

RUBIA BORGES MENDES

**PREDIÇÃO DA RETENÇÃO DE ÁGUA EM SOLOS DE
SANTA CATARINA ATRAVÉS DE REDES NEURAIS
ARTIFICIAIS**

Dissertação apresentada ao
Centro de Ciências
Agroveterinárias da
Universidade do Estado de
Santa Catarina – Udesc para
obtenção do título de Mestre
em Ciência do Solo.

Orientador: Dr. Jackson
Adriano Albuquerque
Co-orientador: Dr. Jaime
Antônio Almeida
Co-orientador: Dr. André da
Costa

**LAGES, SC
2014**

Ficha catalográfica elaborada pela Bibliotecária
Renata Weingärtner Rosa – CRB 228/14^a Região
(Biblioteca Setorial do CAV/UDESC)

M538p

Mendes, Rubia Borges

Predição da retenção de água em solos de Santa Catarina através de Redes Neurais Artificiais / Rubia Borges Mendes. - Lages, 2014.

147 p.: il.: 21 cm

Orientador: Jackson Adriano Albuquerque

Coorientador: Jaime Antônio Almeida

Coorientador: André da Costa

Bibliografia: p. 93-120

Dissertação (mestrado) - Universidade do Estado de

Santa Catarina, Centro de Ciências

Agroveterinárias, Programa de Pós-Graduação em Ciência do Solo, Lages, 2014.

1. Funções de pedotransferência. 2. Tensão de água no solo. 3. Disponibilidade de água. 4. Modelos hidráulicos.

I. Mendes, Rubia Borges. II. Albuquerque, Jackson Adriano. III. Universidade do Estado de Santa Catarina. Programa de Pós-Graduação em Ciência do Solo. IV. Título

CDD: 631.7 - 20.ed.

RUBIA BORGES MENDES

PREDIÇÃO DA RETENÇÃO DE ÁGUA EM SOLOS DE SANTA CATARINA ATRAVÉS DE REDES NEURAIS ARTIFICIAIS

Dissertação apresentada ao Centro de Ciências Agroveterinárias da Universidade do Estado de Santa Catarina - Udesc para obtenção do título de Mestre em Ciência do Solo.

Banca Examinadora

Orientador/presidente

Prof. Dr. Jackson Adriano Albuquerque
(UDESC/Lages – SC)

Co-orientador/membro externo

Dr. André da Costa
(Epagri)

Membro interno

Prof. Dra. Letícia Sequinatto
(UDESC/Lages – SC)

Membro externo

Dr. Milton da Veiga
(Epagri)

Lages, SC, 25 de julho de 2014.

AGRADECIMENTOS

Acima de tudo a Deus, meu Senhor e Salvador, pela vida e salvação em Jesus.

Ao meu companheiro e amigo, meu marido, pelo apoio e compreensão.

Aos meus pais pela educação, ensino nos caminhos de Deus, conselhos e apoio.

Aos meus irmãos pelo incentivo e orações, e pelas conversas ‘de corredor’.

Ao meu orientador, pelo apoio e confiança, pela compreensão e dedicação, esclarecendo as dúvidas e dando tantas outras.

Aos amigos que são como irmãos para mim.

A todos os professores e colegas do curso de pós-graduação que fizeram com que eu continuasse e chegasse até aqui.

Ao programa de Pós-Graduação em Ciência do Solo, e à Capes pela bolsa concedida.

À UDESC pelo ensino gratuito e de qualidade.

À Florestal Gateados por disponibilizar a área experimental e aos seus funcionários que colaboraram na abertura das trincheiras.

Deus nos abençoe sempre.

RESUMO

MENDES, Rubia Borges. **Predição da retenção de água em solos de Santa Catarina através de Redes Neurais Artificiais.** 147 p. (Dissertação de Mestrado em Ciência do Solo) – Universidade do Estado de Santa Catarina. Programa de Pós-Graduação em Ciências Agrárias, Lages, SC. 2014.

Várias técnicas vêm sendo utilizadas para obtenção da curva de retenção de água no solo. Como métodos diretos demandam tempo e são de alto custo, tem sido estudadas funções de pedotransferência (FPTs), as quais utilizam preditores de fácil obtenção e baixo custo para obter os parâmetros. FPTs geradas a partir de regressões múltiplas têm mostrado resultados confiáveis, mas exigem grande conhecimento estatístico para sua determinação. Uma nova abordagem para obtenção de FPTs é o uso de redes neurais artificiais (RNAs), que não exigem conhecimento prévio estatístico e podem ser obtidas utilizando-se um banco de dados mínimos. As RNAs vêm sendo utilizadas em diversas áreas do conhecimento, e têm se mostrado precisas e confiáveis. Este trabalho teve por objetivo comparar a eficiência de RNAs e regressões múltiplas na geração de FPTs para estimar a retenção e a disponibilidade de água em solos do estado de Santa Catarina. As FPTs foram geradas a partir de 940 horizontes de solos representativos de Santa Catarina, tendo como dados de entrada a granulometria (sete classes de tamanhos de partículas), o teor de matéria orgânica, a densidade do solo e de partículas e, como dados de saída, a retenção de água nas tensões de 0 até 1.500 kPa. As RNAs foram geradas utilizando o software WEKA, tendo como arquitetura a rede Multilayer Perceptron, com seis neurônios na camada escondida, utilizando-se a função de retropropagação

do erro (Backpropagation) e validação cruzada para estratificar a amostra. As FPTs obtidas a partir de RNAs são mais eficientes que as regressões múltiplas. As FPTs pontuais, que incluem dados de granulometria (cinco divisões de areia), matéria orgânica do solo, densidade do solo, densidade de partículas, porosidade total e suas interações estimam melhor a retenção e a disponibilidade de água nestes solos. A partir destes resultados, é possível desenvolver um programa que utiliza as FPTs geradas para estimar a curva de retenção de água, sendo, portanto uma ferramenta extremamente útil para estudos que envolvam a retenção e a disponibilidade de água no solo.

Palavras-chave: funções de pedotransferência; tensão de água no solo; disponibilidade de água; modelos hidráulicos.

ABSTRACT

MENDES, Rubia Borges. **Using Artificial Neural Networks to predict water retention in soils of Santa Catarina – Brazil.** 147 p. (Master Dissertation in Soil Science) – University of the State of Santa Catarina. Programa de Pós-Graduação em Ciências Agrárias, Lages, SC. 2014.

Several techniques have been used to obtain soil water retention curve. Direct methods are time consuming and costly. Mathematical techniques have been used to replace direct methods through pedotransfer functions (PTFs), using predictors easily obtained and inexpensive to obtain parameters that expend more time and resources. PTFs generated from multiple regressions have shown reliable results but requires great knowledge of statistics. A new approach to obtaining PTFs, artificial neural networks (ANN) that does not require prior knowledge of statistical and database minimum, have been used in various areas of knowledge, and have been shown to be accurate and reliable. The study aimed to compare the efficiency of ANNs and multiple regressions to generate PTFs for estimating the retention and availability of water in soils of Santa Catarina state, located in a subtropical zone (region) of Brazil. The PTFs were generated for 940 horizons of representative soils of St. Catarina having as input data the particle size distribution (seven classes), the organic matter content, bulk density, particle density and output data water retention between from zero to 1500 kPa tension. The ANNs were generated using the software WEKA, with six neurons in the hidden layer using the error backpropagation algorithm (Multilayer Perceptron) and the cross-validation to stratify sample. Results showed that PTFs obtained from ANNs are more efficient than multiple regression. The PTFs that include

specific texture data (five classes of sand), soil organic matter, soil bulk density, particle density, total porosity and their interactions better estimate the retention and availability of water in these soils. From these results, it is possible to develop a program that uses these PTFs generated to provide these values of SWRC, and is therefore an extremely useful tool for studies about soil water retention and availability.

Key-words: pedofunctions; soil water tension; water availability; hydraulic models.

LISTA DE TABELAS

Quadro 1 - Exemplos de funções de pedotransferência desenvolvidas para solos brasileiros.	42
Quadro 2 - Valores mínimo e máximo, média e desvio padrão dos atributos dos 57 perfis de solo estudados	66
Quadro 3 - Coeficientes de correlação de Pearson, entre os atributos do solo e a retenção de água, em diferentes pontos da CRA e o CAD para os 57 perfis de solos estudados	70
Quadro 4 - Valores mínimo e máximo, média e desvio padrão dos 44 solos utilizados na comparação das RNAs com RMs .	73
Quadro 5 - Coeficiente de determinação (R^2) e raiz do erro quadrático médio (REQM) das funções de pedotransferência (FPTs) obtidas por regressão múltipla (RM) do estudo de Costa (2012) e por redes neurais artificiais (RNAs) de 44 solos do Estado de SC, quando calculados para os modelos 1, 3, 5 e 7.	76

LISTA DE FIGURAS

Figura 1 – Curva de retenção de água no solo, mostrando suas características gerais. CC10 é a umidade na capacidade campo (10 kPa) e PMP é o ponto de murcha permanente (1500 kPa).	34
Figura 2 – Nível de informação e qualidade da precisão da FPT gerada.	40
Figura 3 – Neurônio artificial.	45
Figura 4 – Típica rede MLP com uma cama intermediária.	46
Figura 5 – Fluxo de processamento do algoritmo <i>backpropagation</i> .	48
Figura 6 – Superfície de erros.	48
Figura 7 – Variações e consequências da taxa de aprendizagem do <i>Backpropagation</i> .	49
Figura 8 – Influência do termo <i>momentum</i> na aproximação ao mínimo global.	50
Figura 9 – Distribuição geográfica dos 57 perfis de solo no Estado de Santa Catarina utilizados no estudo. Em vermelho corresponde aos 44 perfis do banco de dados de Costa (2012) e em amarelo os 13 perfis coletados neste estudo.	54
Figura 10 – Funções de ativações da RNA – MLP.	61
Figura 11 – Tela do <i>software WEKA</i> : carregamento dos dados – pré-processo.	62
Figura 12 – Vista em diferentes momentos da tela do Weka para escolha da função MultiLayerPerceptron, validação cruzada, atributo a ser estimado e ajustes dos parâmetros da rede neural (estrutura da rede e normalização dos dados).	63
Figura 13 – Classes texturais dos horizontes A+B (a), horizonte A (b) e para horizonte B (c) do BD2.	65

Figura 14 – Curvas de retenção de água médias dos horizontes superficiais e subsuperficiais das seis classes de solos avaliados. Nitossolo (15 perfis), Cambissolo (12 perfis), Neossolo (11 perfis), Latossolo (7 perfis), Argissolo (9) e Chernossolo (3).....	68
Figura 15 – Estrutura da RNA para estimar AD10 a partir do Modelo 7 (11 atributos de entrada), mostrando a camada de entrada, a camada escondida com os seis neurônios e a camada de saída.....	74
Figura 16 – Gráficos de dispersão da umidade medida em laboratório <i>versus</i> a umidade estimada pelos modelos RNA1 e RNA2 para a capacidade de campo a 10 kPa (CC10) e 33 kPa (CC33), ponto de murcha permanente a 1.500 kPa (PMP) e água disponível a 10 e 33 kPa (AD10 e AD33) de 57 solos do estado de SC.....	84

LISTA DE ABREVIATURAS

AD10	Água Disponível entre 10 kPa e 1500 kPa
AD33	Água Disponível entre 33 kPa e 1500 kPa
BD	Banco de Dados
CC10	Capacidade de Campo a 10 kPa
CC33	Capacidade de Campo a 33 kPa
CRA	Curva de Retenção de Água
Dp	Densidade de Partículas
Ds	Densidade do Solo
EvG	Equação de van GENUCHTEN
FPT	Função de Pedotransferência
K	Condutividade Hidráulica
MLP	Perceptron de Múltiplas Camadas (<i>MultiLayerPerceptron</i>)
MO	Matéria Orgânica
PMP	Ponto de Murcha Permanente
PT	Porosidade Total
RMs	Ressessões Múltiplas
RNAs	Redes Neurais Artificiais
UE	Umidade Equivalente

SUMÁRIO

INTRODUÇÃO	25
1 OBJETIVOS.....	28
2 HIPÓTESES	29
3 REVISÃO BIBLIOGRÁFICA.....	30
3.1 A água e o desenvolvimento humano.....	30
3.2 Curva de retenção de água no solo - importância agrícola	32
3.3 Regressões múltiplas e redes neurais artificiais na geração de funções de pedotransferência para estimar a retenção de água no solo	39
4 MATERIAL E MÉTODOS.....	53
5 RESULTADOS E DISCUSSÃO	65
5.1 Relação dos atributos dos solos com a retenção de água no solo e disponibilidade para as plantas.....	65
5.2 Redes Neurais Artificiais (RNAs) comparadas com Regressões Múltiplas (RMs) na geração de FPTs	72
6 CONCLUSÕES	91
7 CONSIDERAÇÕES FINAIS	92
REFERÊNCIAS BIBLIOGRÁFICAS	93
APÊNDICE	121
Apêndice A – Descrição morfológica dos 13 perfis de solo estudados.....	121
Apêndice B – Pesos das RNAs gerados pelo <i>software</i> WEKA	138

INTRODUÇÃO

Muito se tem falado sobre a importância da água, seja para consumo humano, animal ou na agricultura. O conhecimento da armazenagem de água do solo na zona radicular durante um ciclo de cultivo agrícola é essencial ao manejo dos recursos da água e do solo.

Desde que a irrigação tornou-se uma técnica útil para aumentar a produção, o uso de água aumentou. Assim, a partir do ponto de vista da gestão, tem-se observado que o conhecimento dos processos de fluxo e movimento da água no solo é necessário para controlar o conteúdo de água em cada uma das camadas de solo explorado pelas raízes. Por essa razão, o desenvolvimento de modelos para estimar a retenção de água no solo é imprescindível em estudos que envolvem interações solo-planta-atmosfera, irrigação e drenagem, entre outros.

É sabido que as propriedades de retenção de água do solo são controladas principalmente pela granulometria do solo, pelo teor de matéria orgânica, pela estrutura do solo e pela mineralogia que, por sua vez, variam espacialmente em resposta aos fatores de formação do solo.

A curva de retenção de água no solo (CRA) é a relação entre o conteúdo volumétrico de água e o potencial matricial do solo. A obtenção da CRA em amostras indeformadas de solo fornece dados sobre a distribuição do tamanho de poros, umidade na capacidade de campo e no ponto de murcha permanente, e assim, a disponibilidade de água no solo, sendo importante para manejo de irrigação de culturas e estudos hidrológicos.

