de atrito do solo. Esse resultado corrobora com Braida (2004), que afirma que densidade do solo afeta o ângulo de atrito interno por estar relacionada ao arranjo espacial das partículas, ou seja, o número de pontos de contato entre as mesmas, sendo que

para um mesmo material o atrito é tanto maior quanto maior for a densidade do solo.

Na RLM 6, areia, ds, e LL se correlacionaram positivamente com a coesão, sendo maior valor para ds (0,273) e menor valor para a areia (0,042). Negativamente foram correlacionados argsil (-0,042) e w (-0,344). O ângulo de atrito teve correlação positiva com ArgSil (0,102) e negativa com areia, ds, LL e w, sendo a w de maior valor contrário de correlação com o ângulo de atrito. Ainda, de acordo com Braida (2004), a adição de água ao solo resulta na formação de filmes de moléculas de água ao redor das partículas minerais, reduzindo o atrito entre as mesmas, ou seja, quanto maior teor de água no solo menor será o ângulo de atrito interno do solo. Também Silva et al (2007), verificaram aumentos expressivos na coesão e ângulo de atrito do solo quando ocorreu a redução do teor de água do solo.

4.2 FPTs obtidas por Regressão Linear Múltipla (RLM)

As próximas tabelas apresentadas expressam os resultados das Funções de Pedotransferência (FPTs) dos parâmetros cisalhantes do solo (coesão e ângulo de atrito interno do solo), obtidas para cada um dos 6 conjunto de dados da Regressão Linear Múltipla.

4.2.1 Estimativa dos parâmetros de cisalhamento do solo – RLM 1

Na Tabela 6 estão apresentadas as FPTs geradas para a estimativa dos parâmetros coesão e ângulo de atrito interno do solo, com seus respectivos coeficientes de determinação (R^2).

Para a FPT de estimativa da coesão do solo, observa-se que as variáveis com contribuição significativa foram argila, ds e IP, sendo que a ds apresentou destaque por ter maior valor de R^2 parcial (0,293). Esse valor está de acordo com o resultado da correlação apresentada na Tabela 5, onde a ds teve correlação superior com a coesão do solo, quando comparadas com as demais variáveis independentes significativas da FPT. Esse resultado corrobora parcialmente com

Khanlari et al. (2012), que trabalhando com RLM para a estimativa da coesão, também encontrou equação de predição considerando argila e IP, porém sem a inserção de ds como apresentado neste trabalho.

O ângulo de atrito do solo teve somente a variável independente silte como significativa para sua FPT, ainda com um valor baixo de R^2 parcial, com valor de 0,074.

Tabela 6 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 1

Variáveis	Parâmetros Cisalhantes do Solo			
	Coesão		Angulo de Atrito	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-71,69		32,342	
Argila	0,458	0,072	ns	
Silte	ns		-0,198	0,074
Areia	ns		ns	
Ds	72,776	0,293	ns	
IP	-0,703	0,015	ns	
R^2		0,38		0,074

Argila (%), Silte(%), Areia (%), Ds – Densidade do solo ($gm.cm^{-3}$), IP – Índice de Plasticidade (%) e ns – não significativo a 5%.

A relação entre os dados observados e estimados pelas FPTs, juntamente com o R^2 calculado de todas as amostras presentes no banco de dados estão plotados na Figura 16.

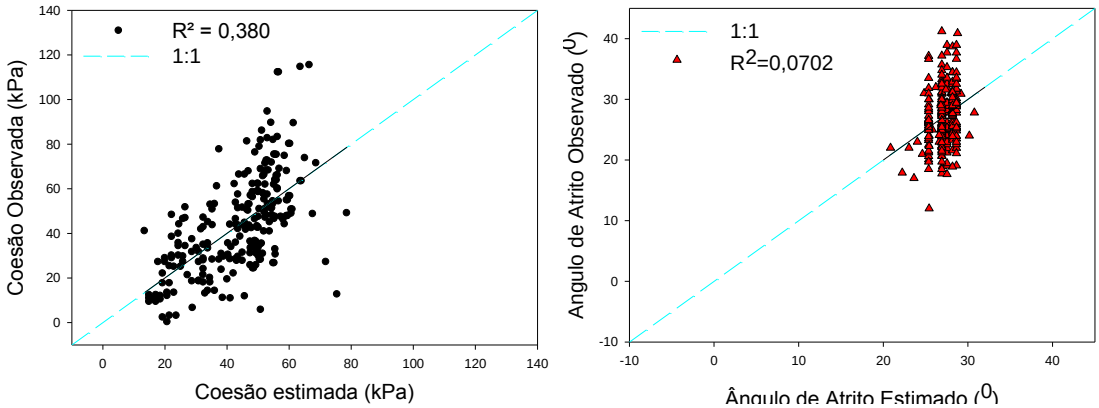

Figura 16 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 1.

Observa-se na Figura 16, que o valor de coeficiente de determinação para a FPT gerada para a coesão, apresenta um valor de R^2 de 0,380, ou seja 38% da coesão estimada é função das variáveis incluídas no modelo proposto. Já para a FPT gerada para o ângulo de atrito do solo, o valor é inferior (0,072).

4.2.2 Estimativa dos parâmetros de cisalhamento do solo – RLM 2

Na Tabela 7 estão apresentadas as FPTs para estimativa dos parâmetros cisalhantes, bem como seus valores de R^2 parcial e total.

Para a FPT proposta de estimativa da coesão do solo foram significativos as variáveis independentes ArgiSil, ds e IP. Igualmente à RLM 1, a ds teve maior valor de R^2 parcial, ou seja teve maior influência na FPT dentre as variáveis significativas. Valor que concorda com a maior correlação com a coesão do solo.

A FPT para a estimativa do ângulo de atrito do solo foi composta por ds e IP. O IP foi a variável que mais contribuiu para a função gerada, apresentando coeficiente de determinação parcial (R^2 parcial) de 0,045.

Tabela 7 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 2.

Variáveis	Parâmetros Cisalhantes do Solo			
	Coesão		Angulo de Atrito	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-95,438		26,185	
ArgSil	0,54	0,056	ns	
Areia	ns		ns	
Ds	80,368	0,293	3,299	0,017
IP	-1,105	0,039	-0,27	0,045
R^2		0,388		0,061

ArgSil – Argila (%) + Silte (%), Areia (%), Ds – Densidade do solo ($gm.cm^{-3}$), IP – Índice de Plasticidade (%) e ns – não significativo a 5%.

Depois dos modelos gerados para estimar a coesão e ângulo de atrito do solo, os mesmos foram avaliados quanto a sua capacidade preditiva, através da

relação 1:1, entre os dados estimados e observados e estimados pelas FPTs, juntamente com o R^2 calculado de todas as amostras presentes no banco de dados da RLM 2 (Figura 17).

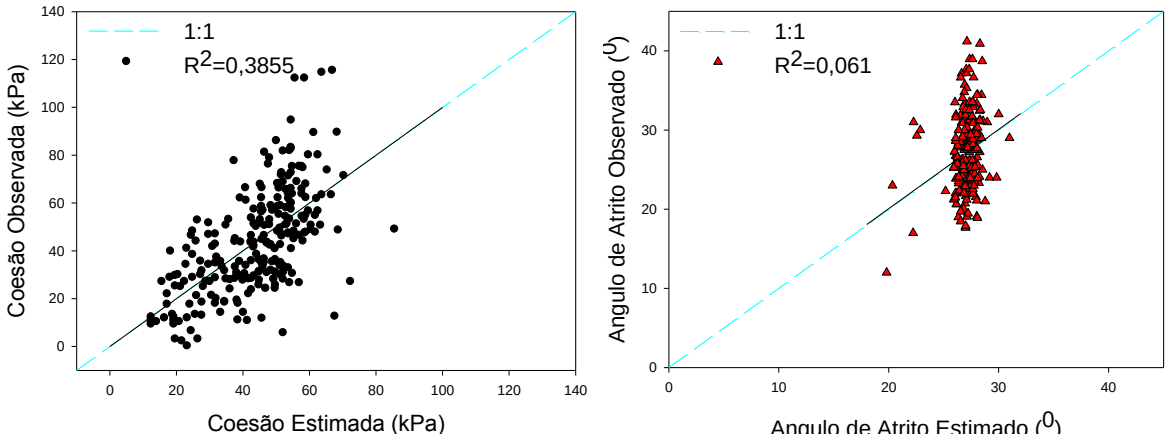

Figura 17 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM2

Os valores baixos de coeficiente de determinação para os parâmetros cisalhantes do solo medidos e preditos pelas FPTs, demonstram baixo desempenho das FPTs para a RLM 2.

4.2.3 Estimativa dos parâmetros de cisalhamento do solo – RLM 3

Na Tabela 8 estão representados os coeficientes das equações de regressão para a estimativa dos parâmetros do solo, a partir do banco de dados obtidos para formar a RLM 3.

A FPT formada para a estimativa da coesão inclui significativamente apenas as variáveis independentes argila e ds. A ds teve maior influência na equação de predição, pois teve maior valor de R^2 parcial (0,339). Esse valor está conforme a maior correlação entre a ds e a coesão do solo, resultado semelhante as RLMs 1 e 2.

Para o ângulo de atrito do solo não houve variáveis significativas a 5% para a

construção do modelo de estimativa.