Entretanto, é uma determinação demorada e, por isso, formas alternativas para sua estimativa, chamadas funções de pedotransferência (FPTs), têm sido continuamente

desenvolvidas para descrever a relação entre a retenção de água com os atributos do solo, principalmente a granulometria e o teor de matéria orgânica do solo (BOUMA e van LANEN, 1987). A utilização das técnicas de regressão para estimar estas FPTs, quer lineares ou não-lineares, necessitam que, *a priori*, os modelos sejam bem definidos, o que em geral é difícil, uma vez que estes modelos não são conhecidos.

Muitos estudos relacionados à modelagem de vários atributos do solo usando diferentes tipos de FPTs têm sido ainda realizados. Apesar do progresso alcançado no desenvolvimento de FPTs em geral, no Brasil ainda é pouco frequente o uso de Redes Neurais Artificiais (RNAs) para obtenção de FPTs da CRA do solo. Uma rede neural é uma estrutura adaptável de transferência de dados não-linear que pode aprender as relações entre os dados de entrada e saída, e ao mesmo tempo, ser insensível ao ruído¹ de medição (HECHT-NIELSEN, 1990).

Tamari et al. (1996) sugeriram que uma entrada com banco de dados maior tornaria as RNAs ainda mais eficientes que as RMAs. Além disso, um BD mais amplo, com mais classes de solos, forneceria valores mais precisos dos ajustes dos pesos de cada atributo. Apesar de dificuldades encontradas no processo de gerar FPTs a partir de RNAs, os autores observaram que as RNAs são úteis na predição de parâmetros hidráulicos, mesmo quando o BD de treinamento é pequeno.

No estudo de Schaap e Leij (1998) os autores concluíram que a precisão das predições aumenta se o BD é maior e que as RNAs podem ser vistas como funções universais de aproximações. A flexibilidade delas permite trabalhar para obtenção de um melhor ajuste, o que é limitado ao utilizar outras ferramentas na obtenção das FPTs. Com um

¹ Ruído é um termo geral para modificações (em geral desconhecidas) que o sinal pode sofrer durante a transmissão ou processamento na rede (TUZLUKOV, 2010).

BD de 204 amostras de solos arenosos Schaap e Bouting (1996) mostraram que as predições obtidas através de RNAs apresentaram erros muito menores que aquelas obtidas por aproximações de regressões lineares.

Dentro desse contexto, este trabalho procurou aumentar o BD e incluir outros atributos do solo como dados de entrada das RNAs. Isso porque se a quantidade de dados é pequena a rede não conseguirá criar um modelo suficientemente representativo para se ter um bom desempenho quando aplicado em situações reais após o seu desenvolvimento. Além disso, os dados devem englobar todos os aspectos do problema em questão, a fim de que o modelo criado seja genérico.

Neste trabalho, o desenvolvimento do tema tem a seguinte estrutura: Referencial teórico sobre a água como recurso natural imprescindível ao desenvolvimento humano; a CRA como atributo imprescindível no estudo da retenção e disponibilidade de água nos solos e os métodos para obter a CRA; hipóteses e objetivos do trabalho; e, finalmente, material e métodos como sendo itens gerais do trabalho. Em resultados e discussão, o trabalho foi dividido em tópicos, para facilitar a leitura e entendimento da pesquisa realizada, já que o mesmo seguiu a ordem aqui disposta, de modo a alcançar os objetivos propostos: CRA e atributos físicos do solo; Redes Neurais Artificiais (RNAs) em comparação com Regressões Múltiplas (RMs) na geração de FPTs; e uso ótimo de RNAs para gerar FPTs. A conclusão aborda os principais resultados encontrados, compilando cada tópico discutido.

1 OBJETIVOS

- I. Avaliar a relação entre a retenção e disponibilidade de água com os atributos de solos de SC;
- II. Avaliar a eficiência de funções de pedotransferência que estimam a curva de retenção de água no solo, geradas por métodos de Regressão Múltipla e por Redes Neurais Artificiais;
- III. Gerar funções de pedotransferência para estimar a retenção de água em solos de SC e comparar o efeito do tamanho do banco de dados utilizado por meio de Redes Neurais Artificiais.

2 HIPÓTESES

Redes neurais artificiais são mais eficientes que regressões múltiplas na geração de funções de pedotransferência, pois são capazes de interpolar e extrapolar informações dos dados;

Funções de pedotransferência geradas a partir de redes neurais artificiais podem estimar pontos da curva de retenção de água no solo de forma generalizada, agrupando diferentes classes de solos e granulometrias, sendo tanto melhores quanto maior e mais completo for o banco de dados.

3 REVISÃO BIBLIOGRÁFICA

3.1 A ÁGUA E O DESENVOLVIMENTO HUMANO

“Todos os ribeiros vão para o mar, e contudo o mar não se enche; para o lugar para onde os ribeiros vão, para aí tornam eles a ir”.

Bíblia Sagrada, Eclesiastes 1.7

Qual das substâncias encontradas na Terra tem maior relação com a questão do desenvolvimento e sobrevivência do homem do que a água? O homem desde os primórdios do seu desenvolvimento, aglomerado em comunidades de milhares de pessoas, enfrenta desafios de sobrevivência, e a história mostra que a busca pela água potável é o ponto mais importante desse desafio.

Fatos da história, datados ao longo de mais de 6.000 anos, evidenciam que o uso e manejo da água foram constantes para o desenvolvimento humano (SILVA, 2000). Entre eles destacam-se: instruções sobre irrigação de lavouras em terraços pelos sumérios; obras de engenharia de irrigação no antigo Egito e Mesopotâmia; galerias de esgoto na Índia; abastecimento de água e drenagem no vale do Indo; e o uso de tubos de cobre para transporte e clarificação da água com uso de sulfato de alumínio no Egito.

Por quase dez séculos, durante a Idade Média, a água representou o pulmão da vida econômica. Com o decorrer dos tempos, a água foi se tornando vital para o desenvolvimento econômico, fato comprovado pela construção de moinhos para geração de força motriz, impulsionando o desenvolvimento industrial no final do século XII.

A prosperidade econômica de inúmeros povos esteve muitas vezes entrelaçada com a história da agricultura e também da irrigação, pois muitas das antigas civilizações se originaram em regiões áridas, onde a produção só era possível com o concurso desta. Estudos comprovam que em 4.500 a.C.

essa prática era utilizada no continente asiático pelos Assírios, Caldeus e Babilônicos. Da mesma forma, as grandes aglomerações que se fixaram nas margens dos rios Huang Ho e Iang-Tse-Kiang na China (ano 2.000 a.C.), do Nilo no Egito, do Tigre e do Eufrates na Mesopotâmia e do Ganges na Índia (ano 1.000 a.C.), nasceram e cresceram graças à utilização eficiente de seus recursos hídricos (SILVA, 2000).

Com o contínuo crescimento demográfico, consequentemente havendo aumento da demanda por alimentos, a humanidade se viu compelida a praticar a irrigação, tanto para suplementar as chuvas nas regiões úmidas, como para tornar produtivas as zonas áridas e semi-áridas.

Embora a irrigação seja uma técnica agrícola muito antiga, seu uso no Brasil tornou-se frequente somente nos últimos trinta anos. Contudo, foram encontrados registros que em 1589 os jesuítas já praticavam esta técnica na antiga Fazenda Santa Cruz, no estado do Rio de Janeiro. A difusão da irrigação se processou, inicialmente em maior escala, nas culturas de arroz no Rio Grande do Sul e em alguns vales da região central do país. Já nos cafezais do estado de São Paulo, o emprego da irrigação por aspersão iniciou-se por volta da década de 1950 e somente entre as décadas de 1960 e 1970 que esta se iniciou em regiões do nordeste brasileiro (SILVA, 2000).

Como as maiores áreas agricultáveis do Brasil se encontram em regiões úmidas, a irrigação tem um caráter suplementar, principalmente em regiões mais secas e com culturas perenes.

Além disso, resíduos de fertilizantes e de agrotóxicos, quando aplicados sobre o solo, podem atingir os corpos d'água diretamente, através da água da chuva e da irrigação, ou indiretamente através da percolação no solo, chegando aos lençóis freáticos. Por essa razão, o conhecimento da retenção de água no solo é imprescindível em estudos que envolvem

interações solo-planta-atmosfera, irrigação e drenagem, entre outros (VEIGA, 2007).

3.2 CURVA DE RETENÇÃO DE ÁGUA NO SOLO - IMPORTÂNCIA AGRÍCOLA

“Para uma árvore há esperança; se for cortada, brota de novo e torna a viver. Mesmo que as suas raízes envelheçam, e o seu toco morra na terra, basta um pouco de água, e ela brota, soltando galhos como uma planta nova.”

Bíblia Sagrada, Jó 14:7-9

O solo é um sistema complexo, constituído das fases sólida, líquida e gasosa. A fase líquida constitui-se essencialmente de água, a qual dependendo da umidade ocupa parte ou quase todo o espaço vazio entre as partículas sólidas (REICHARDT, 1985).

A retenção de água no solo depende de dois fenômenos: adsorção e capilaridade. A adsorção corresponde à atração entre a parte sólida do solo e os filmes de água, logo, é dependente da granulometria e da superfície específica do solo (REICHARDT, 1985). Já a capilaridade está ligada à afinidade das partículas de solo com a água e necessita da formação de um menisco para atuar, por isto depende da distribuição do tamanho dos poros. A energia de retenção da água no solo é importante, pois solos de diferentes classes texturais podem ter semelhantes quantidades de água, porém com distintas energias de retenção.

Em 1907, o físico Edgar Buckingham trabalhando com movimento da água no solo, reconheceu a importância do potencial de forças geradas pela interação solo-água. Ele chamou essa força de potencial capilar, que hoje é conhecida como potencial matricial. Ele combinou a teoria da capilaridade com a energia potencial da teoria da física do solo, e foi o primeiro a mostrar a dependência da condutividade

hidráulica com o potencial capilar. De seu experimento com seis amostras de solo foi criada a primeira curva de retenção de água (CRA).

A CRA é uma propriedade física que descreve a relação entre o teor de água e a energia com a qual ela está retida, que varia no tempo e no espaço, cujas informações possibilitam a obtenção de outros atributos de solo como, por exemplo, a condutividade hidráulica não saturada (SCOTT, 2000). Esta relação parte do princípio de que a água ocupa os espaços porosos do solo sob determinada tensão, que é dependente da composição granulométrica e do arranjo estrutural do solo (BRADY e BUCKMAN, 1989).

Em solos saturados, ou próximo da saturação, a água é extraída do solo mesmo em baixas tensões. Entretanto, quando o solo está mais seco, a extração da água do solo necessita de tensões bem maiores. A CRA mostra todas as graduações entre estes extremos, indicando que com o aumento ou diminuição da umidade a tensão se modifica.

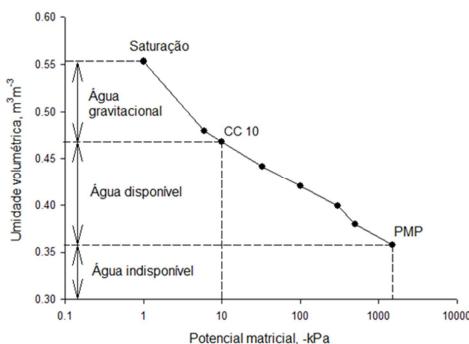
A CRA é necessária para predizer o armazenamento de água no solo e a disponibilidade dela para as plantas, além de ser ferramenta útil no estudo do movimento de água em solos não saturados. Ela permite calcular a quantidade de água que um determinado solo pode reter dentro de certos limites de tensão.

As características gerais da CRA podem ser vistas na figura 1, em que o conteúdo de água volumétrico, θ (U_v , m^3/m^3) é plotado *versus* a tensão, h (kPa). Em tensões próximas de zero, o solo está próximo à saturação e a água é retida por forças capilares. Quando θ diminui, a ligação da água com o solo se torna mais forte. Em tensões próximas ao ponto de murcha permanente (PMP), a água fica fortemente retida nos poros menores, nos pontos de contato entre os sólidos e os filmes de água retidos por forças de adsorção.

Um atributo importante para o manejo da água no solo é a capacidade de campo (CC). Veihmeyer e Hendrickson (1949)

definiram a capacidade de campo (CC) como “a quantidade de água retida pelo solo após a drenagem ter ocorrido ou cessado, quando a velocidade do movimento descendente praticamente cessa, o que usualmente ocorre dois ou três dias após a chuva ou irrigação, em solos permeáveis de estrutura e textura uniformes”. A CC é um estado hídrico específico para cada tipo de solo e observado durante o processo de redistribuição da água, quando a água gravitacional já foi drenada. Para a escala do perfil de solo explorado pelas culturas agrícolas, existe uma dependência muito forte entre as características físicas, físico-hídricas e químicas, ligadas principalmente às distribuições de tamanho de partículas e de poros e à quantidade de matéria orgânica dos horizontes pedológicos. Numa escala mais ampla, as profundidades do solo e do lençol freático são fatores influentes na determinação da capacidade de campo (MEYER e GEE, 1999).

Figura 1 – Curva de retenção de água no solo, mostrando suas características gerais. CC10 é a umidade na capacidade campo (10 kPa) e PMP é o ponto de murcha permanente (1500 kPa).



Fonte: produção do próprio autor.

A determinação adequada da CC, bem como de outros pontos específicos da curva de retenção de água é fundamental para o correto manejo das culturas agrícolas, principalmente em áreas irrigadas, e para a otimização de manejos de solo e da

irrigação visando maximizar a eficiência de uso da água pelas plantas. Atrelado a esse aspecto tem-se, ainda, que a utilização de um valor alto de CC, estimado para outros solos, pode provocar drenagem interna excessiva e causar lixiviação de fertilizantes e agroquímicos, causando contaminação de águas subterrâneas e dos lençóis freáticos, empobrecimento do solo pela lixiviação de nutrientes e riscos à saúde humana (BRITO et al., 2011).

3.2.1 Fatores que influenciam a retenção de água no solo

A capacidade de retenção de água de um solo é função de suas propriedades físicas (HILLEL, 1980; COSTA, 2001, REICHERT et al., 2009). No entanto, a disponibilidade de água às culturas é variável de acordo com a espécie vegetal, manejo dado ao solo e com o tipo de solo (SILVA, 2003).

3.2.1.1 TEXTURA – Nem todos os solos têm a mesma capacidade de armazenar água. Entre as propriedades do solo, a granulometria é a que mais influencia na retenção de água no solo. Ela determina a área de contato entre a água e as partículas sólidas, ou seja, o volume de água retida depende do somatório da água retida no filme de água que recobre as partículas variando de acordo com sua superfície específica (REICHARDT, 1985). Assim, quanto maior o conteúdo de argila, por possuir maior superfície específica, o solo tende a reter maior quantidade de água e, consequentemente, mais suave será a inclinação da curva, devido também a uma distribuição mais uniforme do tamanho de poros. Já em solos arenosos, onde normalmente os poros são maiores, em tensões menores a água é esvaziada dos mesmos mais rapidamente, restando pouca água retida na superfície das partículas e em capilares em tensões maiores, o que explica a CRA possuir

uma inclinação mais acentuada nesta classe de solos (SILVA et al., 2005).