Tabela 8 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 3

Variáveis	Parâmetros Cisalhantes do Solo			
	Coesão		Angulo de Atrito	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-111,538		ns	-
Argila	ns		ns	-
Silte	1,042	0,235	ns	-
Areia	ns		ns	-
Ds	72,158	0,339	ns	-
LL	ns		ns	-
R^2		0,575		-

Argila (%), Silte (%), Areia (%), Ds – Densidade do solo ($gm.cm^{-3}$), LL – Limite de Liquidez (%) e ns – não significativo a 5%.

Como dito anteriormente não há um modelo gerado para o ângulo de atrito do solo, portanto na Figura 18 está ilustrado somente o resultado da correlação entre os dados observados e preditos de coesão do solo. O coeficiente de correlação é de 0,575.

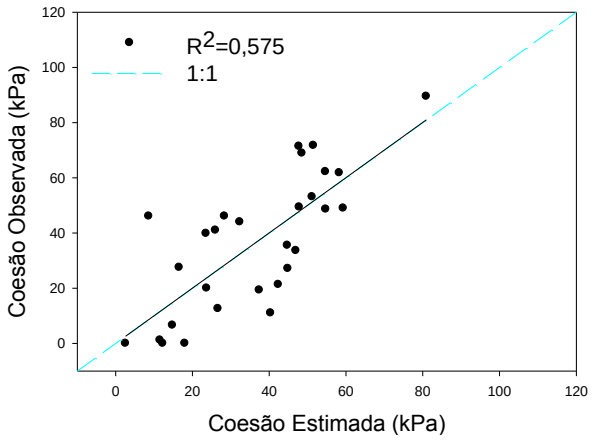

Figura 18 – Valores de coesão do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 3

4.2.4 Estimativa dos parâmetros de cisalhamento do solo – RLM 4

Na Tabela 9 está apresentada a FPT para o parâmetro cisalhante do solo, coesão, referentes aos dados obtidos para formar a RLM 4 .

A FPT gerada para a predição da coesão do solo, por meio de regressão linear múltipla, considerou apenas duas variáveis significativas (ds e LL), dentre todas variáveis independentes presentes na RLM 4. A ds novamente teve mais expressão na FPT, pois seu valor de R^2 parcial foi maior. Esse valor está de acordo com a maior correlação com a coesão do solo, quando comparados com as outras variáveis correlacionadas.

Para o ângulo de atrito interno do solo, semelhante ao caso da RLM 3, também não houve variáveis significativas a 5% para inserção no modelo, por isso nenhum modelo foi gerado.

Tabela 9 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 4

Variáveis	Parâmetros Cisalhantes do Solo			
	Coesão		Ângulo de Atrito	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-111,444		ns	-
ArgSil	ns		ns	-
Areia	ns		ns	-
Ds	78,682	0,153	ns	-
LL	0,674	0,077	ns	-
R^2		0,230		

ArgSil – Argila (%) + Silte (%), Areia (%), Ds – Densidade do solo ($gm.cm^{-3}$), LL – Limite de Liquidez (%) e ns – não significativo a 5%.

A seguir, na Figura 19 está representado o gráfico considerando os valores observados na literatura e estimados pela FPT, de coesão. O modelo apresenta um baixo R^2 (0,230), sendo assim tem baixa capacidade preditiva para o parâmetro coesão do solo.

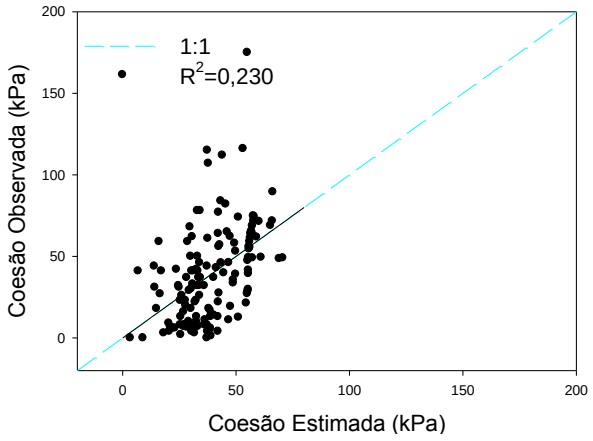

Figura 19 – Valores de coesão do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 4

4.2.5 Estimativa dos parâmetros de cisalhamento do solo – RLM 5.

A RLM 5 é um caso especial, onde o banco de dados é semelhantes à RLM 4, porém contém unicamente os dados de ângulo de atrito interno como saída.

Tabela 10 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 5

Variáveis	Parâmetros Cisalhantes do Solo	
	Angulo de Atrito	
	Coeficiente	R^2 Parcial
Constante	-6,321	
ArgSil	ns	
Areia	ns	
Ds	18,061	0,637
LL	ns	
R^2		0,637

ArgSil – Argila (%) + Silte (%), Areia (%), Ds – Densidade do solo ($gmcm^{-3}$), LL – Limite de Liquidez (XX) e ns – não significativo a 5%.

Na Tabela 10 está apresentada a FPT gerada para estimar o ângulo de atrito interno do solo a para a RLM 5. Observa-se que dentre as variáveis presentes no conjunto, somente a ds foi significativa para formar a equação. O valor de R^2 parcial para ds foi de 0,637. Esse valor esta de acordo com a alta correlação da ds do solo com o ângulo de atrito para este conjunto de dados. Esses resultados corroboram com o trabalho Kayadelen et al (2009), que trabalhando com regressão linear múltipla, concluiu maior importância da ds na geração de FPT para estimar ângulo de atrito do solo.

O resultado da correlação entre os dados observados e preditos do ângulo de atrito do solo estão ilustrados na Figura 20. O valor da determinação (R^2) é de 0,637, ou seja, aproximadamente 65%. Este valor é considerado baixo, ou de baixa capacidade preditiva, pois é inferior a 70%. Segundo a classificação de Garcia (1989), valores abaixo de 70% de coeficiente de determinação (R^2), não apresentam bons ajustes.

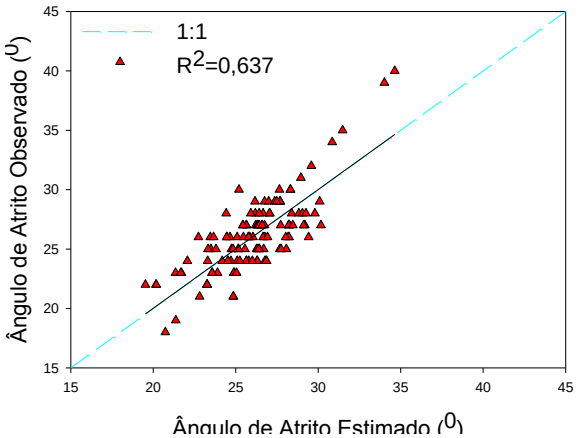

Figura 20 – Valores de ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 5

4.2.6 Estimativa dos parâmetros de cisalhamento do solo – RLM 6.

Na Tabela 11 estão apresentados os resultados das FTPs, para os parâmetros cisalhantes do solo para o conjunto de dados pertencentes à RLM 6.

A FPT gerada para estimar a coesão do solo, teve de forma significativa as seguintes variáveis independentes: argsil, w, ds e LL. Dentre essas variáveis a que teve maior destaque foi a w, por ter um maior R^2 parcial de 0,118.

Mollahasani et al (2010), além da inserção da umidade do solo (w) para a FPT gerada para a predição do parâmetro coesão, também obteve a inserção da fração fina argsil, areia, densidade solo e limite de liquidez.

Para a FPT gerada para estimar o ângulo de atrito do solo, foram significativas as variáveis Argsil, w e LL, sendo que a variável de maior expressão foi novamente a w, com um R^2 parcial de 0,245.

Esses resultados corroboram com Goktepe et al (2007), que utilizando variáveis similares de entrada para a predição da coesão e ângulo de atrito por meio de regressão linear múltipla, também obtiveram a inserção da umidade do solo (w) de forma significativa na equação final de predição desses parâmetros.

Tabela 11 – Coeficientes das equações de regressão linear múltipla e de determinação para estimativa dos parâmetros cisalhantes do solo (coesão e ângulo de atrito) para a RLM 6

Variáveis	Parâmetros Cisalhantes do Solo			
	Coesão		Angulo de Atrito	
	Coeficiente	R^2 Parcial	Coeficiente	R^2 Parcial
Constante	-91,798		22,404	
ArgSil	0,308	0,040	0,103	0,039
Areia	ns		ns	
w	-231,485	0,118	-76,952	0,245
Ds	71,5	0,079	ns	
LL	0,833	0,032	0,164	0,039
R^2		0,27		0,324

ArgSil – Argila (%) + Silte (%), Areia (%), Ds – Densidade do solo ($gm.cm^{-3}$), LL – Limite de Liquidez (%), W – umidade do solo (%) e ns – não significativo a 5%.

As correlações dos valores observados e estimados pelas FPTs para coesão e ângulo de atrito do solo estão ilustrados na Figura 21 abaixo. O valor do coeficiente de determinação para a coesão é de 0,2615, este valor é considerado baixo, portanto tem baixa capacidade de predição da coesão. Para o ângulo de atrito o valor de R^2 (0,3172) é um pouco superior ao da coesão, mas ainda considerado

baixo, portanto também com baixa capacidade de estimar o parâmetro ângulo de atrito do solo.