3.2.1.2 MINERALOGIA – Além da granulometria, outra propriedade dos solos que determina a magnitude da retenção da água é sua mineralogia. Existem argilominerais, como a montmorilonita, vermiculita e a ilita que, devido às suas características cristalográficas, têm propriedades que aumentam a retenção de água, pois possuem maior área superficial específica, cargas elétricas, bem como adsorvem água nas entrecamadas (BRADY, 1984).

3.2.1.3 ESTRUTURA – O termo estrutura é usado para descrever o solo no que se refere ao arranjo, orientação, organização e à adesão das partículas menores na formação de aglomerados maiores denominados de agregados, bem como a geometria dos espaços porosos (REICHARDT e TIMM, 2012). Como possui poros de formas e dimensões variadas, cada tipo de solo possui um comportamento peculiar. Um solo bem agregado (ou estruturado) apresenta boa quantidade de poros de tamanhos relativamente grandes, qualidade que facilita a penetração das raízes, circulação de ar (aeração) e a infiltração de água. A estrutura determina o arranjo das partículas que, por sua vez, determinará a distribuição de tamanho/diâmetro de poros. Como a água ocupa parte do espaço poroso do solo, estando retida sob tensão, a estrutura afeta a retenção da água pelo solo, sendo fator dependente da proporção e arranjo dos componentes granulométricos do solo (REICHARDT, 1985). Se há compactação do solo, a porosidade total e o volume dos poros entre agregados decresce. Com a compactação, há um decréscimo do volume dos poros grandes e aumento do volume dos poros intermediários. O volume dos poros pequenos permanecem praticamente inalterados.

3.2.1.4 MATÉRIA ORGÂNICA – É sabido que a matéria orgânica (MO) e outras substâncias atuam como agentes cimentantes entre as partículas, formando e estabilizando os agregados do solo. Evidências sugerem que fatores diretos e indiretos contribuem para os efeitos favoráveis da MO sobre a disponibilidade de água no solo. A MO afeta indiretamente a quantidade de água disponível para as plantas, através de sua influência sobre a estrutura e espaço poroso total do solo. Ela ajuda a estabilizar a estrutura, aumentando o volume total e o tamanho de poros do solo. Isto resulta em um aumento da infiltração e capacidade de retenção de água, com aumento simultâneo do volume de água retido em altas tensões, como no ponto de murcha permanente. Os efeitos diretos da MO são devido a sua alta capacidade de retenção de água da matéria orgânica, que é muito maior do que a de um igual volume de material mineral (BRADY e BUCKMAN, 1989). A MO é o principal atributo do solo que governa a disponibilidade de água para as plantas, pois tem maior efeito sobre o aumento da capacidade de campo em comparação ao observado para o ponto de murcha permanente (HUDSON, 1994). O autor avaliou o efeito da MO sobre a disponibilidade de água e encontrou uma relação positiva entre esses dois atributos atribuindo esse aumento ao maior efeito da MO sobre o aumento da capacidade de campo, em comparação ao observado no ponto de murcha permanente.

3.2.1.5 MANEJO DO SOLO – O sistema de manejo adotado pode atuar de forma decisiva na distribuição hídrica no perfil e nas interações solo-planta-atmosfera, ao longo do tempo (MARTONARO et al., 2009). Os principais atributos alterados pelo preparo são a porosidade e a densidade, os quais têm influencia direta na retenção de água (VIEIRA e KLEIN, 2007). Além do efeito direto da mobilização na retenção de água, o sistema de manejo modifica os teores de MO e, assim, a área superficial específica do solo e a retenção de água.

DALMAGO (2004) observou que as maiores diferenças entre os sistemas de manejo ocorrem principalmente em tensões mais baixas.

Além dos atributos do solo, fatores externos como precipitação pluvial, radiação solar, temperatura, evapotranspiração da cultura, índice de área foliar, profundidade das raízes e densidade de plantas também influenciam no desenvolvimento das plantas e na dinâmica da água no solo (MARTORANO et al., 2009).

As propriedades hidráulicas do solo são importantes pois descrevem a relação solo-planta, permitindo uma estimativa da disponibilidade de água para as plantas. Desde que a primeira CRA foi determinada por Buckingham (1907), cientistas do solo procuraram estabelecer modelos matemáticos para descrever a relação potencial de água *versus* conteúdo de água, aprimorando as CRAs ao longo dos anos (GARDNER, 1958; BROOKS e COREY, 1964; FARREL e LARSON, 1972; WILLIAMS et al., 1983; MCKEE e BUMB, 1984; van GENUCHTEN, 1980; MCKEE e BUMB, 1987; FREDLUNG e XING, 1994).

No Brasil, Medina e Grohmann (1962) foram os primeiros a apresentarem CRAs de alguns solos do estado de São Paulo. Também Marcos (1968) apresentou CRAs para amostras de diferentes estruturas e estado de agregação, enquanto Scardua (1972) apresentou CRAs para diferentes camadas de dois perfis de solo do município de Piracicaba, SP.

Atualmente a determinação de CRAs é uma rotina em alguns laboratórios, entretanto, até o momento não há nenhuma teoria satisfatória para estimar esta (REICHARDT e TIMM, 2012). Deste modo, existe uma lacuna a ser preenchida nesse campo da física do solo.

3.3 REGRESSÕES MÚLTIPLAS E REDES NEURAIS ARTIFICIAIS NA GERAÇÃO DE FUNÇÕES DE PEDOTRANSFERÊNCIA PARA ESTIMAR A RETENÇÃO DE ÁGUA NO SOLO

“Sabes tu as ordenanças dos céus, podes estabelecer a sua influência sobre a terra?”

Bíblia Sagrada, Jó 38.33

A quantificação da retenção de água no solo é largamente utilizada em estudos de disponibilidade de água para as plantas, projetos de irrigação e drenagem, infiltração, condutividade hidráulica, estresse hídrico e movimento de solutos. A CRA e a condutividade hidráulica (K) estima respectivamente a armazenagem e o fluxo de água nos solos tornando-os parâmetros cruciais em modelos de transporte de água e solutos. Assim, o desenvolvimento de modelos descritivos de transporte de água e solutos no solo tem se tornado de grande importância prática na atualidade, objetivando melhor manejo ambiental e otimização de práticas agrícolas (ANGELOTTI NETO, 2007).

Entretanto, os métodos para elaboração de curvas de retenção de água no solo demandam muito tempo (SCHUH et al., 1988; WILLIAMS et al., 1992), alguns necessitam de equipamentos onerosos (WÖSTEN e van GENUCHTEN, 1988) e raramente disponíveis (SCHUH et al., 1988; van den BERG et al., 1997). Outros ainda, fazem uso de amostras deformadas, o que não reflete a estrutura do solo avaliado (OLIVEIRA e SARVASI, 1997).

Com vista a contornar estes problemas, pesquisadores têm utilizado ferramentas matemáticas para estimar a CRA, fornecendo resultados satisfatórios com base em dados experimentais menos dispendiosos. Estas ferramentas são as funções de pedotransferência (FPTs) (BOUMA, 1989), as

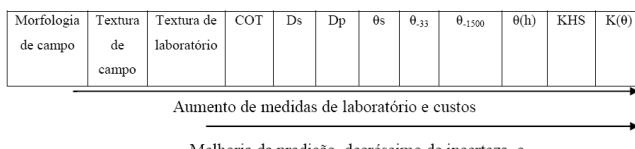
quais podem ser obtidas através de diferentes procedimentos matemáticos e estatísticos.

As FPTs podem ser categorizadas FPTs de classe e FPTs contínuas. As FPTs de classe predizem certas propriedades do solo baseadas na classe a qual o solo pertence, como por exemplo, sua classe textural. As FPTs contínuas pontuais ou paramétricas predizem certas propriedades do solo como uma função contínua das variáveis medidas. Além das metodologias acima descritas, as FPTs também podem ser determinadas a partir de Redes Neurais Artificiais (RNAs), que se constituem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas (PACHEPSKY et al., 1996; MINASNY e McBRATNEY, 2002; PACHEPSKY e RAWLS, 2004).

Segundo van den Berg et al. (1997) algumas equações podem fornecer um ajuste global bom para curvas de retenção, contudo, podem ocasionar baixa precisão de estimativas de conteúdos de água em potenciais particulares no solo.

Com o aumento de medidas de laboratório a predição se torna mais precisa, mas o custo de obtenção das informações adicionais se torna mais elevado. Existe, então, um balanço entre o custo e a qualidade da predição. As aproximações hierárquicas, onde as FPTs são baseadas no nível de informações disponíveis, foram introduzidas por Schaap et al. (1998) para permitir maior flexibilidade no uso de dados disponíveis (Figura 2).

Figura 2 – Nível de informação e qualidade da precisão da FPT gerada.



Fonte: Schaap, Leij e van Genuchten (1998) apud Costa (2012).

Uma grande quantidade de diferentes equações está disponível para a parametrização de funções hidráulicas (VEERECKEN, 1992). O conteúdo de água, θ , como função da tensão, h , é descrito pela seguinte equação (van GENUCHTEN, 1980):

$$\theta(h) = \theta_r + \frac{\theta_s - \theta_r}{(1 + |\alpha h|^n)^{1-1/n}} \quad (1)$$

Nesta equação, os índices θ_r e θ_s referem-se respectivamente aos conteúdos de água residual e de saturação e α e n são parâmetros que determinam a forma da curva. O θ_r se refere ao conteúdo de água quando a gradiente $d\theta/dh$ aproxima-se de zero ($h \rightarrow -\infty$). Na prática, θ_r é o conteúdo de água em valores altos de tensão da água no solo como observado no PMP. O parâmetro α (cm^{-1}) é aproximadamente igual ao inverso da tensão capilar no ponto de inflexão da CRA, onde $d\theta/dh$ tem seu valor máximo. O parâmetro adimensional n determina a taxa na qual a forma S da CRA se volta para a ordenada em altos valores de h , assim refletindo a declividade da curva. Como segue da equação, o parâmetro θ_r influencia apenas os extremos da CRA.

Muitas aproximações existem tanto para estimar as funções que descrevem a relação da retenção de água do solo para uma gama de tensões ou para uma determinada tensão. Dentre elas, regressões múltiplas (RMs) têm sido amplamente utilizadas na geração de FPTs. Mais recentemente, devido a certos inconvenientes no uso de RMs, FPTs começaram a ser geradas com o uso de RNAs (HUSH e HORNE, 1993).

Conforme Minasny et al. (2003), são poucos os resultados de pesquisa em pedotransferência no Brasil, alguns dos quais são apresentados no Quadro 1.

Quadro 1 - Exemplos de funções de pedotransferência desenvolvidas para solos brasileiros.

Variáveis Preditas	Preditores	Tipo e Localização do solo	Referências
K(h)	CRA	Latossolos Amarelos cauliníticos da Amazônia	Tomasella et al. (1997)
AD entre 10 e 1,5 kPa	Granulometria, Ds	Ferralsols do Brasil	van den Berg et al., (1997)
Parâmetros da equação de Brooks-Corey	Textura, Ds, PT, teor de água	Amazônia brasileira	Tomasella e Hodnett (1998)
Relações entre a equação de van Genuchten e parâmetros de retenção de água	Textura, MO, UE, Ds	Dados gerais de relatórios de levantamentos de solos do Brasil	Tomasella et al. (2000)
Mineralogia de argilas e retenção de água	MO	Solos do semi-árido do Nordeste do Brasil e África Ocidental	Gaiser et al. (2000)
CC33, PMP e AD	Textura e Ds	Solos do Estado de Pernambuco	Oliveira et al. (2002)
Parâmetros da equação de van Genuchten	Textura, MO, UE e Ds	Levantamento de solos do Brasil	Tomasella et al. (2003)
Pontos da CRA	Textura, MO, Ds	Solos do Estado do Rio Grande do Sul	Reichert et al. (2009)
CC10, CC33, PMP, AD10 e AD33	Textura, MO, Ds, Dp, PT	Solos do Estado de Santa Catarina	Costa et al. (2013)

Fonte: Modificado de Minasny et al. (2003)

3.3.1 Regressões Múltiplas

Diferentes métodos podem ser utilizados para derivar as relações empíricas nas FPTs. O método mais comumente usado nas FPTs de estimativas pontuais são as RMs (GUPTA e LARSON, 1979).

A RM é um dos inúmeros modelos estatísticos explanatórios causais referentes ao tratamento de séries temporais de dados. Sua base estatística advém da regressão linear e sua aplicação é especialmente importante, pois permite que se estime um valor de uma variável com base num conjunto de outras variáveis. Quanto mais significativo for o peso de uma variável isolada, ou de um conjunto de variáveis explicativas, pode-se afirmar que alguns fatores afetam mais o comportamento de uma variável de resposta especificamente procurada, do que outros.

Numa RM é avaliada a relação de uma variável de interesse Y (variável dependente ou variável resposta) em relação a k variáveis X_j (variável independente ou covariável), $j = 1, 2, \dots, k$. Portanto, um possível modelo para avaliar essa relação pode ser dado por

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i, \quad i = 1, \dots, n \quad (2)$$

em que: n é o número de indivíduos; y_i é a observação da variável dependente para o i -ésimo indivíduo; $X_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ é um vetor de observações das variáveis independentes para o i -ésimo indivíduo; $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$ é um vetor de coeficientes de regressão (parâmetros); e ε_i é um componente de erro aleatório.

Assume-se que esses erros são independentes e seguem distribuição normal com média zero e variância desconhecida σ^2 . O modelo (2) é chamado de RM, pois envolve mais de um coeficiente de regressão. O adjetivo “linear” indica que o

modelo é linear em relação aos parâmetros $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$, e não porque y é uma função linear dos x 's.

Assumindo um modelo de função do tipo potencial para a curva de retenção de água no solo, Williams et al. (1992) desenvolveram FPTs através da granulometria, classes de estrutura (maciço ou estruturado) e matéria orgânica. As variáveis preditas foram inseridas em um modelo de retenção de água e os parâmetros foram estimados usando RM.

Os parâmetros dos modelos hidráulicos exibem algumas vezes distribuição não viesada e as transformações logarítmicas geralmente são realizadas sobre os parâmetros (RAWLS e BRAKENSIEK, 1985). Wösten et al. (1995) aplicaram as transformações para $\ln(\alpha)$ e $\ln(n-1)$ nos parâmetros da equação de van Genuchten (EvG) para normalizar suas distribuições. As transformações são também necessárias no caso de interdependência entre as variáveis. Vereecken et al. (1989) transformaram a distribuição do tamanho de partículas em fatores principais para reduzir a dependência linear entre as variáveis.

Um problema nas FPTs paramétricas é a interdependência entre os parâmetros dos modelos hidráulicos. Para superar esses problemas, van den Berg et al. (1997) sugeriram as seguintes etapas: (1) ajustar o modelo com os dados observados; (2) aplicar a análise de regressão sobre um dos parâmetros; (3) ajustar o modelo novamente fixando o parâmetro calculado no item (2) e, então; (4) continuar com a etapa (2) para outros parâmetros até que todos os parâmetros sejam ajustados.

Scheinost et al. (1997b) relatam as dificuldades na estimativa de escala e forma dos parâmetros α e n da EvG usando aproximações por RM. Os autores desse estudo realizaram uma sobre-parametrização (muitos parâmetros ajustáveis em relação ao número de pontos obtidos experimentalmente) da EvG e propuseram as seguintes abordagens:

- Configurar a relação esperada entre os parâmetros do modelo hidráulico e as propriedades do solo; e

- Inserir a relação dentro do modelo e estimar os parâmetros da relação através do ajuste de modelos estendidos usando regressões não lineares.

Apesar de RMAs serem largamente utilizadas, estes modelos, entretanto, demandam conhecimento prévio da relação entre as variáveis estudadas e exigem conhecimento técnico apurado.

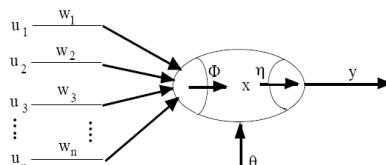
3.3.2 Redes Neurais Artificiais

Como vários textos sobre RNAs já foram publicados e estão disponíveis, neste trabalho procurou-se abordar sumariamente este tópico.

FPTs obtidas utilizando-se RNAs têm sido desenvolvidas por serem mais precisas que as RMAs na estimativa da retenção de água, nas quais os dados provêm de propriedades básicas de solo (PACHEPSKY e TIMLIN, 1994; SCHAAP e BOUTEN, 1996; PACHEPSKY et al., 1996). Apesar do progresso alcançado no desenvolvimento de FPTs em geral, as RNAs são pouco utilizadas no Brasil para estimar a CRA.

Uma RNA é uma simulação simplificada do cérebro humano e composta de unidades de processamento simples, referidas como neurônios (Figura 3).

Figura 3 – Neurônio artificial.



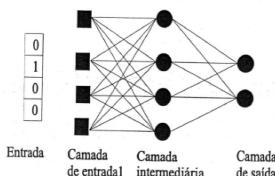
Fonte: Barreto, 2002

Uma RNA é capaz de aprender e generalizar a partir de dados experimentais imperfeitos, aprendendo por exemplos e fazendo interpolações e extrapolações do que aprenderam. Ela é simplesmente um método de regressão sofisticado que pode desempenhar uma função particular quando certos valores são atribuídos às conexões entre elementos. Para descrever um sistema não se assume uma estrutura conhecida do modelo. Ao invés disso, as redes são ajustadas de modo que uma determinada variável de entrada leva a uma saída específica (DEMUTH e BEALE, 1998).

O modelo mais simples de rede neural foi apresentado por Frank Rosenblatt em 1958, que ficou conhecido como Perceptron. Devido às críticas quanto sua capacidade computacional, as pesquisas sofreram uma estagnação e estas foram retomadas somente em 1982, com o trabalho de Hopfield. Em 1986, Rumelhart et al., com o algoritmo de treinamento *backpropagation*, demonstraram que as RNAs – Perceptron de Múltiplas Camadas (do inglês *MultiLayerPerceptron* - MLP) são capazes de resolver “problemas difíceis de aprender”.

Um MLP é uma rede *feedforward* em que os neurônios são organizados em camadas (Figura 4), onde existe uma camada de entrada, uma saída e zero ou mais camadas escondidas.

Figura 4 – Típica rede MLP com uma camada intermediária.



Fonte: Barreto, 2002

A principal característica deste tipo de rede é que não existem ligações entre os neurônios da mesma camada. Normalmente, todas as ligações começam num neurônio sobre uma camada final e para um neurônio na camada seguinte. Finalmente, os nós da camada de entrada não executam qualquer cálculo, mas simplesmente emitem suas entradas.

A fase inicial da utilização de uma RNA na solução de uma tarefa é chamada aprendizagem, quando a rede extrai informações relevantes de padrões de informação apresentados a ela e cria uma representação própria para o problema (BRAGA et al., 2000). Esta etapa consiste de duas fases distintas: fase de treinamento e fase de validação.

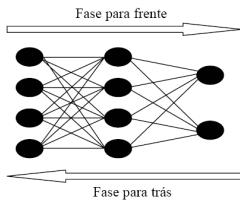
Na fase de treinamento o conhecimento é induzido nos pesos das conexões por meio de um algoritmo de treinamento ou aprendizado. Algoritmo de treinamento é um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma RNA com objetivo de aprender alguma função específica. Os dados de treinamento fornecem os exemplos de referência e o algoritmo de aprendizado incorpora o conhecimento na RNA (FERREIRA, 2005).

O algoritmo *backpropagation* (retro propagação do erro) utiliza um mecanismo de correção de erros que ajusta os pesos da rede. O treinamento da rede nesse algoritmo ocorre em duas fases: “para frente” e “para trás” (Figura 5). Sinais padronizados são enviados desde a camada de entrada e propagados até a saída, com ajuste dos erros em cada passo, de modo que na fase “para trás”, os pesos são corrigidos para minimizar o erro, já que o sinal viaja para trás, a partir de uma saída conhecida. Assim, uma sucessiva repetição das fases “para frente” e “para trás” para cada iteração reduzem progressivamente o erro de treinamento (CÂMARA, 2006).

O *backpropagation* possui, basicamente, três parâmetros que determinam seu desempenho e sua capacidade de aprendizagem: taxa de aprendizagem, que corresponde ao quanto de erro é repassado aos nós a cada iteração; *momentum*;

e o número de épocas, que é o número de iterações (CÂMARA, 2006).

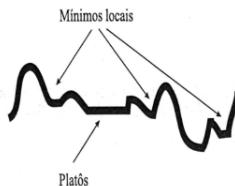
Figura 5 – Fluxo de processamento do algoritmo *backpropagation*.



Fonte: Angelotti Neto, 2007

O treinamento de uma rede neural nem sempre envolve uma função simples em que a solução encontrada não corresponde ao erro mínimo, ou seja, a função pode apresentar mínimos locais, o que pode ocasionar uma parada durante o treinamento num destes mínimos que não corresponde à solução ótima (Figura 6).

Figura 6 – Superfície de erros.



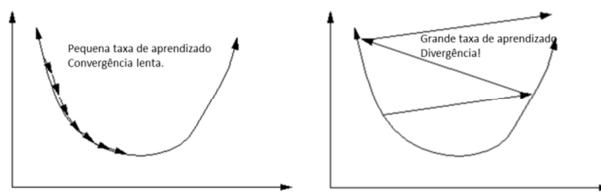
Fonte: Braga, 2000

O elemento de fundamental importância neste processo é a taxa de aprendizagem que controla a velocidade de leitura e corresponde à taxa de convergência entre a solução atual e o mínimo global. Uma das abordagens utilizadas para diminuir a irregularidade da função erro (composta de diversos máximos e mínimos locais) consiste na introdução de um termo adicional chamado *momentum*, que tem por objetivo permitir o aumento da taxa de aprendizagem sem que ocorram oscilações, bem como atuar no aumento da velocidade de convergência (GALVÃO e VALENÇA, 1999). A taxa de aprendizagem e o

momentum são técnicas que ajudam a rede a encontrar o mínimo global, que fornece a solução ótima com o menor erro.

Quando a taxa de aprendizado é muito pequena a convergência ao mínimo local será muito lenta e quando a taxa é muito elevada a rede divergirá (Figura 7). Infelizmente a melhor taxa de aprendizado de uma rede é tipicamente diferente para cada peso da rede.

Figura 7 – Variações e consequências da taxa de aprendizagem do *Backpropagation*.

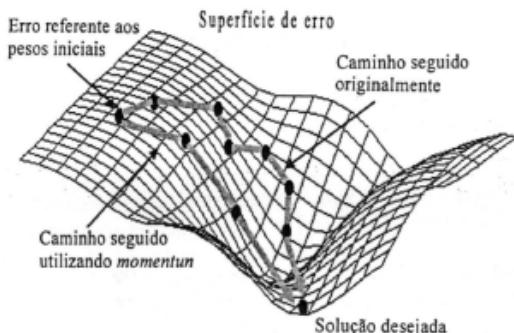


Fonte: Modificado de Orr, 1999.

O *momentum* é uma pequena fração adicionada a cada fase da rede, com um peso anteriormente determinado. Sua variação está no intervalo $[0, 1]$. Juntamente com a taxa de aprendizado, o *momentum* acelera ou retarda a aproximação ao mínimo global. A figura 8 mostra uma aproximação da rede sem o *momentum* e com o *momentum* (HOCHREITER e SCHMIDHUBER (1997) apud ORR, 1999; BRAGA, 2000).

A fase de validação, subsequente à fase de treinamento, tem o objetivo de verificar a capacidade de generalização da rede. O que se espera é uma rede com capacidade de generalização adequada e que seja capaz de categorizar os dados de teste corretamente (CÂMARA, 2006).

Figura 8 – Influência do termo *momentum* na aproximação ao mínimo global.



Fonte: Braga, 2000

3.3.3 Estimativas de Atributos do Solo Utilizando RNAs

A área de RNAs começou a se desenvolver no Brasil ao final dos anos 1970. Por ser uma área multidisciplinar, a gama de aplicações das RNAs é vasta. Somente a partir dos anos 1980 houve maior interesse pelas RNAs pois, com o avanço da tecnologia, sobretudo da microeletrônica, foi possível a retomada dos estudos.

Hsu et al. (1995) demonstraram que a abordagem RNA proporciona uma melhor representação da relação chuva-vazão de uma bacia de tamanho médio do que a abordagem ARMAX ou o modelo de umidade do solo Sacramento. Minns e Hall (1996) aplicaram uma RNA para modelagem da relação chuva-vazão. Dawson e Wilby (1998) utilizaram uma RNA para previsão de fluxo de rio. As redes neurais artificiais foram utilizadas para a previsão do reservatório ingresso por Jain et al. (1999). Birikundavyi et al. (2002) constataram que uma RNA pode conseguir uma precisão superior à de ARMAX e modelos determinísticos para sete dias antes da previsão da chuva. Kumar et al. (2002) concluíram que a RNA pode prever

melhor a evapotranspiração de referência para uma área do que o método de Penman-Monteith.

Um conjunto de dois artigos publicados pelo comitê de tarefa da American Society of Civil Engineers (ASCE), sobre a aplicação das RNAs em hidrologia, contém uma análise detalhada da teoria e aplicações de RNAs em recursos hídricos (ASCE 2000a, 2000b). Govindaraju e Rao (2000) descreveram muitas aplicações de RNAs aos recursos hídricos.

As RNAs também têm encontrado recentemente aplicação generalizada para previsões da CRA a partir da granulometria do solo e de dados relacionados com FPTs (PACHEPSKY et al., 1996; SCHAAP et al., 1998; KOEKKOEK e BOOLTINK, 1999; MINASNY e McBRATNEY, 2002). A premissa básica destas abordagens é assumir a aplicabilidade de um determinado modelo de retenção e, em seguida, usar RNAs para correlacionar vários ou todos os parâmetros desconhecidos do modelo para dados mais facilmente disponíveis ou medidos, tais como granulometria, densidade do solo, teor de matéria orgânica, e/ou estrutura do solo. Exemplificando, Schaap et al. (1998) utilizaram RNAs para estimar os parâmetros da EvG, bem como da condutividade hidráulica saturada. Para facilitar o uso prático de FPTs, eles projetaram uma estrutura hierárquica para permitir a entrada de ambos os conjuntos limitados e mais prolongados de preditores. Foram combinadas as RNAs com o método de inicialização (EFRON e TIBSHIRANI, 1993) para obter adicionalmente uma estimativa da incerteza nas previsões de FPTs (SCHAAP et al., 1998). As FPTs foram calibradas para alguns dos 2.100 conjuntos de dados hidráulicos do solo e testadas em mais de 47.000 registros do banco de dados de caracterização do solo do Serviço de Conservação de Recursos Naturais dos EUA. Posteriormente, Schaap e Leij (2000) expandiram a abordagem hierárquica para incluir a condutividade hidráulica do solo não saturado. O trabalho

resultou em um pacote de software baseado em janelas (Rosetta), que incorpora as diferentes FPTs.

Muitos estudos relacionados à modelagem de vários parâmetros do solo usando diferentes tipos de FPTs ainda têm sido realizados. Por exemplo, Najafi e Givi (2006) utilizaram RNAs e FPTs tradicionais para previsão da densidade do solo, predizendo-a melhor do que as FTs tradicionais. Jain e Kumar (2006) indicaram que a técnica RNA pode ser empregada com sucesso na calibração de equações de infiltração, sendo eficazes mesmo com limitada disponibilidade de dados.

Reichardt e Timm (2012) levantaram dados sobre a utilização de RNAs na área agronômica e encontraram exemplos de textos com fundamentos conceituais, princípios operacionais e métodos de modelagem com redes neurais artificiais em Kovács (1996), Valença (2005) e Rezende (2005). Já na literatura internacional, encontraram um texto bastante amplo sobre este assunto (Haykin, 1999).

4 MATERIAL E MÉTODOS

4.1 Perfis dos solos amostrados

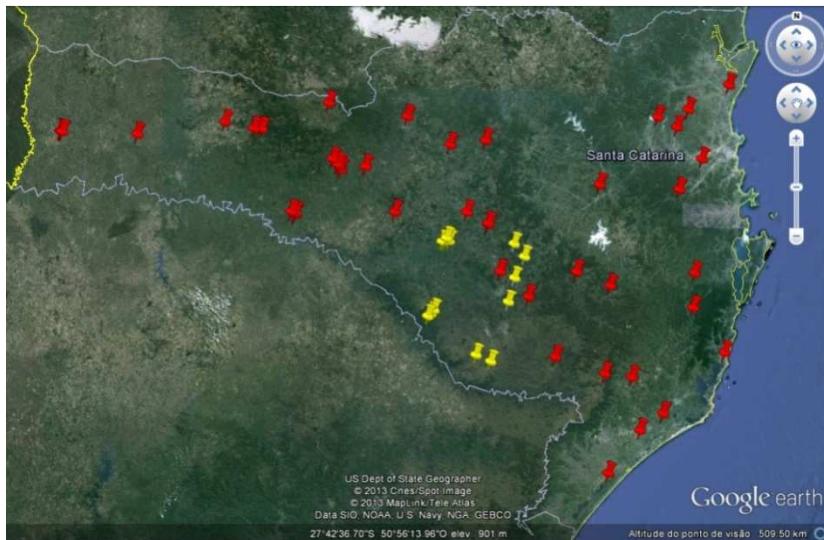
Utilizou-se neste estudo o banco de dados de 44 perfis de solo (BD1) publicado por Costa (2012). Nesse banco os solos foram descritos e estão inclusos nos trabalhos de Almeida et al. (1997, 2000, 2003), Corrêa (2003), SBCS (2008), Paes Sobrinho et al. (2009) e Bringhenti (2010). Costa (2012) utilizou em seu estudo os teores de areia, argila e silte, densidade do solo e de partícula, teor de matéria orgânica e porosidade total e os relacionou com pontos da CRA.