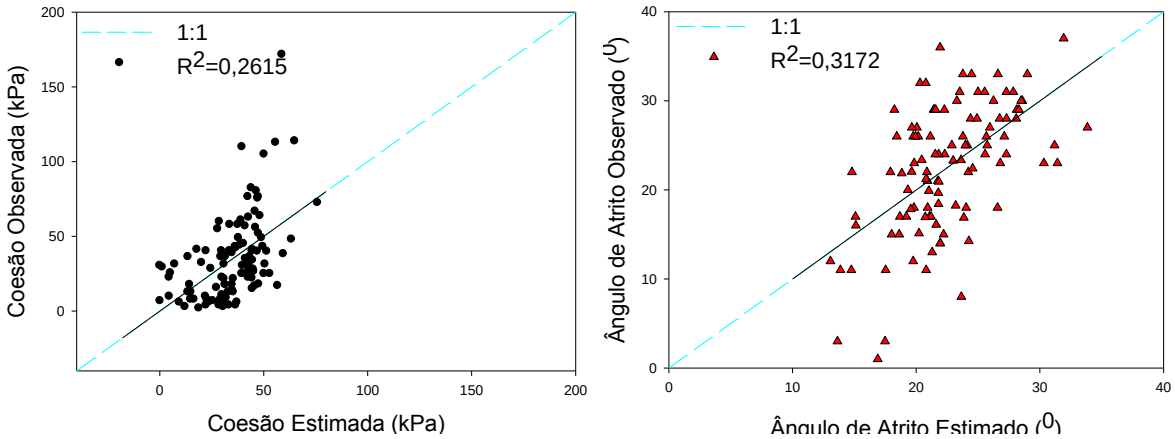

Figura 21 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com regressão linear múltipla, para a RLM 6

4.3 FPTs obtidas pelas redes neurais artificiais

Como dito anteriormente, foram testadas seis redes neurais artificiais (RNA 1, RNA 2, RNA 3, RNA 4, RNA 5 e RNA 6). Cada uma dessas redes neurais é composta de entradas diferentes, tendo como saídas o ângulo de atrito e/ou coesão, estimados simultaneamente e separadamente. A arquitetura entre elas foi a mesma (1 camada escondida na rede), sendo modificada somente a topologia dessas redes. Cada topologia utilizada variou além das variáveis independentes de entrada e as variáveis dependentes de saída, o número de neurônios da camada escondida (10, 20, 30, 40, 50 e 70 neurônios). A seguir serão apresentados, em forma de figuras (gráficos), os melhores resultados para cada uma das RNAs estudadas, sendo apresentados também os respectivos coeficientes de correlação.

4.3.1 Rede neural artifical 1 – RNA 1

Na figura 22 observada a seguir, são apresentados os gráficos de estimativa dos valores observados e estimados de coesão e ângulo de atrito simultaneamente

(a) e separadamente (b – coesão e c – ângulo de atrito). Observa-se que no gráfico onde foram preditos os valores simultaneamente, a melhor arquitetura foi com 20 neurônios para coesão e 30 neurônios para ângulo de atrito e os valores de coeficiente de determinação (R^2) foram de 0,4869 e 0,2165 respectivamente. Quando estimados separadamente, a arquitetura que apresentou melhor predição foi diferente de quando estimada simultaneamente, sendo 30 neurônios para coesão e 50 neurônios para ângulo de atrito. Com relação ao R^2, houveram valores diferentes e superiores (0,5040 para coesão e 0,2965 para ângulo de atrito). No eixo "Y" são plotados os dados de coesão e/ou ângulo de atrito encontrados/observados na literatura e no eixo "X" estão os valores preditos pelas RNAs, de maneira que está exposto no eixo "X" o nome do parâmetro (coesão ou ângulo) e ao lado o número de neurônios com melhor desempenho para cada situação.

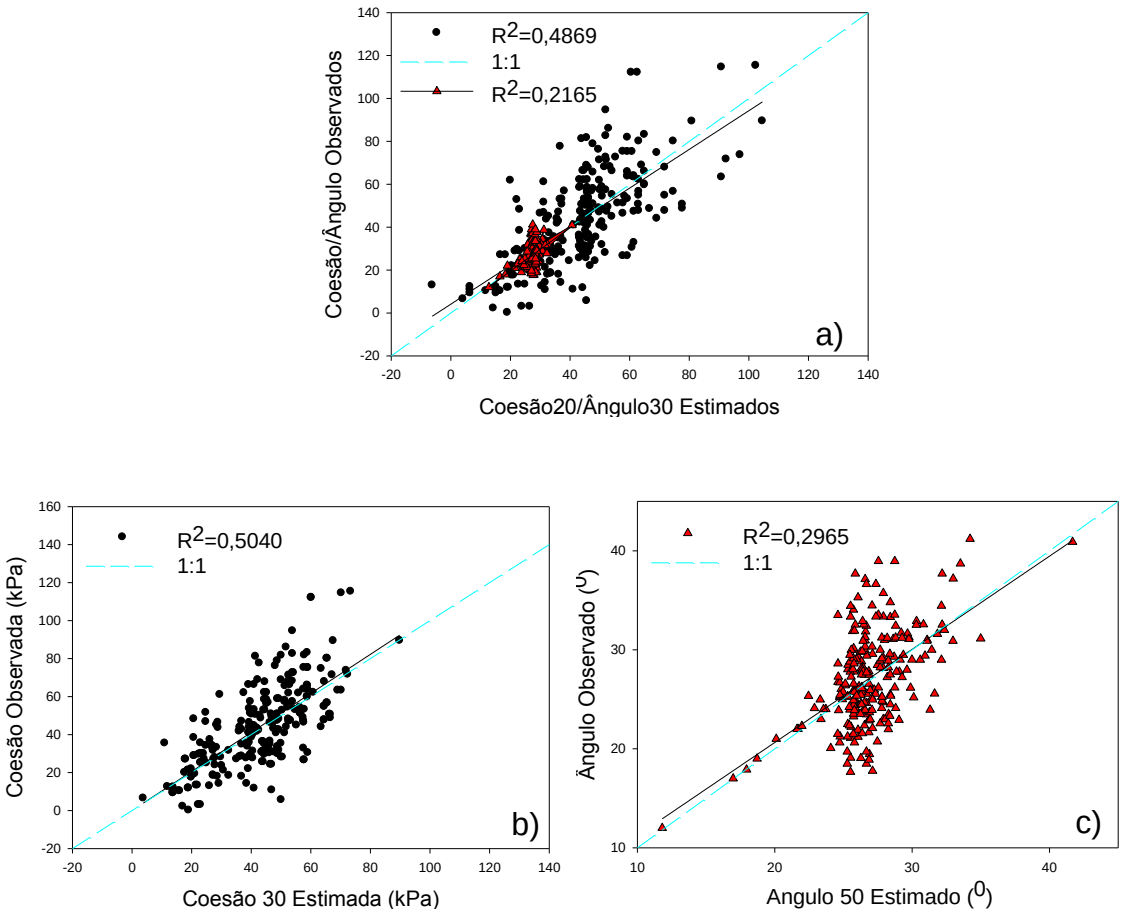

Figura 22 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b – coesão e c – ângulo de atrito), para a RNA 1.

4.3.2 Rede neural artifical 2 – RNA 2

As arquiteturas com 10 neurônios para coesão e 30 para ângulo de atrito foram as que apresentaram melhor capacidade preditiva, quando simulados simultaneamente (a). A relação 1:1, entre os dados observados, presentes no banco de dados da RNA 2 e os estimados pela rede estão representados na Figura 23. O R^2 para a coesão foi 0,5027 e para ângulo de atrito foi de 0,1853. Esses valores foram inferiores aos valores de coeficiente de determinação (R^2) dos parâmetros quando eles foram simulados de forma separada (b – coesão e c – ângulo de atrito), bem como a arquitetura foi diferente, sendo R^2 de 0,5401 e 0,2300 e arquitetura com 50 e 50 neurônios, respectivamente para Coesão e ângulo de atrito do solo.