Adicionalmente foram incluídos neste estudo mais 13 solos (BD2) das Ordens Nitossolo, Cambissolo, Neossolo e Latossolo, coletados em várias regiões da Serra Catarinense, os quais foram objeto de estudo de Bonfatti (2012), Oliveira (2012), Teske (2010) e Ferreira (2010). Entretanto, em nenhum deles estudou-se a retenção e a disponibilidade de água no solo.

Deste modo, o estudo contou com dois bancos de dados: BD1 com 44 perfis de solo; e BD2 com 13 perfis adicionados ao BD1, perfazendo 57 perfis solos, totalizando 940 horizontes pedogenéticos superficiais e subsuperficiais avaliados. As amostras com estrutura preservada foram coletadas em quadruplicata.

A distribuição dos perfis pode ser vista na figura 9. No apêndice A encontram-se a classificação dos solos, a localização, a litologia, os horizontes amostrados e a altitude dos 13 perfis adicionais. As demais informações encontram-se ao longo do texto.

Figura 9 – Distribuição geográfica dos 57 perfis de solo no Estado de Santa Catarina utilizados no estudo. Em vermelho corresponde aos 44 perfis do banco de dados de Costa (2012) e em amarelo os 13 perfis coletados neste estudo.



Fonte: Google Earth.

4.2 Coleta das amostras

Em cada um desses perfis foram coletadas amostras de solo nos horizontes A, AB, BA e B, quando presentes no solo, e suas subdivisões (ex. A1, A2, B1, B2, ...) exceto BC, e apenas no horizonte A dos Neossolos.

As quatro subamostras com estrutura preservada foram coletadas no centro de cada horizonte, verticalmente de cima para baixo no perfil utilizando-se anéis volumétricos (diâmetro de 6,0 e altura de 2,5 cm). Amostras simples com estrutura alterada foram coletadas na mesma posição e armazenadas em sacos plásticos para determinação de outros atributos do solo.

4.3 Curva de retenção de água (CRA)

As amostras coletadas com estrutura preservada em anéis volumétricos foram submetidas às sucções de 1, 6 e 10 kPa aplicadas em coluna de areia (REINERT e REICHERT, 2006) e de 33, 100, 300, 500, 1.000 e 1.500 kPa em câmaras de Richards (RICHARDS, 1949).

4.4 Granulometria

A granulometria foi determinada pelo método da pipeta (GEE e BAUDER, 1986) em 50 g de terra fina seca ao ar (TFSA), empregando-se NaOH 1 N como dispersante químico e agitação mecânica de 120 rpm por 4 h sem interrupção. A fração areia foi separada por peneiramento, a fração argila por sedimentação e a fração silte por diferença. A fração areia foi subdividida em cinco classes: areia muito grossa (AMG) ($\varnothing = 2,0$ a 1,0 mm), areia grossa (AG) ($\varnothing = 1,0$ a 0,5 mm), areia média (AM) ($\varnothing = 0,5$ a 0,25 mm), areia fina (AF) ($\varnothing = 0,25$ a 0,105 mm) e areia muito fina (AMF) ($\varnothing = 0,105$ a 0,053 mm).

4.5 Densidade do solo e de partículas

A densidade do solo (Ds) foi determinada pelo método do anel volumétrico (EMBRAPA, 1997) e a densidade de partículas (Dp) pelo método do balão volumétrico (GUBIANI et al., 2006).

4.6 Carbono orgânico total

A análise do carbono orgânico total (COT) foi realizada de acordo com a metodologia descrita por Tedesco (1995). Amostras de 0,20 a 0,50 g de TFSA foram colocadas em erlenmeyer de 50 ml, adicionando-se solução oxidante composta de 5 ml de $K_2Cr_2O_7$ (dicromato) 1,25 mol l^{-1} e 10 ml

de H_2SO_4 (6 N) concentrado. Após, foram levadas para o banho de areia e aquecidas até atingir 150 °C e mantidas nesta temperatura por 1 minuto. Na sequencia foram tituladas com sulfato ferroso (FeSO_4 0,25 mol L⁻¹) na presença de 3 gotas do indicador ferroin (O-fenantrolina). Provas em branco também foram submetidas ao aquecimento, para quantificar a redução do dicromato durante o processo. No trabalho foi utilizado o teor de matéria orgânica (MO), sendo obtido multiplicando-se pelo fator 1,7239, supondo-se que a MO tem em média 58 % de COT.

4.7 Análise estatística

Para atender o objetivo 1 foi realizada a análise de correlação entre os atributos obtidos da curva de retenção de água com os demais atributos do solo.

Para atender o objetivo 2, as funções de pedotransferencia ajustadas por Costa (2012), incluindo os dados que avaliaram a eficiência foram comparados com os dados gerados através de RNA. Para isso foram ajustadas novas funções de pedotransferência através de RNAs. A comparação da eficiência foi realizada através do R^2 e REQM. A descrição do procedimento segue abaixo no texto.

Para atender o objetivo 3 foi utilizado o BD2 que inclui os 57 perfis de solos de SC. A comparação da eficiência foi realizada através da R^2 e REQM dos resultados das FPTs geradas por RNAs. Os gráficos de dispersão dos valores preditos *versus* estimado se encontram no final do texto.

4.8 Funções de Pedotransferência

As FPTs pontuais foram utilizadas para estimar a umidade do solo na tensão de 10 kPa, denominada de CC10; na tensão de 33 kPa, denominada de CC33 e; na tensão de 1.500 kPa, denominada de PMP. Além dessas, também foram

geradas FPTs para estimativa de dois conteúdos de água disponível, resultantes da diferença da umidade do solo entre as tensões de 10 a 1.500 kPa, denominada de AD10, e entre as tensões de 33 e 1.500 kPa, denominada de AD33.

FPTs podem ser geradas a partir da separação dos solos por horizontes pedogenéticos (A+B, A e B) e também em diferentes níveis hierárquicos de entrada de atributos dos solos, considerando-se primeiramente aqueles com maior correlação com a retenção e disponibilidade de água.

4.8.1 Regressões Múltiplas

As RMAs para geração de FPTs para solos do estado de Santa Catarina foram determinadas por Costa (2012) com o BD1 de 44 perfis de solos representativos do estado, totalizando 1.232 dados de atributos físicos e químicos do solo (Quadro 4).

A partir deste BD o autor gerou e validou FPTs Pontuais seguindo sete modelos diferentes, com efeito aditivo das variáveis preditoras e possíveis interações – cujo procedimento está detalhado abaixo:

- efeito aditivo com variáveis em escala não transformada (x);

- efeito aditivo com variáveis em escala com as seguintes transformações: elevado ao quadrado (x^2); raiz quadrada (\sqrt{x}); inverso ($1/x$); inverso do quadrado ($1/x^2$); inverso da raiz quadrada ($1/\sqrt{x}$); logaritmo natural ($\ln(x)$); logaritmo natural do quadrado ($\ln(x^2)$); logaritmo natural do inverso ($\ln(1/x)$); logaritmo natural do quadrado ao inverso ($\ln(1/x^2)$);

- efeito multiplicativo com variáveis independentes multiplicadas entre si, combinadas duas a duas, em escala não transformada ($a*b$; $a*c$; $b*c$) e elevada ao quadrado (a^2*b^2 ; a^2*c^2 ; b^2*c^2).

Modelo 1 – Granulometria: teores de areia, argila e silte;

Modelo 2 – Granulometria e suas iterações;

Modelo 3 – Granulometria e MO;

Modelo 4 – Granulometria, MO e suas iterações;

Modelo 5 – Granulometria, MO, Ds, Dp e PT;

Modelo 6 – Granulometria, MO, Ds, Dp, PT e suas iterações;

Modelo 7 – Cinco classes de areia (AMG, AG, AM, AF e AMF), argila, silte, MO, Ds, Dp, PT e suas iterações.

As FPTs pontuais foram geradas para cada variável dependente utilizando três bancos de dados, constituídos pelas seguintes amostras de solos: (a) apenas de horizontes superficiais; (b) apenas de horizontes subsuperficiais; e (c) dos horizontes superficiais e subsuperficiais. Isso resultou na obtenção de três FPTs para cada variável dependente em cada modelo, totalizando 15 FPTs geradas para cada um dos sete modelos.

As FPTs foram geradas através do procedimento STEPWISE, disponível na rotina do programa SAS (1990), considerando como variáveis dependentes as umidades nas tensões estudadas (10, 33 e 1.500 kPa) e o teor de água disponível (água retida entre as tensões de 10 e 1.500 kPa e 33 e 1.500 kPa) e, como variáveis independentes, os demais atributos do solo. A umidade estimada pelos modelos existentes para cada tensão foi comparada com a umidade medida em laboratório.

4.8.2 Redes Neurais Artificiais

A geração de FPTs pontuais utilizaram dois BDs distintos.

Para comparar as FPTs geradas por RMs com aquelas geradas com RNAs, atendendo o segundo objetivo, o BD1 foi utilizado. Como RNAs não exigem linearidade nem normalidade dos dados, os modelos que incluíram interações não foram utilizados. Isso resultou em quatro modelos:

Modelo 1 – Granulometria: teores de areia, argila e silte;

Modelo 3 – Granulometria e MO;

Modelo 5 – Granulometria, MO, Ds, Dp e PT;

Modelo 7 – Cinco classes de areia (AMG, AG, AM, AF e AMF), argila, silte, MO, Ds, Dp, PT (sem suas iterações).

Para testar a segunda hipótese do trabalho, o BD2 foi utilizado. Os modelos escolhidos foram aqueles que forneceram os melhores resultados nas predições, além disso, considerou-se que como RNAs não exigem linearidade nem normalidade dos dados, os modelos que incluíram interações não foram utilizados.

Neste procedimento, os modelos e a estrutura da rede são reajustados de modo a aumentar a eficiência e reduzir o erro e o número de *inputs*. Isso resultou em dois modelos:

Modelo RNA1 – Teores de Silte, Argila, Classe Areia Fina e Grossa, MO, Ds e Dp.

Modelo RNA2 – Teores de Silte, Argila, Classe Areia Fina, MO, Ds, PT e microporosidade.

As RNAs foram desenvolvidas utilizando-se o software WEKA (WITTEN e EIBE, 2005) que disponibiliza a função Perceptron de Camadas Múltiplas (do inglês *MultiLayerPerceptron* - MLP) para treinamento da RNA, através do algoritmo *backpropagation* (RUMELHART et al., 1986). Além desse algoritmo, outro critério adotado foi a utilização da validação cruzada em 10 dobras (*cross-*

validation). Esta técnica permite estimar a precisão do método, no qual exemplos do conjunto de dados são divididos aleatoriamente em 10 grupos mutuamente exclusivos (dobras) com tamanho e distribuição semelhantes. Uma dobra é separada como teste e as 9 dobras restantes são consideradas para treinamento da rede. Cada par (dobra de teste, dobra de treinamento) constitui uma iteração para a validação do algoritmo, totalizando 10 iterações. Após o treinamento, utilizando a dobra de treinamento, a dobra de teste é apresentada à rede em questão e o erro é calculado. Finalmente, a média das 10 dobras fornece uma estimativa do desempenho do algoritmo (FERREIRA, 2005). Cada dobra apresenta um erro relativo ao valor esperado. Após as 10 dobras, o erro e o coeficiente de determinação refletem a estimativa de desempenho futuro (precisão) da RNA.

Para geração da FPT é necessário proceder ao cálculo da função de ativação da rede, que neste caso é uma sigmóide para os pesos dos nós das camadas ocultas e linear para o peso de saída (Figura 10).

As FPTs obtidas a partir da RNA-MLP são calculadas como demonstradas a seguir:

$$y = f(x)$$

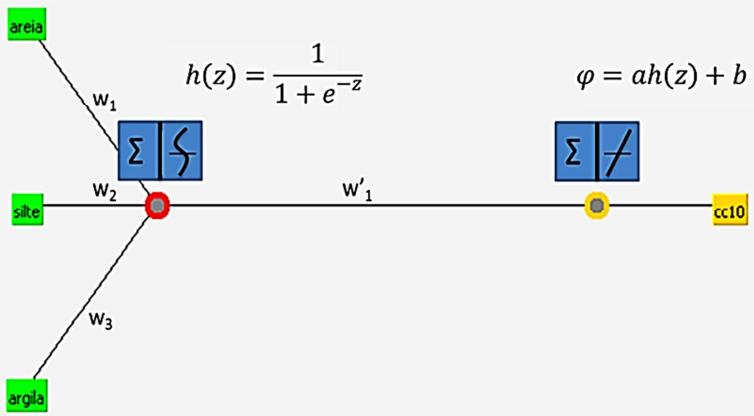
$$f: R^N \ni x \rightarrow y \in R$$

Onde:

$$x = [N]^T$$

Em que: N corresponde ao número de atributos do solo que servem como dados de entrada da rede e y a função de saída da RNA.

Figura 10 – Funções de ativações da RNA – MLP.



Fonte: produção do próprio autor.