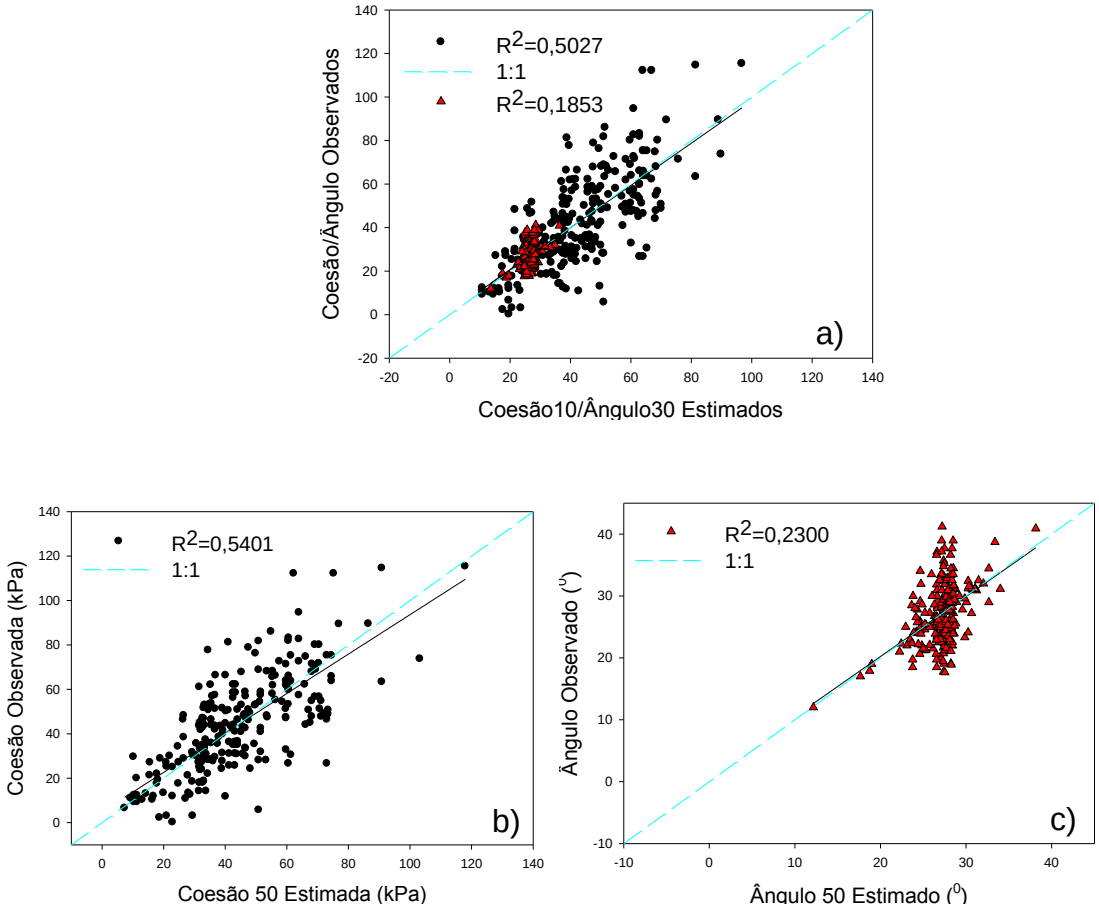

Figura 23 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b – coesão e c – ângulo de atrito), para a RNA 2.

4.3.3 Rede neural artifical 3 – RNA 3

Após o treino de diversas topologias (10, 20, 30, 40, 50 e 70 neurônios), foi observada melhor capacidade preditiva para a topologia com 40 neurônios para coesão e 20 neurônios para ângulo de atrito, quando simulados de forma conjunta (a). Após a validação de cada topologia, foi realizada a comparação entre os valores de coesão e ângulo de atrito observados na literatura e estimados pela rede neural (Figura 24). O coeficiente de determinação (R^2) de coesão e ângulo de atrito, quando simulados juntos, foi de 0,7976 e 0,7773, respectivamente, significando que 79% e 77% da variação total é explicada pela RNA 3 treinada. Quando simulados separadamente (b – coesão e c – ângulo de atrito), as topologias de melhor predição foram com 50 e 40 neurônios na camada escondida, respectivamente para coesão e ângulo de atrito, que também obtiveram valores de R^2 de 0,8727 e 0,8588, coeficientes superiores quando comparados com a simulação conjunta dos parâmetros.

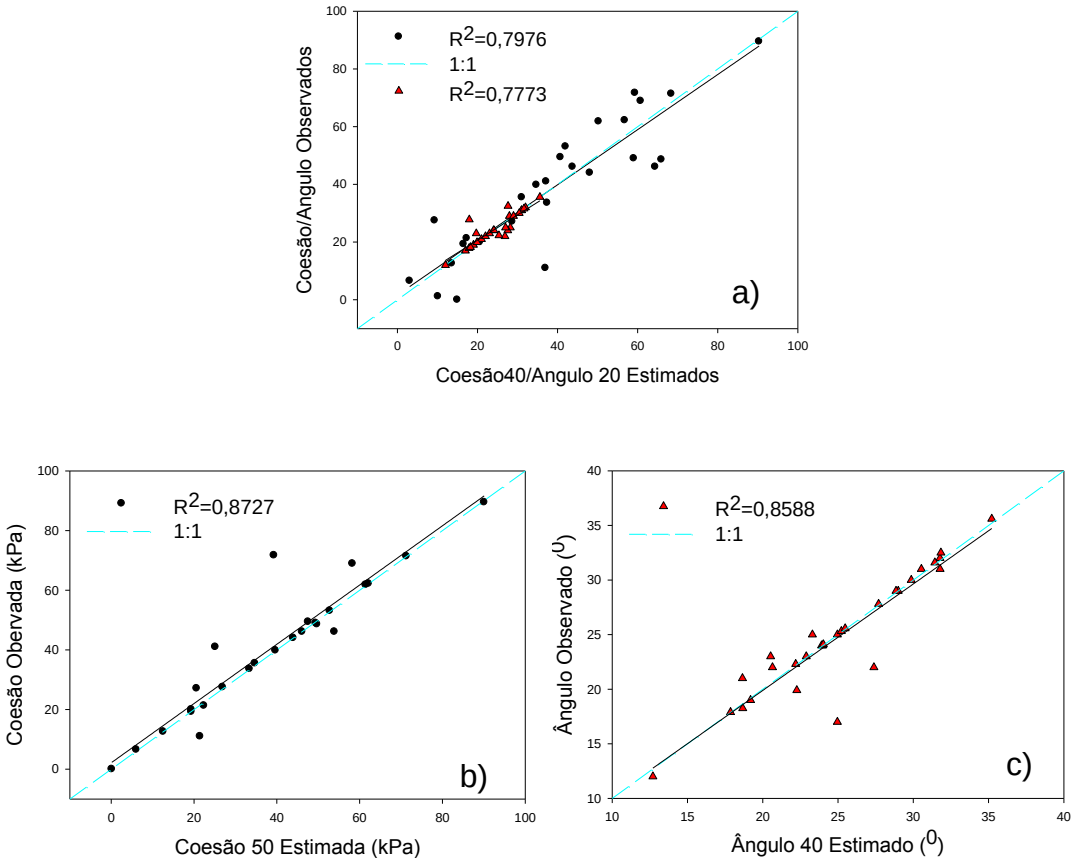

Figura 24 – Valores de coesão e ângulo de atrito observados na literatura e preditos com rede neural artificial simultânea (a) e separada(b –coesão e c –ângulo de atrito),para RNA 3.

4.3.4 Rede neural artifical 4 – RNA 4

Dentre as diversas topologias treinadas, a topologia que obteve melhor capacidade de predição dos parâmetros cisalhantes do solo quando simulados simultaneamente, para a RNA 4 (Figura 25), conteve na camada escondida 40 neurônios para a coesão e 40 para ângulo. Os coeficientes de determinação (R^2) foram 0,4881 para coesão e 0,3133 para ângulo de atrito. Esses valores de R^2 foram superiores aos valores de R^2 dos parâmetros (coesão - 0,4694 e ângulo de atrito - 0,2543), quando simulados separadamente. Também a topologia que melhor apresentou capacidade preditiva foi diferente, sendo 30 neurônios para coesão e ângulo de atrito.

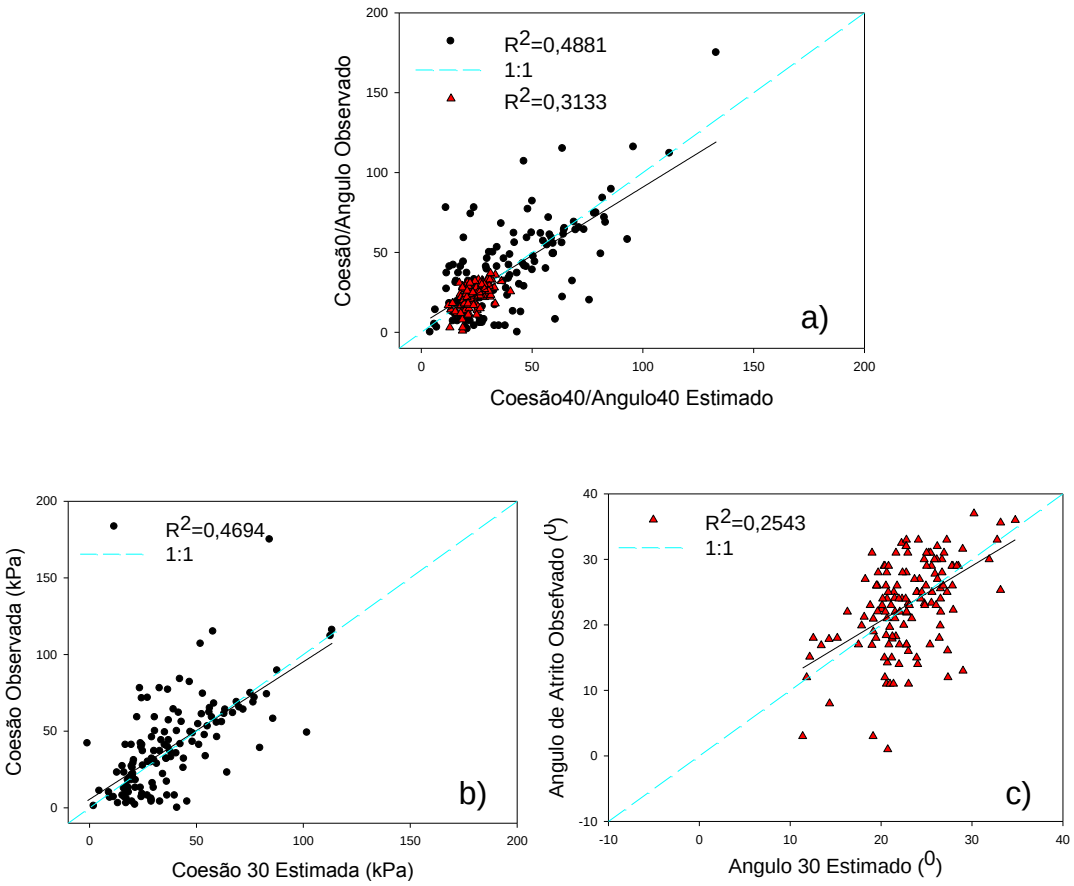

Figura 25 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b – coesão e c – ângulo de atrito), para a RNA 4.

4.3.5 Rede neural artifical 5 – RNA 5

Os dados pesquisados na literatura para formar a RNA 5, foram selecionados da mesma forma que as demais redes, porém além das variáveis independentes de entrada, eles tem apenas a variável dependente ângulo de atrito como saída. Dessa forma, apenas um gráfico (Figura 26) foi gerado, demonstrando que dentre todas as arquiteturas testadas, a que obteve maior capacidade preditiva foi com 10 neurônios na camada escondida. O coeficiente de determinação (R^2) desta rede, para o ângulo de atrito, foi de 0,7812, significando que 78,12% da variação total é explicada pela RNA 5 treinada. Para Smith (1986) e Kasabov (1998), se um modelo da um R^2 maior que 0,80 uma forte correlação existe entre os valores observados e os estimados.

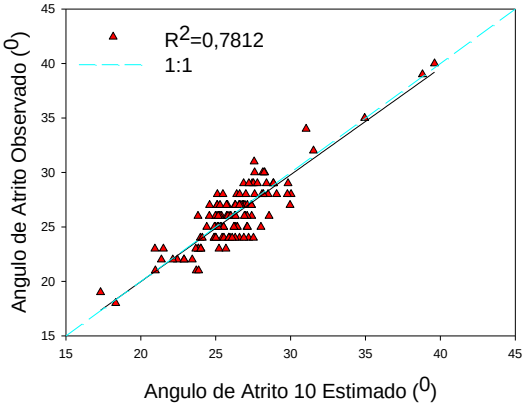

Figura 26 – Valores de ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial, para a RNA 5.

4.3.6 Rede neural artifical 6 – RNA 6

Os melhores resultados de predição para a RLM 6 simultaneamente e separadamente, estão plotados na Figura 27.

Entre todas as arquiteturas testadas para a RNA 6 para estimar os parâmetros cisalhantes simultaneamente (a), as que melhor tiveram capacidade preditiva foram com 20 e 40 neurônios na camada escondida, respectivamente para coesão e ângulo de atrito interno. Foi gerado um coeficiente de determinação (R^2)

para a coesão de 0,6904 e para o ângulo de 0,4670. Quando estimada de forma separada (b – coesão e c – ângulo de atrito), a melhor arquitetura para a coesão se manteve igual com 20 neurônios na camada escondida e o valor de R^2 foi inferior (0,6323). Já para o ângulo de atrito, a melhor arquitetura foi com 50 neurônios escondidos na rede e o valor de coeficiente de determinação (R^2=0,7587) foi superior do que quando estimado de forma concomitante com a coesão. Esses resultados corroboram parcialmente com Mousavi et al (2011), que trabalhando com um conjunto de dados similar, acharam FPTs para estimativa de parâmetros cisalhantes do solo com desempenho satisfatório.

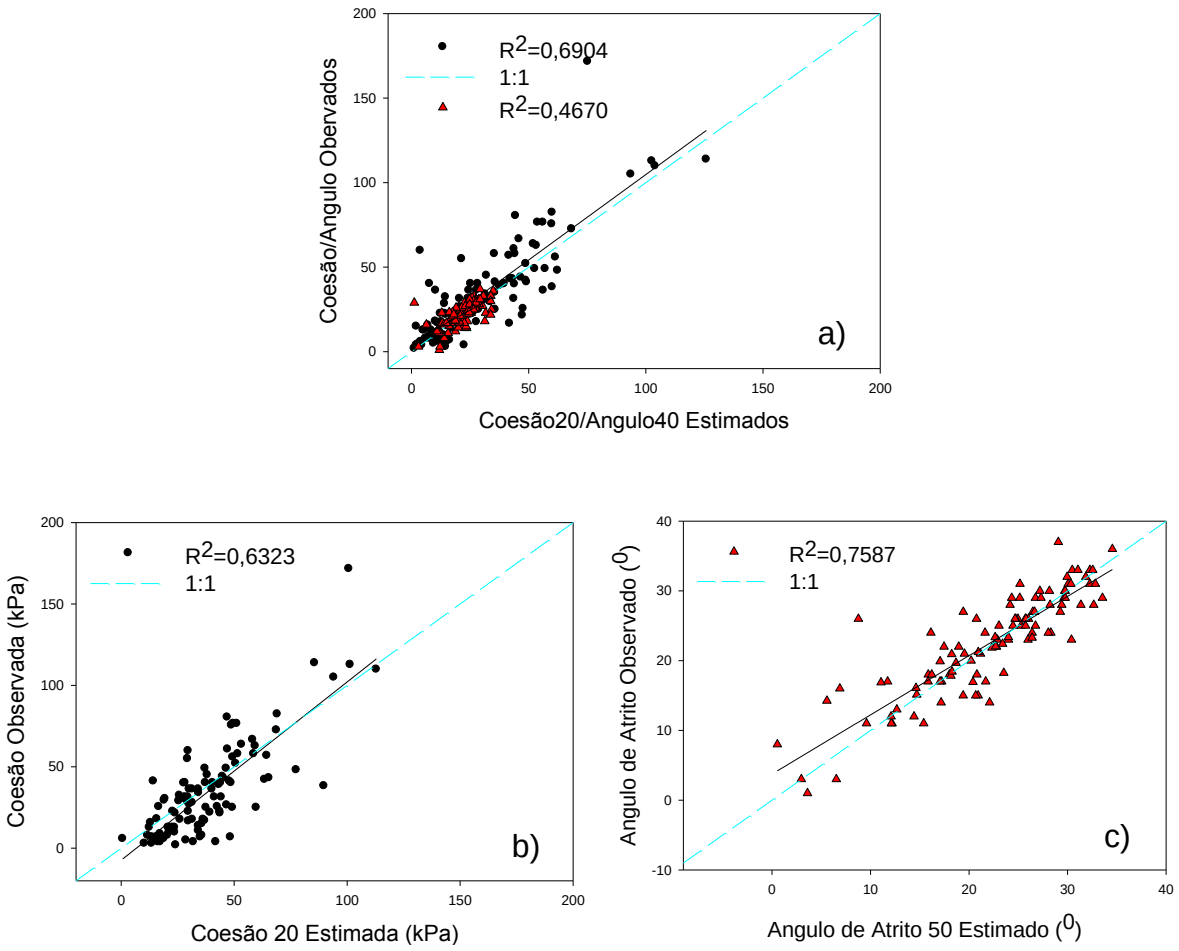

Figura 27 – Valores de coesão e ângulo de atrito interno do solo observados na literatura e preditos com rede neural artificial de forma simultânea (a) e separada (b – coesão e c – ângulo), para a RNA 6.

4.4 Desempenho das FPTs desenvolvidas através de RLM e RNA

A seguir serão apresentados os valores do coeficiente de correlação (r), índice de concordância (c) e índice de desempenho (id) para as RLMs e RNAs desenvolvidas nesse trabalho. A partir dos valores do ic foi concedida uma classificação referente ao desempenho de cada conjunto de dados.

4.4.1 Desempenho das RLMs

Na Tabela 13 está apresentada a classificação (desempenho) referente aos parâmetros de cisalhamento do solo (coesão e ângulo de atrito) das RLMs 1, 2, 3, 4, 5 e 6.

Tabela 12 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e classificação do desempenho, das diferentes RLMs utilizadas para estimativa da coesão e ângulo de atrito interno do solo.

RLM	Parâmetro	c	r	id	Desempenho
1	Coesão	0,9147	0,6167	0,5641	Fraco
	Ângulo	0,3488	0,2722	0,0950	Péssimo
2	Coesão	0,7374	0,6229	0,4593	Muito Fraco
	Ângulo	0,2968	0,2478	0,0735	Péssimo
3	Coesão	0,8537	0,7581	0,6472	Regular
	Ângulo	-	-	-	-
4	Coesão	0,5813	0,4796	0,2788	Péssimo
	Ângulo	-	-	-	-
5	Coesão	-	-	-	-
	Ângulo	0,8751	0,7935	0,6944	Bom
6	Coesão	0,6216	0,5182	0,3221	Péssimo
	Ângulo	0,6846	0,5689	0,3895	Péssimo

Essa classificação é baseada no valor do índice de desempenho (id), que por sua vez é o resultado do produto do coeficiente de correlação (r) com o índice de

concordância (c).