Uma RNA tem como função de saída uma combinação dos dados de entrada ponderados por seu peso individual somados e, em seguida, limitados por uma função de ativação, que no caso do MLP é uma sigmóide.

$$h_j(z) = \frac{1}{1 + e^{-z_j}} \quad (4)$$

$$z_j = (\sum_{j=1}^N w_{ij} \cdot x_j + \theta_i) \quad (5)$$

$$f(x) = (\sum_{i=1}^N w'_i \cdot z_i + \theta') \quad (6)$$

Substituindo (4) em (5), temos:

$$f(x) = \text{sig}(\sum_{i=1}^N w'_i \cdot \text{sig}(\sum_{j=1}^N w_{ij} \cdot x_j + \theta_i) + \theta') \quad (7)$$

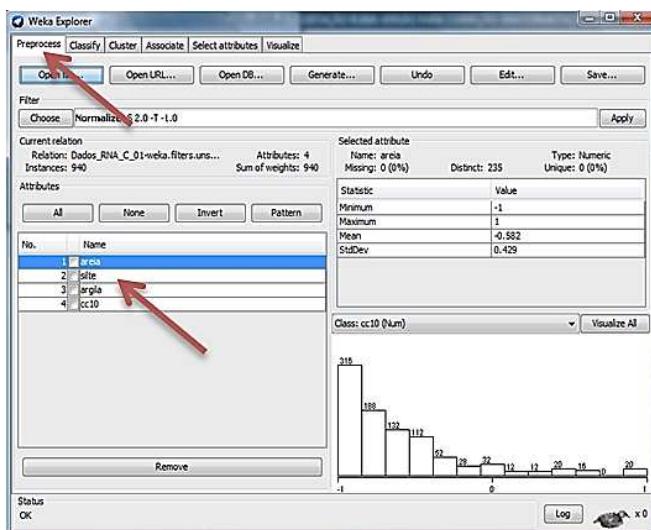
Finalmente, substituindo (6) em (7), obtém-se:

$$f(x) = \left[1 + e^{-\left(\sum_{i=1}^N w'_i \cdot \left[\left(\sum_{j=1}^N w_{ij} \cdot x_j + \theta_i \right) \right]^{-1} + \theta' \right)} \right]^{-1} \quad (8)$$

Em que: w é a matriz de pesos da camada de entrada; w' o vetor de pesos da camada de saída; θ_i o i -ésimo termo de polarização (bias) do neurônio da camada intermediária; θ' o termo de polarização do neurônio de saída; e g_i a função de saída do i -ésimo neurônio da camada intermediária. Um exemplo de cálculo dessa FPT gerada é dada no apêndice B.

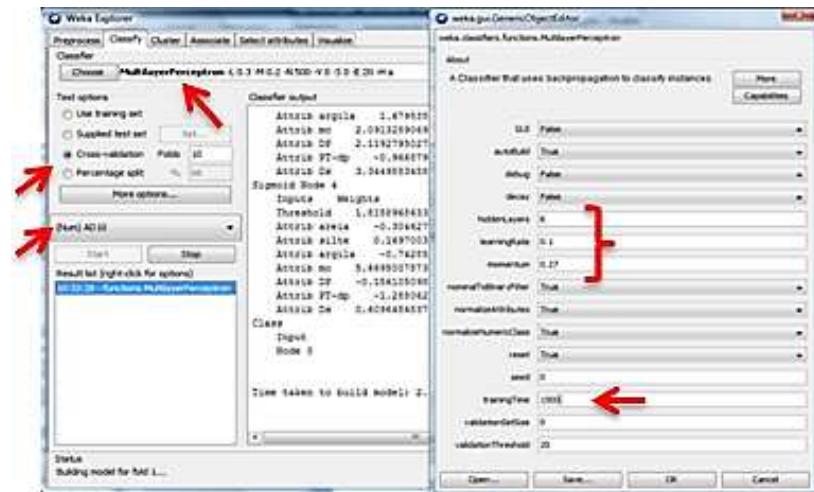
Após o pré-processo dos dados de entrada da rede (*input*), na tela inicial do WEKA, a classificação é feita (Figura 11). Os dados que alimentam a RNA precisam ser normalizados para que estejam no intervalo em que a função abrange. O processo de normalização se dá automaticamente selecionando-se a opção *normalizeAttributes*, quando os dados são carregados e em seguida classificados. Nesta etapa, o atributo a ser predito (*output*) é escolhido, a estrutura da rede é ajustada através de tentativa e erro até obtenção da melhor estrutura e o processo é iniciado (figura 12).

Figura 11 – Tela do *software* WEKA: carregamento dos dados – pré-processo.



Fonte: produção do próprio autor.

Figura 12 – Vista em diferentes momentos da tela do Weka para escolha da função MultiLayerPerceptron, validação cruzada, atributo a ser estimado e ajustes dos parâmetros da rede neural (estrutura da rede e normalização dos dados).



Fonte: produção do próprio autor.

As FPTs pontuais foram geradas para os atributos CC10, CC33, AD10, AD33 e PMP, ao quais podem ser preditos pela RNA, selecionando-se diretamente no programa.

A raiz do erro médio quadrático (REQM) e coeficiente de correlação de Pearson foram utilizados para avaliar o desempenho da FPTs geradas a partir de RMs e RNAs.

A REQM é obtida através da seguinte equação:

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (\theta i_m - \theta i_e)^2} \quad (9)$$

Onde: n é o número de amostras; θi_m é a umidade do solo medida; e θi_e é a umidade do solo estimada pela função de pedotransferência.

A utilização somente do REQM deve-se à grande disponibilidade desse indicador em estudos com FPTs

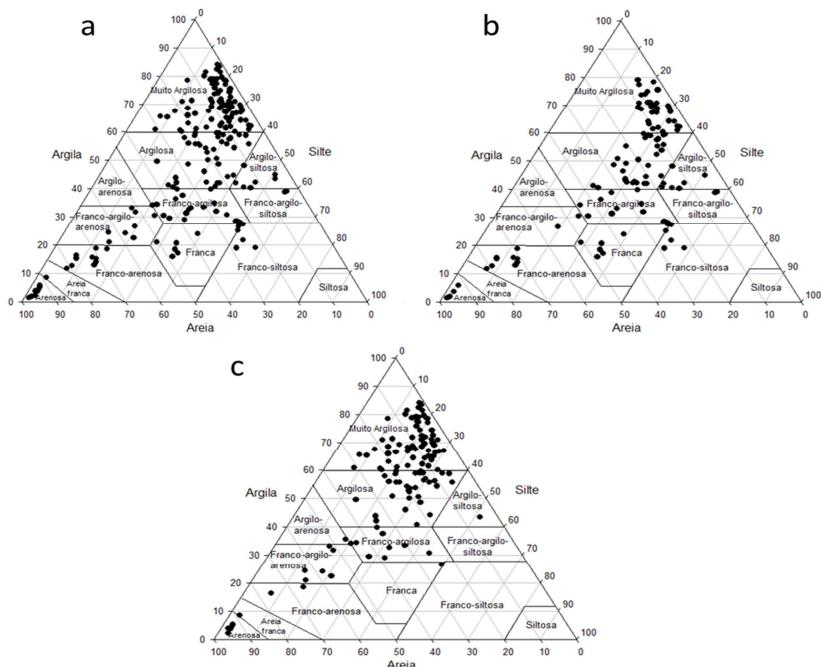
(TOMASELLA et al., 2003; MINASNY, 2006; SAXTON e RAWLS, 2006; MICHELON et al., 2010; MINASNY e HARTEMINK, 2011), o que possibilita a comparação dos valores obtidos para solos do Estado de Santa Catarina com valores da literatura.

5 RESULTADOS E DISCUSSÃO

5.1 Relação dos atributos dos solos com a retenção de água no solo e disponibilidade para as plantas

As classes de solo mais representativas dos perfis avaliados, ao nível de Ordem, foram os Nitossolos (15 perfis), Cambissolos (12 perfis) e Neossolos (11 perfis). Em sua maioria os solos estudados são de textura argilosa a muito argilosa, sendo que apenas os Neossolos Quartzarênicos apresentaram textura arenosa a franco-arenosa (Figura 13 – a, b e c).

Figura 13 – Classes texturais dos horizontes A+B (a), horizonte A (b) e para horizonte B (c) do BD2.



Fonte: produção do próprio autor.

O conteúdo de água na CC10 e no PMP foi maior nos horizontes subsuperficiais em relação ao superficial, consequentemente o conteúdo médio de água disponível (AD) para as plantas igual foi maior no horizonte superficial (Quadro 2).

A variabilidade dos dados de umidade entre os horizontes pedogenéticos pode ser atribuída à variação nos constituintes do solo entre os horizontes e os perfis.

Apesar da grande variabilidade, existem poucos solos com teores de silte acima de 400 g kg⁻¹ e predominam solos com teores elevados de argila (Figura 13 e quadro 2). Em SC predomina material de origem do tipo basalto e riodacito, ambos da Formação Serra Geral, situado no Planalto Sul e Oeste, os quais originam solos com classe textural argilosa ou muito argilosa (COSTA et al., 2013). Além deste, existem áreas extensas sob a influência de rochas sedimentares de textura variada, situadas em uma faixa no centro do estado, as quais originam solos desde argilosos até arenosos.

Quadro 2 - Valores mínimo e máximo, média e desvio padrão dos atributos dos 57 perfis de solos.

Atributo	Mínimo	Máximo	Média	Desvio Padrão
Horizontes A+B				
Areia	11	973	212	206
Silte	12	581	260	106
Argila	15	841	529	197
MO	3	150	30	21
Ds	0,60	1,76	1,15	0,18
Dp	2,12	2,98	2,49	0,17
PT	0,26	0,74	0,54	0,08
CC10	0,12	0,77	0,47	0,10
CC33	0,11	0,75	0,44	0,09
PMP	0,04	0,66	0,36	0,09
AD10	0,04	0,26	0,11	0,03
AD33	0,02	0,23	0,08	0,03
<i>continua...</i>				

...conclusão

Horizontes A				
Silte	12	581	290	122
Argila	15	789	453	207
MO	7	150	43	22
Ds	0,60	1,76	1,11	0,21
Dp	2,12	2,95	2,48	0,16
PT	0,26	0,74	0,55	0,09
CC10	0,12	0,77	0,44	0,11
CC33	0,11	0,73	0,41	0,10
PMP	0,04	0,59	0,31	0,09
AD10	0,04	0,26	0,13	0,04
AD33	0,02	0,23	0,09	0,03
Horizontes B				
Areia	11	661	171	147
Silte	73	516	231	79
Argila	184	841	598	158
MO	3	76	19	10
Ds	0,81	1,63	1,19	0,14
Dp	2,17	2,98	2,51	0,17
PT	0,34	0,70	0,52	0,07
CC10	0,24	0,76	0,49	0,07
CC33	0,22	0,75	0,47	0,07
PMP	0,15	0,66	0,40	0,07
AD10	0,04	0,22	0,09	0,03
AD33	0,03	0,18	0,08	0,02

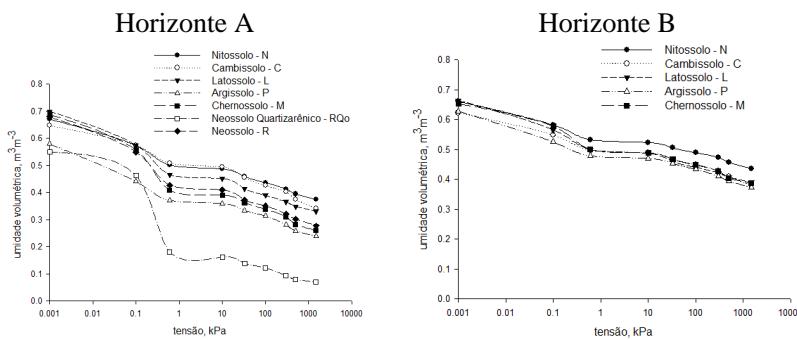
Teores de areia, silte, argila e MO em g kg^{-1} ; Ds e Dp em g cm^{-3} ; PT, CC10, CC33, PMP, AD10 e AD33 em $\text{m}^3 \text{m}^{-3}$.

Fonte: produção do próprio autor.

Na figura 14 estão colocadas as CRAs para os horizontes superficiais e subsuperficiais, computando a média para cada classe de solo. Estas curvas fornecem um bom indicador da variedade de classes de solos estudados, indicando qual atributo influencia a forma da CRA. Na figura, os Nitossolos e Cambissolos retém mais água nos horizontes superficiais, provavelmente pelo maior teor de argila e MO nestes solos. De modo geral, a variação entre os solos foi mais evidente na retenção de água nos horizontes superficiais e que

nestes horizontes a retenção de água é menor que nos subsuperfícias, mesmo em solos de classes diferentes. Isso ocorre, principalmente, devido ao maior teor de argila e menor de areia nos horizontes subsuperficiais.

Figura 14 – Curvas de retenção de água médias dos horizontes superficiais e subsuperficiais das seis classes de solos avaliados. Nitossolo (15 perfis), Cambissolo (12 perfis), Neossolo (11 perfis), Latossolo (7 perfis), Argissolo (9) e Chernossolo (3).



Fonte: produção do próprio autor.

O maior teor de MO nos horizontes superficiais (ver Quadro 2) influencia diretamente a porosidade destes horizontes, consequentemente a retenção de água é maior e a declividade da CRA é mais acentuada na região onde a tensão é maior, indicando o esvaziamento destes poros. No caso dos horizontes subsuperficiais, a CRA tem um declive suave, indicando drenagem lenta e gradual com o aumento da tensão aplicada.

O efeito da MO na retenção de água foi alto para o conjunto dos horizontes superficiais e muito baixo para os horizontes subsuperficiais. A MO possui alta capacidade de retenção de água, a qual é muito maior do que a de um igual volume de material mineral. Geralmente a MO estabiliza a estrutura e aumenta o volume total e o tamanho de poros do solo. Isto resulta em um aumento da infiltração e da capacidade

de retenção de água, com aumento simultâneo da quantidade de água retida no PMP. (BRADY e BUCKMAN, 1989).

A retenção de água foi dependente da granulometria e dos teores de MO do solo. A correlação foi negativa para a areia e Ds e positiva para a argila, silte, MO e PT. Entretanto, a disponibilidade de água nestes solos teve maior correlação com o teor de silte e MO. A retenção e a disponibilidade de água nos solos teve baixa correlação com a densidade do solo e de partículas (Quadro 3).

Solos de granulometria fina retêm mais água do que solos de granulometria grossa, porém nesses solos a água disponível não difere muito daquela dos de granulometria mais grossa, pelo fato de solos argilosos possuírem elevada retenção de água no PMP. Quando os atributos são separados por horizontes pedogenéticos (Quadro 3), é possível verificar quais atributos mais contribuem para retenção e disponibilidade de água no solo.

A retenção de água não teve correlação significativa com a Dp em nenhum dos conjuntos de horizontes estudados. Costa et al. (2013) sugerem que a interação da MO (com baixa Dp) com a fração mineral (com alta Dp) mascara o efeito dos óxidos de ferro que, por sua alta concentração em solos argilosos de origem basáltica, diminui a correlação entre a retenção e disponibilidade de água e a densidade de partículas (Quadro 3).

Os teores de areia, argila e MO influenciaram a retenção de água nos horizontes superficiais, enquanto que o silte contribuiu menos neste horizonte. A disponibilidade de água teve correlação positiva com os teores de silte e MO nos horizontes A, e correlação negativa com o teor de argila nos horizontes B, no entanto, os coeficientes foram baixos para este atributo (entre -0,09 e 0,50).