No geral, a maioria das RLMs não apresentou boa classificação de desempenho para as FPTs geradas. A RLM 5, que contém como variáveis independentes de entrada a fração fina do solo (ArgSil), densidade do solo (ds), Areia e Limite de Liquidez (LL) apresentou o melhor desempenho para a FPT de estimativa para o ângulo de atrito, classificado como “Bom”.

Para a estimativa da coesão do solo, a RLM que melhor apresentou desempenho foi a RLM 3, composta pelas variáveis independentes: areia, argila, silte, ds e LL, classificada como “Regular”.

4.4.2 Desempenho das RNAs

A classificação (desempenho) para a coesão e ângulo de atrito do solo estimados de forma conjunta e separadamente, referente às RNAs 1, 2, 3, 4, 5 e 6 estão apresentados na Tabela 14. Essa classificação é baseada no valor do índice de desempenho (id), que por sua vez é o resultado do produto do coeficiente de correlação (r) com o índice de concordância (c). Pela classificação pode-se verificar que há diferença em seu desempenho quando os parâmetros foram estimados em conjunto e separadamente. Os melhores resultados das FPTs foram da RNA 3, composta das seguintes variáveis independentes de entrada: argila, silte areia, ds e LL, que quando estimados juntos apresentaram classificação “Muito Bom” para a coesão e ângulo de atrito. Quando estimados de forma separada esses parâmetros apresentaram desempenho classificado como “’Ótimo”. A RNA 5, composta pelas variáveis independentes argsil, areia, ds e LL, apresentou classificação de desempenho classificada como “Muito Bom”, quando estimado o ângulo de atrito do solo.

A coesão do solo, um dos parâmetros do solo estimados com o banco de dados formador da RNA 6, apresentou classificação de desempenho “Bom” quando estimado de forma conjunta com o ângulo de atrito do solo, bem como estimado de forma separada. O ângulo de atrito, por sua vez, foi classifica do como “Fraco”, quando estimado de forma simultânea com a coesão e “Muito Bom”, quando estimado de forma isolada.

Tabela 13 – Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e classificação do desempenho, das diferentes RNAs utilizadas para estimativa da coesão e ângulo de atrito interno do solo.

RNA	Parâmetro	c	r	id	Desempenho
1 Juntos	Coesão	0,8159	0,6993	0,5706	Fraco
	Ângulo	0,5661	0,4688	0,2654	Péssimo
1 Separados	Coesão	0,8074	0,7114	0,5744	Fraco
	Ângulo	0,6765	0,5471	0,3701	Péssimo
2 Juntos	Coesão	0,875	0,7105	0,6217	Regular
	Ângulo	0,921	0,4344	0,4001	Péssimo
2 Separados	Coesão	0,8899	0,7362	0,6551	Regular
	Ângulo	0,9338	0,4829	0,4509	Muito Fraco
3 Juntos	Coesão	0,9554	0,8974	0,8574	Muito Bom
	Ângulo	0,9195	0,8865	0,8152	Muito Bom
3 Separados	Coesão	0,9742	0,9369	0,9127	Ótimo
	Ângulo	0,9627	0,9294	0,8948	Ótimo
4 Juntos	Coesão	0,8274	0,7015	0,5804	Fraco
	Ângulo	0,7191	0,5645	0,4059	Péssimo
4 Separados	Coesão	0,8143	0,6881	0,5603	Fraco
	Ângulo	0,6668	0,5098	0,3399	Péssimo
5 Juntos	Coesão	-	-	-	-
	Ângulo	0,9371	0,8849	0,8292	Muito Bom
5 Separados	Coesão	-	-	-	-
	Ângulo	-	-	-	-
6 Juntos	Coesão	0,8964	0,8327	0,7464	Bom
	Ângulo	0,8163	0,6872	0,561	Fraco
6 Separados	Coesão	0,8625	0,7974	0,69	Bom
	Ângulo	0,932	0,8724	0,813	Muito Bom

Os resultados das FPTs geradas por redes neurais artificiais tiveram melhor classificação de desempenho, demostrando melhor capacidade de predição dos parâmetros cisalhantes do solo quando comparados a capacidade de predição da regressão linear múltipla. Esse resultado esta de acordo com Soares (2013), que estudando a predição dos pontos matriciais para formar a curva de retenção do solo por meio de FPTs geradas por RLM e RNA, também observou melhor desempenho das RNAs em relação às RLMs. Mousavi (2011) e Khanlari (2012), trabalharam com a predição dos parâmetros cisalhantes do solo com RLM e RNA e também obtiveram melhores resultados com as RNAs.

5 CONCLUSÕES

De acordo com os métodos empregados para a estimativa dos parâmetros cisalhantes do solo neste trabalho, concluiu-se que:

- As Funções de Pedotransferência geradas por Regressão Linear Múltipla tiveram desempenho insatisfatório para estimativa dos parâmetros cisalhantes do solo para todos os conjuntos de dados utilizados;
- As redes neurais artificiais apresentaram capacidade preditiva superior, das funções de pedotransferência, em relação as regressões lineares múltiplas para todos os bancos de dados estudados;
- Obteve-se diferença entre os resultados das arquiteturas das RNAs, quando os parâmetros coesão e ângulo de atrito interno foram preditos conjunta e separadamente;
- Os números de neurônios com melhores resultados na camada oculta foram: RNA 3 - 40 e 50 para coesão e ângulo, respectivamente, quando preditos juntos e 50 e 40, quando preditos separados. RNA 5 - 10 neurônios para predição do ângulo de atrito. RNA 6 - 20 e 40 neurônios, quando estimados juntos coesão e ângulo, respectivamente, e 20 e 50, quando estimados separados.

REFERÊNCIAS BIBLIOGRÁFICAS

ADELOYE, A. J, & DE MUNARI, A. Artificial neural network based generalized storage–yield–reliability models using the Levenberg–Marquardt algorithm. **Journal of Hydrology**, 326(1–4), 215−230, 2005.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6459**: Solo – Limite de liquidez. Rio de Janeiro, 1984d.

AL-SHAYEA, N.A.The conbined effect of clay and moisture content on the behavior of remolded unsaturated soils. **Engineering geology**, Amsterdam v. 62, p. 319- 342, 2001.

ANDRADE. M. C. de; NETO, A. R.; ROSA, R. R.; SAWANT, H. S.; FERNANDES, F. C. R. Spatiotemporal Patterns Estimation Using a Multilayer Perceptron Neural Network in a Solar Physics Application. Learning and Nonlinear Models – **Revista da Sociedade Brasileira de Redes Neurais**, v.1, n.2, p. 159-167, 2003.

ARTERO, A.O. **Inteligência Artificial Teórica e Prática**. São Paulo: Livraria da Física, 2009.

ARVIDSSON, J.; TRUTNER, A.; VAN DEN AKKER, J.J.H. et al. Subsoil compaction caused by heavy sugarbeet harvesters in southern Sweden. II. Soil displacement during wheeling and model computations of compaction. **Soil &TillageResearch**, Amsterdam, v.60, p.79-89, 2001.

AZEVEDO, M. A. A. **Contribuição ao estudo geotécnico de solos de Viçosa** – MG. Viçosa: Universidade Federal de Viçosa, 1999. 169 p

AZEVEDO, F. M.; BRASIL, L. M. e OLIVEIRA, R. C. L. de. **Redes neurais com aplicações em controle e em sistemas especialistas**. Florianópolis: Visual Books Editora, 2000, 401p.

BALASTREIRE, L.A. **Máquinas agrícolas**. São Paulo: Manole. 1987. 310p.

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.

BAUMGARTL, T. & HORN, R. Effect of aggregate stability on soil compaction.**SoilTill. Res.**, 19:203-213, 1991.

BEALE, R., AND T. JACKSON,: Neural Computing: An Introduction. **Institute of Physics Publishing**, 240 pp, 1994.

BOENI, M. **Comportamento mecânico de solos escarificados em função do teor de água e pressão de inflação dos pneus do trator**. 2000. 99 f. Dissertação

(Mestrado em Ciência do Solo) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

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

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.

BRAIDA, J.A. **Matéria orgânica e resíduos vegetais na superfície do solo e suas relações com o comportamento mecânico do solo sob plantio direto**. 2004, 107p, Tese (Doutorado em Ciência do Solo). Universidade Federal de Santa Maria,Santa Maria,2004

BUDIMAN, M.; McBRATNEY, A.B.; MENDONÇA-SANTOS, M.L. & SANTOS, H.G. **Revisão sobre funções de pedotransferência (PTFs) e novos métodos de predição de classes e atributos do solo.** Rio de Janeiro, Embrapa Solos, 2003. 50p. (Documento 45)

CAMARGO, A. P; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativas da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, n.1, p.89-97, 1997.

CANAKCI, H., BAYKASOGLU, A., GULLU, H.. Prediction of compressive and tensile strength of Gaziantep basalts via neural networks and gene expression programming. **Neural Computing & Applications** 18, 1031–1041, 2009.

CAPUTO, H. P. M**ecânica dos solos e suas aplicações,** 3ª ed. (revisada e ampliada). Rio de Janeiro, Livros Técnicos e Científicos, vol.1, 1976. 242p.

CAPUTO, H. P. M**ecânica dos solos e suas aplicações,**. Rio de Janeiro, Livros Técnicos e Científicos, vol. 2, 1981. xxxp.

CAUDILL, M., Neural Network Primer, Miller Freeman Publications. (1990)

CERQUEIRA E. O., ANDRADE J. C., POPPI R. J., MELLO C. Redes Neurais e suas aplicações em calibração multivariada. **Quim. Nova** 24, 864-873, 2001.

CHANG, T.C., CHAO, R.J. Application of back-propagation networks in debris flow prediction. **Engineering Geology** 85, 270–280. 2006

CRAIG, R. F. M**ecânica dos solos.** 7ª ed. Rio de Janeiro, Livros Técnicos e Científicos, 2004. 365p.

COSTA, T.; LANÇA, R. Universidade do Algarve. Núcleo de hidráulica e ambiente. **Barragens**. Faro, 2001.

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

CHONG, IL-GYO, JUN, CHI-HYUCK.Performance of some variable selection methods when multicollinearity is present. **Chemometrics** and Intelligent Laboratory Systems, 78: 103, 2005.

DAS, S.K., BASUDHAR, P.K. Prediction of residual friction angle of clays using artificial neural network. **Engineering Geology** 100, 142–145, 2008.

DIHORU, L. ET. AL " A neural network for error prediction in a true triaxial apparatus with flexible boundaries", **Computers and Geotechnics**, , vol. 32, pp. 59-71. 2005

EKWUE, E.I. Organic matter effects on soil strength properties. **Soil Tillage Res.**, 16:289-297, 1990.

EKWUE, E.I. & STONE, R.J. Organic matter effects on the strength properties of compacted agricultural soils.**Trans. Am. Soc. Agric. Eng.**, 38:357-365, 1995.

EL-MAKSOUD, M. A. F. "Laboratory determining of soil strength parameters in calcareous soils and their effect on chiseling draft prediction."**Proc. Energy Efficiency and Agricultural Engineering** Int. Conf., Rousse, Bulgaria.(2006).

FAUSETT, L.V. "Fundamental of neural networks: Architecture, algorithem, and applications", Prentice-Hall, Inc., **Englewood Cliffs**, N.J, 1994.

FERRAZ, R., C. **Sistema Web e Mobile para estimativa de evapotranspiração de referência utilizando redes neurais artificiais**. 2013. 119f. Tese (Doutorado em Engenharia Agrícola). Universidade Federal de Santa Maria. Santa Maria, 2013.

FERREIRA, F., P.; SECCO, D.; REINERT, D., J.; REICHERT, J., M. &, JUNIOR S., A., G. Influência da compactação do solo sobre parâmetros de resistência ao cisalhamento em latossolo vermelho distroférrico sob sistema plantio direto. In: XVI REUNIÃO BRASILEIRA DE MANEJO E CONSERVAÇÃO DO SOLO E DA ÁGUA. Cuiabá. **Anais...**2002.

FISCHER, G., SHAH, M., VAN VELTHUIZEN, H., NACHTERGAELE, F.O. Global agro-ecological assessment for agriculture in the 21stCentury. **IIASA Research Report 02-02**, International Institutefor Applied Systems Analysis, Laxenburg, Austria, p. 119 2001

FLOOD, I., AND KARTAM, N. "Neural networks in civil engineering: Systems and application." **J. Comp. in Civ. Engrg**., ASCE, 8(2), 131-148, 1994.

FIORI, A. P.; CARMIGNANI, L. **Fundamentos de mecânica dos solos e das rochas: aplicações na estabilidade de taludes**. Universidade Federal do Paraná. 2ª ed. Editora UFPR. Curitiba, 2009. 604p.

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.

FREDLUND, D.G. & RAHARDJO, H. **Soil mechanics for unsaturated soils**.New York, John Wiley, 1993. 517p.

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.

GOMEZ, H., KAVZOGLU, T. Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela. **Engineering Geology** 78, 11–27, 2008.

GUPTA S.C., LARSON W.E. Estimating soil water retention characteristics from particle size distribution, organic matter content, and bulk density. **Water Resour**. **Res**., 15:1633-1635. 1979 b

GUIMARÃES, A. M.; VRIESMANN, L. M.; TOMASI, A. L. B.; CANTERI, M. G.; MATHIAS, I. M. **Aplicação de Técnicas de Data Mining na obtenção de padrões de características físico-químicas do solo em função de sua produtividade**. In: X Encontro Anual de Iniciação Científica e I Encontro de Pesquisa da UEPG, Anais..., Ponta Grossa: Editora UEPG, v.1. p.292 – 293, 2001.

GUIMARÃES, A. M. **Aplicação de computação evolucionária na mineração de dados físico-químicos da água e do solo**, 2005. Tese. 127p. (Doutorado em Agronomia – Energia na Agricultura), Universidade Estadual Paulista – UNESP, Botucatu, 2005.

HAYKIN, S. **Neural Networks**. A Comprehensive Foundation. Macmillan, New York, NY, 1994.

HAYKIN S. **Neural networks**. Englewood Cliffs, NJ: Prentice-Hall; 1999.

HAYKIN, S. "**Neural Networks**", Second Edition, Addison Wesely Longman, 2000.

HAYKIN, S. Redes Neurais: **Princípios e prática**. 2.ed. Porto Alegre: Bookman, 900p, 2001.

HAIR Jr., J.F. et al. **Análise Multivariada de Dados**. 5. ed.Porto Alegre: Bookman, 2005.

HECHT-NIELSEN, R. **Neuro computing**, Reading, MA: Addison-Wesley, 1990.

HORN, R.; TAUBNER, H.; WUTTKE, M.; BAUMGARTL, T. Soil physical properties related to soil structure.**Soil Tillage Res**., 30:187-216,1993

HORN, R.; LEBERT, M. Soil compactability and compressibility. In: SOANE, B.D.; OUWERKERK, C. VAN. (Edi.). **Soil compaction in crop production.** Amsterdam: Elsevier, 1994. 662p.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359-366, 1989.

JACKSON, J. Data Mining: **A Conceptual Overview. Communications of the Association for Information Systems**, v. 8, p. 267-296, 2002.

JAIN, R., JAIN, P. K., BHADAURIA, S. S., "Computational approach to predict soil shear strength", **International Journal of Engineering Science and Technology**, 2010 Vol. 2(8), p. 3874-3885.

KAYADELEN, C., GÜNAYDIN, O., FENER, M., DEMIR, A., ÖZVAN, A., Modeling of the angle of shearing resistance of soils using soft computing systems. **Expert Systems with Applications** 36, 11814–11826, 2009.

KOVÁCS, Z. L. **Redes neurais artificiais: Fundamentos e aplicações**. 3.ed. São Paulo: Livraria da Física, 2002. 174p.

MARANGON, M. UNIVERSIDADE FEDERAL DE JUIZ DE FORA, Faculdade de Engenharia, Departamento de Transportes e Geotecnia.**Tópicos em Geotecnia e Obras de Terra**. 2004. Material didático ou instrucional. 25 p.

MAREN, A., HARSTON, C. AND PAP, R. Handbook of neural computing **Aplications, Academic Press Inc**., San Diego, California, 448p. 1990

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., 2010.

MITCHELL, J.K. **Fundamentals of soil behavior**. New York, John Wiley, 1976. 422p.

McCORMACK, D. E.; WILDING, L. P. Soil properties influencing strength of Cranfield and Geeburg soils.**Soil Science Society of American Journal**, Madison, v.43, n.1, p.167-173, 1979

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

MCKYES, E.; NYAMUGAFATA, P.; NYAMAPFENE, K.W. Characterization of cohesion, friction and sensitivity of two hardsetting soils from Zimbabwe**.Soil & TillageResearch**, Amsterdam, v.29, p.357-366, 1994.

MEDEIROS, J. S. **Bancos de dados geográficos e redes neurais artificiais: Tecnologia de apoio à gestão do território**. Tese (Doutorado em Geografia física) Universidade de São Paulo, São Paulo, 1999.

MEDEIROS, L. F. de. **Redes neurais em delphi**. Florianópolis: Visual Books Editora, 2003, 115p

MOLLAHASANI A, ALAVI A H, GANDOMI A H AND RASHED A Nonlinear neural-based modeling of soil cohesion intercept; **KSCE J. Civil. Eng**. 15(5) 831–840. (2011)

MULLINS, C.E.; MaCLEOD, D.A.; NORTHCOTE, K.H.; TISDALL, J.M. & YOUNG, I.M. Hardsetting soils: behavior, occurrence and management. **Adv. Soil Sci.**, 11:37-108, 1990

MURTHY, S. **Geotechnical Engineering. Principles and Practicesof Soil Mechanics, 2nd Edition**. Taylor & Francis, CRC Press, U.K. (2008).

NASTA, P. et al. Scaling soil water retention functions using particle-size distribution. **Journal of Hydrology**, v. 374, p. 223-234, 2009.

NEFESLIOGLU, H.A., GOKCEOGLU, C. Sonmez, H. An assessment on the use of logistic regression and artificial neural networks with different sampling strategies for the preparation of landslide susceptibility maps. **Engineering Geology** 97, 171–191, 2008.