Quadro 3 - Coeficientes de correlação de Pearson, entre os atributos do solo e a retenção de água, em diferentes pontos da CRA e o CAD para os 57 perfis de solos estudados.

Atributo	Areia	Silte	Argila	MO ⁽¹⁾	Dp	PT	Ds
Horizonte A+B							
1 kPa	-0,60	0,19	0,53	0,34	-0,09	0,75	-0,63
6 kPa	-0,73	0,22	0,64	0,22	-0,05*	0,53	-0,39
CC 10	-0,72	0,21	0,64	0,20	-0,05*	0,50	-0,36
CC 33	-0,71	0,18	0,65	0,14	-0,05*	0,46	-0,29
100 kPa	-0,71	0,16	0,65	0,10	-0,04*	0,44	-0,27
300 kPa	-0,72	0,14	0,68	0,07*	-0,01*	0,43	-0,27
500 kPa	-0,73	0,10	0,71	0,05*	0,01*	0,43	-0,26
PMP	-0,74	0,07	0,73	0,03*	0,01*	0,43	-0,25
AD 10	0,10	0,38	-0,31	0,50	-0,17	0,18	-0,29
AD 33	0,13	0,38	-0,34	0,40	-0,22	0,11	-0,14
Horizonte A							
1 kPa	-0,59	0,31	0,52	0,61	-0,08*	0,73	-0,70
6 kPa	-0,76	0,50	0,62	0,64	-0,07*	0,51	-0,53
CC 10	-0,77	0,50	0,63	0,64	-0,06*	0,49	-0,52
CC 33	-0,76	0,49	0,62	0,61	-0,06*	0,48	-0,48
100 kPa	-0,76	0,49	0,63	0,60	-0,07*	0,46	-0,46
300 kPa	-0,78	0,48	0,66	0,56	-0,02*	0,46	-0,48
500 kPa	-0,79	0,44	0,69	0,55	0,01	0,46	-0,48
PMP	-0,80	0,42	0,72	0,53	0,01	0,46	-0,47
AD 10	-0,08	0,34	-0,10	0,44	-0,22	0,22	-0,25
AD 33	-0,02	0,36	-0,19	0,39	-0,27	0,16	-0,13
Horizonte B							
1 kPa	-0,64	0,06*	0,57	0,14	-0,13	0,80	-0,62
6 kPa	-0,61	-0,01*	0,57	0,10	-0,11	0,68	-0,42
CC 10	-0,59	-0,02*	0,56	0,10*	-0,12*	0,66	-0,39
CC 33	-0,57	-0,02*	0,55	0,07*	-0,12	0,61	-0,32
100 kPa	-0,57	-0,02*	0,54	0,06*	-0,12	0,60	-0,31
300 kPa	-0,61	-0,03*	0,58	0,06*	-0,09*	0,59	-0,32
500 kPa	-0,62	-0,06*	0,61	0,06*	-0,09*	0,59	-0,32
PMP	-0,63	-0,08*	0,63	0,06*	-0,09*	0,59	-0,32
AD 10	0,21	0,21	-0,31	0,09*	-0,06*	0,10	-0,16
AD 33	0,25	0,24	-0,35	0,03*	-0,09	0,00*	0,03*

⁽¹⁾MO – Matéria orgânica; Dp – Densidade de partículas; PT – Porosidade total; Ds – Densidade do solo. * Não significativo a 0,05.

Fonte: produção do próprio autor.

Como o teor de MO diminui em profundidade, o efeito desta na retenção e disponibilidade de água é menos acentuado no horizonte B. O teor de argila teve comportamento semelhante nos três conjuntos de horizontes analisados, correlacionando-se com a retenção e disponibilidade de água nos horizontes A+B, A e B.

A correlação entre a PT e a retenção de água se deu em todos os horizontes, mas foi maior nos horizontes subsuperficiais, sendo muito baixa para disponibilidade de água, especialmente no horizonte B.

Epibenu e Nwadialo (1994) afirmaram que a AD é significativamente correlacionada apenas com o teor de argila, silte e carbono orgânico no solo, sendo o carbono orgânico responsável por quase 50 % da variação da AD e o teor de silte por cerca de 6 % desta. Estes resultados sugerem que o carbono orgânico é uma fonte primária na determinação da umidade na capacidade de campo dos horizontes superficiais do solo. Quando diferentes horizontes superficiais têm teor de carbono orgânico semelhante, a quantidade de argila ou silte + argila foi responsável pela maior parte da variação de umidade na capacidade de campo. Os mesmos autores também encontraram uma alta correlação entre a granulometria e a CC e o PMP.

Salter et al. (1966) indicaram que tanto a estrutura quanto a granulometria influenciam a AD do solo e, desta maneira, a variação na AD determinada entre solos na mesma classe textural pode ser parcialmente resultante de diferenças estruturais entre solos. A AD apresentou uma baixa correlação com o teor de argila (Quadro 3), o que confirma os resultados obtidos por Abrol et al. (1968). Esses autores também observaram que a fração silte tem grande importância no armazenamento de água disponível (entre 0,33 e 1500 kPa).

Solos de textura mais fina, com mais silte e argila retêm mais água em todas as tensões, independente do conjunto de horizontes analisado. Em solos com maior teor de MO, a

retenção de água também é maior, sendo este efeito mais importante nos horizontes superficiais e menos nos subsuperficiais. Solos menos densos e mais porosos retêm mais água. A AD foi relacionada com os teores de silte e MO. Nos solos mais argilosos e com maior Dp a AD foi menor. O agrupamento de 44 perfis de solos por classes texturais foi realizado por Costa (2012), mostrando que as propriedades de retenção e disponibilidade de água dependem da classe textural, horizonte analisado e classe de solo.

5.2 Redes Neurais Artificiais (RNAs) comparadas com Regressões Múltiplas (RMs) na geração de FPTs

A média, desvio padrão e valor mínimo e máximo dos atributos físicos dos horizontes superficiais e subsuperficiais dos solos coletados em 44 perfis encontram-se no Quadro 4. Estes dados foram utilizados para gerar as funções de pedotransferência do trabalho de Costa (2012), através de RMs, e do presente estudo através de RNAs, considerando a subdivisão proposta por Costa (2012) para horizontes superficiais (horizontes A e subdivisões) e subsuperficiais (horizontes B e subdivisões).

Os dados utilizados na geração de FPTs não tiveram nenhum tratamento estatístico, por isso alguns *outliers* para a PT podem ser vistos no Quadro 4. Este atributo foi obtido a partir da saturação do anel e posterior secagem em estufa. Já a PT calculada resultou em valores menores como pode ser visto na linha PT-Dp do Quadro 4.

Os teores médios de areia, silte e MO são maiores no horizonte A e apenas o teor médio de argila é maior no horizonte B. Os valores médios de retenção de água são maiores no horizonte B (0,40 a 0,50) e menores no A (0,30 a 0,43). A disponibilidade de água é semelhante em ambos os horizontes.

Quadro 4 - Valores mínimo e máximo, média e desvio padrão dos 44 solos utilizados na comparação das RNAs com as RMs.

	Mínimo	Máximo	Média	Desvio Padrão
Horizontes A+B				
Areia	11	973	225	224
Silte	12	581	256	106
Argila	15	841	518	211
MO	3	150	29	22
Ds	0,60	1,76	1,17	0,19
Dp	2,12	2,80	2,44	0,13
PT	0,27	0,91*	0,65	0,07
PT-Dp	0,26	0,74	0,54	0,08
CC10	0,12	0,77	0,46	0,10
CC33	0,10	0,75	0,44	0,11
PMP	0,04	0,66	0,35	0,11
AD10	0,04	0,26	0,11	0,03
AD33	0,02	0,22	0,09	0,03
Horizontes A				
Areia	17	973	280	273
Silte	12	581	287	136
Argila	15	789	433	226
MO	7	150	42	25
Ds	0,60	1,76	1,13	0,23
Dp	2,12	2,75	2,43	0,13
PT	0,27	0,91*	0,65	0,09
PT-Dp	0,26	0,74	0,55	0,09
CC10	0,12	0,77	0,43	0,12
CC33	0,11	0,73	0,39	0,12
PMP	0,04	0,59	0,30	0,11
AD10	0,04	0,26	0,13	0,03
AD33	0,03	0,22	0,09	0,03
Horizontes B				
Areia	11	661	178	155
Silte	73	516	230	83
Argila	184	841	591	166
MO	3	42	18	8
Ds	0,89	1,63	1,21	0,15
Dp	2,17	2,80	2,45	0,13

continua...

...conclusão

	Mínimo	Máximo	Média	Desvio Padrão
PT	0,47	0,87*	0,65	0,06
PT-Dp	0,34	0,70	0,52	0,07
CC10	0,24	0,76	0,50	0,07
CC33	0,22	0,75	0,47	0,08
PMP	0,15	0,66	0,40	0,08
AD10	0,04	0,22	0,09	0,03
AD33	0,03	0,18	0,08	0,02

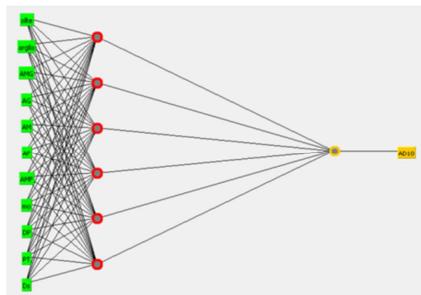
Teores de areia, silte, argila e MO em g kg^{-1} ; Ds e Dp em g cm^{-3} ; PT, CC10, CC33, PMP, AD10 e AD33 em $\text{m}^3 \text{m}^{-3}$. * Possivelmente são *outliers*.

Fonte: produção do próprio autor.

As RNAs foram construídas utilizando-se uma estrutura simples, com camada de entrada, uma camada escondida com 6 neurônios e uma camada de saída. Esta estrutura está demonstrada na Figura 15, utilizando como modelo a água disponível (AD10).

Após várias tentativas e erros, a rede foi estruturada, para todos os atributos e modelos, tendo *momentum* de 0,27, taxa de aprendizagem de 0,1 no intervalo $[0, 1]$ e número de iterações de 1.300 no intervalo $[0, \infty]$. O número de neurônios na camada escondida foi escolhido conforme sugestão de Schaap e Bouten (1996).

Figura 15 – Estrutura da RNA para estimar AD10 a partir do Modelo 7 (11 atributos de entrada), mostrando a camada de entrada, a camada escondida com os seis neurônios e a camada de saída.



Fonte: produção do próprio autor.

Atualmente, funções de pedotransferência têm sido utilizadas para estimar a CC (GIVI et al., 2004) por meio dos parâmetros de granulometria, densidade do solo, conteúdo de matéria orgânica e parâmetros da CRA. Entretanto, a precisão da maioria dessas funções não é adequada, o que dificulta a aplicabilidade para manejo correto das culturas agrícolas (BRITO et al, 2011).

Os resultados mostram que as FPTs geradas a partir de RNAs foram melhores do que as RMs para estimar os pontos da CRA, CC10, CC33 e PMP, bem como para calcular a AD10 e AD33, para todos os modelos testados (Quadro 5). Além de aumentar o coeficiente de determinação da estimativa destes atributos, reduziu a REQM para os atributos CC10, CC33 e PMP, mas praticamente não alterou a RQME da AD10 e AD33.

Quanto maior a quantidade de dados de entrada, melhor torna-se a estimativa da retenção e disponibilidade de água, quando a inclusão do novo atributo aumenta significativamente no coeficiente de determinação. Isto é observado comparando os modelos 1, 3, 5 e 7. Como exemplo, para CC10, o R^2 aumentou de 0,80 no modelo 1 para 0,93 no modelo 7.

À medida que mais atributos do solo são incorporados aos modelos, maior a contribuição deles para melhorar a estimativa dos pontos da CRA e melhor o ajuste destes pontos. Como a divisão da areia em cinco classes (Modelo 7) não melhorou o ajuste, o uso do modelo 5 é suficiente para estimar os pontos da CRA com eficiência, já que essa determinação não é uma análise comum nos laboratórios e, portanto, estes dados são disponíveis para poucos estudos ou solos.

Quadro 5 - Coeficiente de determinação (R^2) e raiz do erro quadrático médio (REQM*) das funções de pedotransferência (FPTs) obtidas por regressão múltipla (RM) do estudo de Costa (2012) e por redes neurais artificiais (RNAs) de 44 solos do Estado de SC, quando calculados para os modelos 1, 3, 5 e 7.

		Modelo 1		Modelo 3		Modelo 5		Modelo 7	
		RML	RNA	RML	RNA	RML	RNA	RML	RNA
Horizonte A+B									
CC10	R^2	0,63	0,80	0,69	0,87	0,71	0,89	0,80	0,93
	REQM	0,07	0,06	0,05	0,05	0,06	0,05	0,05	0,04
CC33	R^2	0,63	0,79	0,70	0,86	0,68	0,89	0,83	0,93
	REQM	0,07	0,06	0,06	0,05	0,06	0,05	0,05	0,04
PMP	R^2	0,69	0,83	0,74	0,90	0,74	0,91	0,87	0,94
	REQM	0,06	0,06	0,06	0,05	0,06	0,04	0,04	0,04
AD10	R^2	0,30	0,44	0,55	0,66	0,59	0,72	0,72	0,75
	REQM	0,03	0,03	0,02	0,03	0,02	0,02	0,02	0,02
AD33	R^2	0,31	0,43	0,52	0,60	0,52	0,61	0,63	0,68
	REQM	0,03	0,03	0,02	0,02	0,02	0,02	0,02	0,02
Horizonte A									
CC10	R^2	0,62	0,83	0,80	0,89	0,80	0,92	0,88	0,93
	REQM	0,08	0,06	0,05	0,05	0,05	0,05	0,04	0,04
CC33	R^2	0,62	0,84	0,78	0,90	0,80	0,93	0,88	0,94
	REQM	0,07	0,06	0,06	0,05	0,05	0,04	0,04	0,04
PMP	R^2	0,68	0,84	0,77	0,87	0,79	0,91	0,88	0,93
	REQM	0,06	0,06	0,05	0,05	0,05	0,04	0,04	0,04
AD10	R^2	0,23	0,53	0,53	0,66	0,53	0,71	0,73	0,80
	REQM	0,03	0,03	0,03	0,03	0,03	0,03	0,02	0,02
AD33	R^2	0,28	0,46	0,56	0,64	0,56	0,70	0,73	0,78
	REQM	0,03	0,03	0,02	0,02	0,02	0,02	0,02	0,02
Horizonte B									
CC10	R^2	0,69	0,70	0,69	0,78	0,72	0,87	0,89	0,89
	REQM	0,06	0,05	0,06	0,05	0,06	0,04	0,04	0,03
CC33	R^2	0,68	0,66	0,68	0,77	0,71	0,84	0,88	0,87
	REQM	0,06	0,06	0,06	0,06	0,06	0,04	0,04	0,04
PMP	R^2	0,75	0,72	0,75	0,80	0,76	0,88	0,92	0,91
	REQM	0,05	0,06	0,05	0,05	0,05	0,04	0,03	0,04
AD10	R^2	0,19	0,34	0,23	0,49	0,34	0,64	0,57	0,66
	REQM	0,02	0,03	0,02	0,02	0,02	0,02	0,01	0,02
AD33	R^2	0,19	0,34	0,19	0,53	0,25	0,53	0,48	0,55
	REQM	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02

*REQM em $m^3 m^{-3}$.