NIEVOLA, J. C. Redes neurais artificiais. In: XII Escola regional de informática – ERI 2004, **Anais**, p.01-50, ISBN 858844287-6, Universidade Estadual do Centro-Oeste – UNICENTRO, Guarapuava, 2004

NUNES, P.G.A.**Uma nova técnica para seleção de variáveis em calibração multivariada aplicada às espectrometrias uv-vis e nir**. 2008. 121 f. Tese (Doutorado em Química) – Universidade Federal da Paraíba, João Pessoa, 2008

OHU, O.J.; RAGHAVAN, G.S.V.; MCKYES, E. & MEHUYS, G. Shear strength prediction of soils with varying added organic matter contents.**Trans. Am. Sci. Agric. Eng.**, 29:351-355. 1986.

OLIVEIRA, L.; RIVEIRO, M.; JACOMINE, P.; RODRIGUES, J.; MARQUES, F. Funções de pedotransferência para predição da umidade retida a potenciais específicos em solos do estado de Pernambuco.**Revista Brasileira de Ciência do Solo**, v.26, p.315-323, 2002.

ORTIGÃO, J.A.R. **Introdução à mecânica dos solos dos estados críticos.**2ª.ed. Rio de Janeiro, Livros Técnicos e Científicos, 1995. 378p.

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.;TIMLIN, AD.; VARALLYAY, G. Artificial neural networks to estimate soil water retention from easily measurable data. **Soil Science Society of America Journal**, v. 60: 727-733, 1996.

PACHEPSKY, Y; RAWLS, W. Accuracy and reliability of pedotransfer functions as affected by grouping soils. **Soil Science Society of America Journal**, v.63, p.1748-1757, 1999.

PACHEPSKY, Y.A., W.J. RAWLS AND H.S, Lin.Hydropedology and pedotransfer functions. **Geoderma**, 131: 308-316, 2006.

PINTO, C.S. **Curso básico de mecânica dos solos**. São Paulo, Oficina de Textos, 2000. 247p.

PINTO, C.S., **Curso básico de mecânica dos solos**. 2ª ed. São Paulo, Oficina de Textos, 2002. 355p.

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

REINKE, M. **Utilização de redes neurais artificiais aplicadas a mapeamento hidrogeológicos**, 2008. Dissertação (Mestrado em Geologia), Universidade do Vale do Rio dos Sinos. São Leopoldo, 2008.

REZENDE, S., O,. **Sistemas Inteligentes: fundamentos e aplicações**. Barueri, SP: Manole, 2003.

RIBEIRO, L. N. **Rede Neural com retropropagação: uma aplicação na classificação de imagens de satélite**. 2003. Dissertação. 131p. (Mestrado em Estatística), Departamento de Computação e Estatística, Universidade Federal do Mato Grosso do Sul - UFMS, Campo Grande, 2003

RIO GRANDE DO SUL. Decreto n. 6136, de 15 de julho de 1955. Aprova a regulamentação da Lei nº 2434, de 23 de setembro de 1954, modificada pela Lei nº 2642, de 20 de junho de 1955. **Assembléia Legislativa do Estado do Rio Grande do Sul**, Porto Alegre, RS, 15 jul. 1955. Disponível em: <http://www.al.rs.gov.br/>. Acesso em: 30 ago. 2011.

ROBAINA, A. D.; PEITER, M. X. **Hidráulica Agrícola**. UNIVERSIDADE FEDERAL DE SANTA MARIA, Curso de Agronomia, Departamento de Engenharia Rural, 2013. Material didático ou institucional. 101 p.

ROCHA, W.W.; DIAS JÚNIOR, M.S.; LIMA, J.M.; MIRANDA, E.E.V. & SILVA, A.R. Resistência ao cisalhamento e grau de intemperismo de cinco solos na região de Lavras (MG). **R. Bras. Ci. Solo**, 26:297-303, 2002.

ROHN, M. da C; MINE, M. R. M. Uma aplicação das redes neurais artificiais à previsão de chuvas de curtíssimo prazo. In: SIMPÓPIO BRASILEIRO DE RECURSOS HÍDRICOS, 15. Curitiba. **Anais**. Curitiba: ABRH, 2003.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Internal Representation by Error Propagation, in Parellel Distributed Processing. **MIT Press**, Cambridge, 1986.

SARLE, W. S. **Web: ftp://ftp.sas.com/pub/neural/FAQ.html.zip**, acesso em setembro/2004.

SCHAAP, M. G., AND W. BOUTEN. Modeling water retention curves of sandy soils using neural networks. **Water Resour. Res**., 32(10), 3033–3040, doi:10.1029/96WR02278. (1996)

SCHAAP, M. G., F. J. LEIJ, AND M. T. VAN GENUCHTEN. Neural network analysis for hierarchical prediction of soil water retention and saturated hydraulic conductivity. **Soil Sci. Soc. Am. J.**, 62(4), 847– 855. (1998)

SCHJONNING, P. Soil strength as influenced by texture, water content and soil management.**SoilTillage Res**., 12:277-283. 1991.

SECCO, D. **Estados de compactação de dois Latossolos sob plantio direto e suas implicações no comportamento mecânico e na produtividade de culturas.** 2003. 108f. Tese (Doutorado em Agronomia). Universidade Federal de Santa Maria.Santa Maria, 2003

SILVA, A.J.N. & CABEDA, M.S.V. Influência de diferentes sistemas de uso e manejo na coesão, resistência ao cisalhamento e óxidos de Fe, Si e Al em solo de tabuleiro costeiro de Alagoas. **R. Bras. Ci. Solo**, 29:447-457, 2005

SILVA, A. J. N.; CABEDA, M. S. V. Influência de diferentes sistemas de uso e manejo na coesão, resistência ao cisalhamento e óxidos de Fe, Si e Al em solos do tabuleiro costeiro de Alagoas. **Revista Brasileira de Ciência do Solo**, Viçosa, MG, v. 29, n. 3, p. 447-457, maio/jun. 2005.

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, I. N. da; ARRUDA, L. V. R.; AMARAL, W. C. do; BORDON, M. E. Projeto e análise de uma rede neural para resolver problemas de programação dinâmica. **Sba Controle & Automação**, v.12, n.1, p.1-10, 2001b.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas.** São Paulo: Artliber, 2010. 399 p.

SILVA, R. B., DAIS JUNIOR, M.S., SANTOS, R. L., FRANZ, C. A. B. Resistência ao cisalhamento de um latossolo sob diferentes condições de manejo. Revista Brasileira de Ciência do Solo, v.28, n.165, p.165-173, 2004.

SMITH, G. N.; SMITH, I. G. N. **Elements of soil mechanics**. 7th ed. Oxford: Blackwell Science Professional. 1998. 494 p.

SOARES, F. C. **Uso de diferentes metodologias na geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul**. 2013. 200 f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2013.

SOUZA, P., H., T., O. **Rede neural artificial para monitoramento em tempo real da concentração de potássio na vinhaça *in natura.*** 2010. 85 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Carlos, 2010.

STERNBERG, J.C.; STILLS, H.S.; SCHWENDEMAN, R.H. **Anais**. Chem., 32: 84, 1960.

TAFNER, M. A. **Estagiamento Automático do Sono Utilizando um Canal de EEG e uma Rede Neural Artificial com Alta Representação Cortical.** 1999. 75 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 1999.

TAMARI S, WÖSTEN JHM, RUIZ-SUÁREZ JC Testing an artificial neural network for predicting soil hydraulic conductivity. **Soil Science SocietyofAmericaJournal**. 60: 1732–1741. (1996)

TATIBANA, C. Y.; KAETSU, D. Y. Homepage de Redes Neurais. Disponível em: **<http://www.din.uem.br/ia/neurais/>**. Acesso em: 28 de maio 2012. 72. 2012

TIRYAKI, B. Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees.Engineering **Geology** 99, 51–60, 2008.

VALENÇA, M. J.S. Aplicando redes neurais: um guia completo. Olinda, PE: Livro Rápido, 2005. 284p.

VALENÇA, M. **Fundamentos das redes neurais**. Especial Ed. Recife: Livro Rápido, 2007.

VALENÇA, M. J.S. Fundamentos das redes neurais: Exemplos em JAVA. 2ed. Olinda, PE: Livro Rápido, 2010. 386p.

VARGAS, M. **Introdução à mecânica dos solos.** São Paulo, McGraw-Hill do Brasil, Ed. da Universidade de São Paulo, 1978. 509p.

VEREECKEN, H.; FEYEN, J.; MAES, J. Estimating the soil moisture retention characteristic from texture, bulk density and carbon content. **Soil Science**. v.148, p.389–403, 1989.

VEREECKEN, H., J. MAES, AND J. FEYEN. Estimating unsaturated hydraulic conductivity from easily measured soil properties. **Soil Sci**. 149:389–403. 1990.

WIDROW, B. AND HOFF, M. Adaptive switching circuits. In **Western Electronic Show and Convention,** *Volume 4*, pages 96-104. Institute of Radio Engineers (now IEEE), 1960.

WIILMOTTt, C. J. On the validation of model.Physical Geography, v.2, n.2, p.184-194, 1981.

ZELL, A. et al. SNNS – **Stuttgart Neural Network Simulator** v.4.2, user manual.Stuttgart: University of Stuttgart/University of Tübingen, 1998. 338p

ZURADA, J. M. Artificial Neural Systems. **West Publishing**. 1992