Modelo 1 – teores de areia, argila e silte;

Modelo 3 – teores de areia, argila, silte e MO;

Modelo 5 – teores de areia, argila, silte, MO, Ds, Dp e PT;

Modelo 7 – teores de areia (AMG, AG, AM, AF e AMF), argila, silte, MO, Ds, Dp, PT.

Fonte: produção do próprio autor.

5.2.1 FPTs pontuais para as CC10 e CC33

As RNAs se mostraram eficientes na geração de FPTs, mesmo com poucos atributos do solo usados como entrada. Isso demonstra uma boa generalização e aprendizagem das redes e, à medida que mais atributos são incorporados à rede, melhor é a FPT gerada.

Quando o BD foi dividido em horizontes superficiais e subsuperficiais as estimativas tiveram maior R^2 e menor REQM do que quando as estimativas foram geradas sem a separação dos horizontes. Os coeficientes de determinação das FPTs geradas a partir das RNAs foram maiores para o horizonte superficial (entre 0,80 e 0,93). A retenção e disponibilidade de água depende mais fortemente dos atributos do solo, granulometria, Ds, Dp, PT e MO, pois há maior variação destes no horizonte superficial, e essa dependência é vista no quadro 6, onde observa-se aumento do R^2 à medida que os atributos de entrada são incorporados aos modelos. Há um comportamento semelhante nos demais horizontes (A+B e B), entretanto a diferença não é tão grande e em alguns casos a correlação não é tão elevada (0,66 a 0,93).

Tanto para A quanto para B a melhora foi a mesma quando se compara RMs com RNAs, exceto para CC10, que no A teve melhora um pouco maior em relação ao B. O melhor BD é para estimar a retenção de água é formado por atributos do horizonte A.

Para a CC, que trata de um conteúdo de água atingido durante os primeiros dias de um processo dinâmico de drenagem, o fator predominante é a granulometria associada a estrutura do solo (BRITO et al, 2011), pois a estrutura de um

solo é dependente do teor de MO e também da Ds, atributos incluídos nos modelos 3, 5 e 7 (BRADY e BUCKMAN, 1989).

5.2.2 FPTs pontuais para o PMP

Para o PMP, as RNAs apresentaram maior R^2 para os quatro modelos dos horizontes A+B e B.

O modelo 1 (teores de areia, silte e argila) é adequado para estimar o PMP, já que a granulometria é preponderante para estimar este atributo, enquanto que a estrutura do solo tem menor influência na retenção de água nesse ponto (ARRUDA et al., 1987). O melhor modelo para gerar FPTs foi o composto pelos dados de entrada teores de areia, argila e silte, MO, Ds, Dp e PT (Modelo 5). Apesar de o modelo 7 ter os maiores valores de R^2 , separar a areia em cinco classes não é um procedimento realizado na maioria dos estudos que englobam os atributos físicos do solo, dificultando sua utilização, portanto não deve ser adotado como melhor resultado de FPTs. Além disso, a inclusão de cada classe de areia só deve ser feita se houver incremento significativo no ajuste do modelo. Os coeficientes de determinação das FPTs geradas a partir das RNAs foram maiores para o horizonte A+B (entre 0,83 e 0,94).

Reichert et al. (2010) encontraram que os conteúdos de argila, silte e MO apresentaram correlação positiva com o conteúdo de água no PMP. Koekkoek e Bootink (1999) encontraram que para RNA com dados de entrada do modelo 3, o R^2 variou de 0,80 a 0,93 para os potenciais 0, -100 e -15.000 kPa e REQM de 0,02 até 0,05 $m^3 m^{-3}$, concordando com os resultados obtidos pelas RNAs deste trabalho.

Oliveira et al. (2002) encontraram R^2 de 0,96 para FPTs que estimam o PMP através de RM de solos do Pernambuco utilizando a granulometria e Ds, considerando as frações areia e argila conjuntamente, mas o modelo proposto superestima a retenção de água nesta tensão.

5.2.3 FPTs pontuais para as AD10 e AD33

O melhor BD para estimar a disponibilidade de água é formado por atributos do horizonte A onde há correlação da AD com o teor de argila (Quadro 3). Assim, mesmo incorporando-se outros atributos, além da granulometria, não há melhora significativa nesta estimativa. Outro ponto a se considerar é que, neste horizonte, o teor de argila não varia como nos demais (Quadro 4). Comparando-se o R^2 da FPT que estima a AD obtida por RML (entre 0,19 e 0,57) com RNA (entre 0,34 e 0,66), o resultado melhorou significativamente no horizonte B.

As FPTs geradas para estimar a AD foram as que apresentaram menor R^2 e, portanto, apresentando equações preditivas de baixa confiabilidade (Quadro 5). Esta variável é uma consequência direta do conteúdos de água no solo na CC e PMP e valores anômalos ou erros nas variáveis principais contribuem para obtenção de baixos índices de correlação (NASCIMENTO et al., 2010). Provavelmente a grande variabilidade dos dados é responsável pela melhor estimativa no horizonte A, já que este horizonte está mais sujeito às alterações causadas pela chuva e/ou irrigação, evaporação, mobilização do solo, etc. Por isso o aumento da dependência da retenção e disponibilidade de água neste horizonte.

No horizonte B há uma menor variabilidade devido à maior homogeneidade e menor influência de fatores como chuva, evaporação e infiltração da água. Isso resultou em menor dependência da retenção e disponibilidade de água com os atributos do solo.

O horizonte A+B corresponde ao uso de todos os horizontes amostrados nos perfis estudados, não correspondendo a uma média dos resultados dos horizontes A e B separadamente (Quadro 5). A retenção e disponibilidade de água é influenciada pelo perfil como um todo, considerando-se o efeito da estrutura de todo o perfil na distribuição de água, seu

movimento até o equilíbrio, sendo redistribuída no mesmo. Conforme Hillel (1980), há redução na transmissão de água durante seu processo de drenagem, pois o espaço poroso que antes continha água vai sendo ocupado por ar, os maiores poros são esvaziados primeiro, e a água fica retida e descontínua em diversos poros do solo, dificultando ainda mais o fluxo.

Lakzian et al. (2010) encontraram que FPTs geradas a partir de RNAs têm fornecido resultados que no mínimo são tão bons quanto outras técnicas conhecidas. Entretanto, na escolha desta técnica alguns problemas encontrados no desenvolvimento dessas funções devem ser considerados: os pesos, que não permitem fácil interpretação física (SCHAAP et al., 2001); a estrutura da RNA deve ser escolhida *a priori* e assim pode não ser ótima porque há muitos tipos de neurônios e muitos tipos possíveis de conexões (WÖSTEN et al., 2001); e finalmente, não existe segurança de que o algoritmo de aprendizado escolhido encontrará pesos que minimizem os erros (LAKZIAN et al., 2010).

5.2.4 Uso ótimo das RNAs na geração das FPTs

Uma RNA pode ser construída contendo mais de uma camada escondida, tornando-a uma rede complexa, que se ajusta aos dados com maior precisão. Qualquer modelo, por mais complexo que seja, pode ser descrito matematicamente, porém, sem nenhuma explicação física do processo. O ideal é que os modelos com estrutura mais simples da rede de uma RNA possam fornecer o melhor ajuste, pois o processo pode ser mais facilmente explicado fisicamente. De acordo com Gershenfeld (1999), uma RNA com uma camada escondida que tenha nós suficientes, pode descrever qualquer função contínua.

Por isso, estruturas de rede complexas foram descartadas, pois não possibilitam explicação física dos processos, e apenas o modelo padrão (camada de entrada –

camada escondida – camada de saída) foi escolhido em todas as análises.

Os modelos 5 e 7, utilizados no capítulo anterior, forneceram os melhores resultados para as FPTs geradas a partir de RNAs. Como no Brasil não é comum a separação da areia em cinco classes, os modelos foram reajustados neste capítulo de forma a fornecer resultados superiores àqueles vistos anteriormente sem, no entanto, incluir atributos pouco analisados. Além disso, a análise de correlação entre os atributos do solo e a retenção e disponibilidade de água também foram determinantes nas escolhas dos modelos.

De acordo com Lake et al. (2009) e Amini et al. (2005), o aumento do número de entradas da rede diminui a precisão das estimativas. Se ao predizer um atributo do solo algum dos atributos de entrada tem baixa correlação com o atributo de saída, a precisão do modelo automaticamente diminui. Por isso a inclusão de um atributo não deve ser aleatória. Cada um individualmente deve apresentar boa correlação com o fenômeno a ser estudado e apresentar um comportamento dentro de uma lógica física/química/biológica.

Deste modo, foram selecionados os modelos RNA1 e RNA2 descritos abaixo e as RNAs foram construídas utilizando-se uma estrutura simples conforme descrito no item 5.2.

Modelo RNA1 – Teores de Silte, Argila, Classe Areia Fina e Grossa, MO, Ds e Dp.

Modelo RNA2 – Teores de Silte, Argila, Classe Areia Fina, MO, Ds, PT e microporosidade.

Koekkoek e Bootink (1999) desenvolveram uma RNA que teve como entrada dados de tensão de água, mas concluíram que a melhora da estimativa gerada pela rede não foi significativa se comparada com RMs. Com base nos resultados obtidos nestes trabalhos (SCHAAP e LEIJ, 1998; SCHAAP et al., 1998; KOEKKOEK e BOOLTINK, 1999; MINASNY et al., 2004; SARMADIAN e MEHRJARDI, 2008;

SARMADIAN et al., 2009) foi testado no presente estudo a inclusão da PT e da microporosidade como entradas da rede. A utilização de mais variáveis na entrada da rede pode melhorar a predição, mas modelos mais simples podem ser mais úteis quando, por exemplo, apenas a granulometria do solo é conhecida.

Gupta e Larson (1979) afirmaram que a diferença em retenção de água correspondente a dois pontos da CRA (AD) pode ser predita a partir de atributos texturais e estruturais. Salter et al. (1966) investigaram quantitativamente a influência da granulometria sobre a retenção de água dos solos, a partir da possível correlação entre esta e teores de MO com a AD desses solos.

Salter et al. (1966) afirmaram que dificilmente seria obtido um método extremamente preciso de predição da AD de um solo, baseado apenas na sua composição textural, exceto se algum método quantitativo para a medição dos efeitos da estrutura possa ser obtido, o que possibilitaria a incorporação deste atributo. Este fato enfatiza a necessidade de incluir nos modelos, para o aumento da precisão, fatores como estrutura, MO, microagregação e mineralogia da fração argila.

Nenhum dos modelos propostos no item anterior forneceu bom ajuste para AD33. Os atributos de entrada não foram suficientes para explicar o conteúdo de água disponível no intervalo entre 33 e 1.500 kPa. Quando incluídos todos os horizontes, o REQM foi de $0,02 \text{ m}^3 \text{m}^{-3}$ e o R^2 foi de 0,68. Costa (2012) obteve para esses parâmetros os valores de $0,02 \text{ m}^3 \text{m}^{-3}$ e 0,63 usando como dados de entrada os teores das cinco classes de areia, silte, argila, densidade do solo e de partícula e porosidade total.

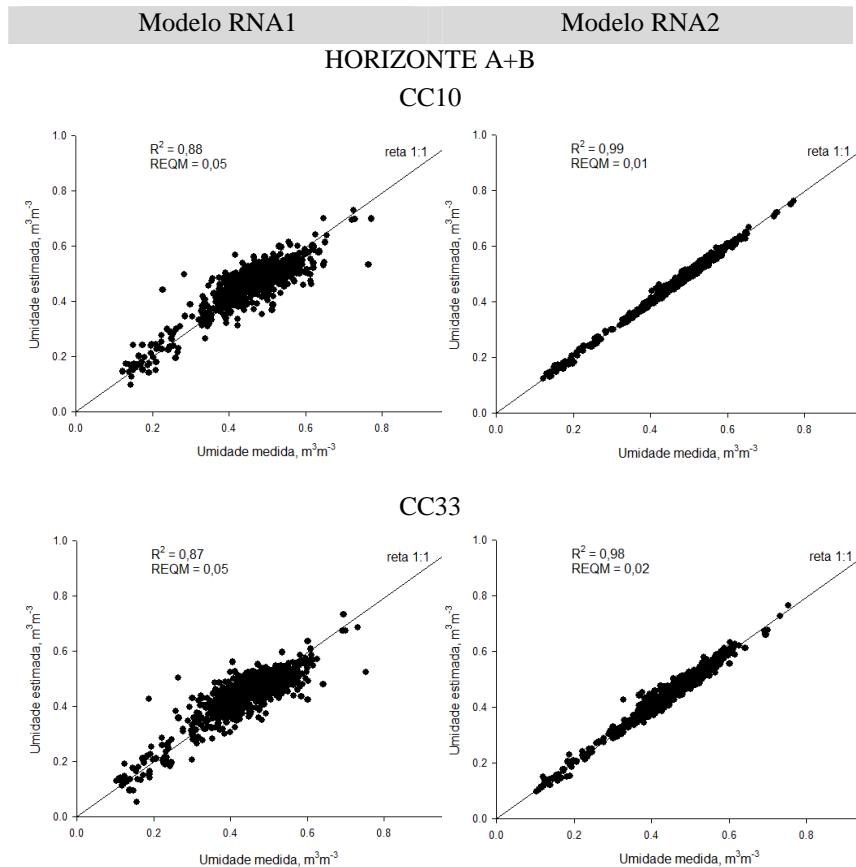
A AD teve baixa correlação com os atributos do solo (Quadro 3), exceto com o teor de silte e de MO. O modelo RNA2 que utilizou a granulometria e a microporosidade apresentou uma correlação maior para estimar a AD ($R^2=0,74$ para AD10 e 0,68 para AD33).

Comparando-se os resultados obtidos para AD utilizando-se o BD A+B com o BD A os resultados não variaram, exceto para AD33 no modelo RNA1, sugerindo que a influência da MO, Ds e Dp é maior no horizonte superficial, já que neste o teor médio de MO é maior e a Ds e a Dp são menores (Quadro 2). A correlação entre AD e os teores de MO e silte é significativa (Quadro 3), deste modo é de se esperar que uma variação nestes atributos afete o R^2 .

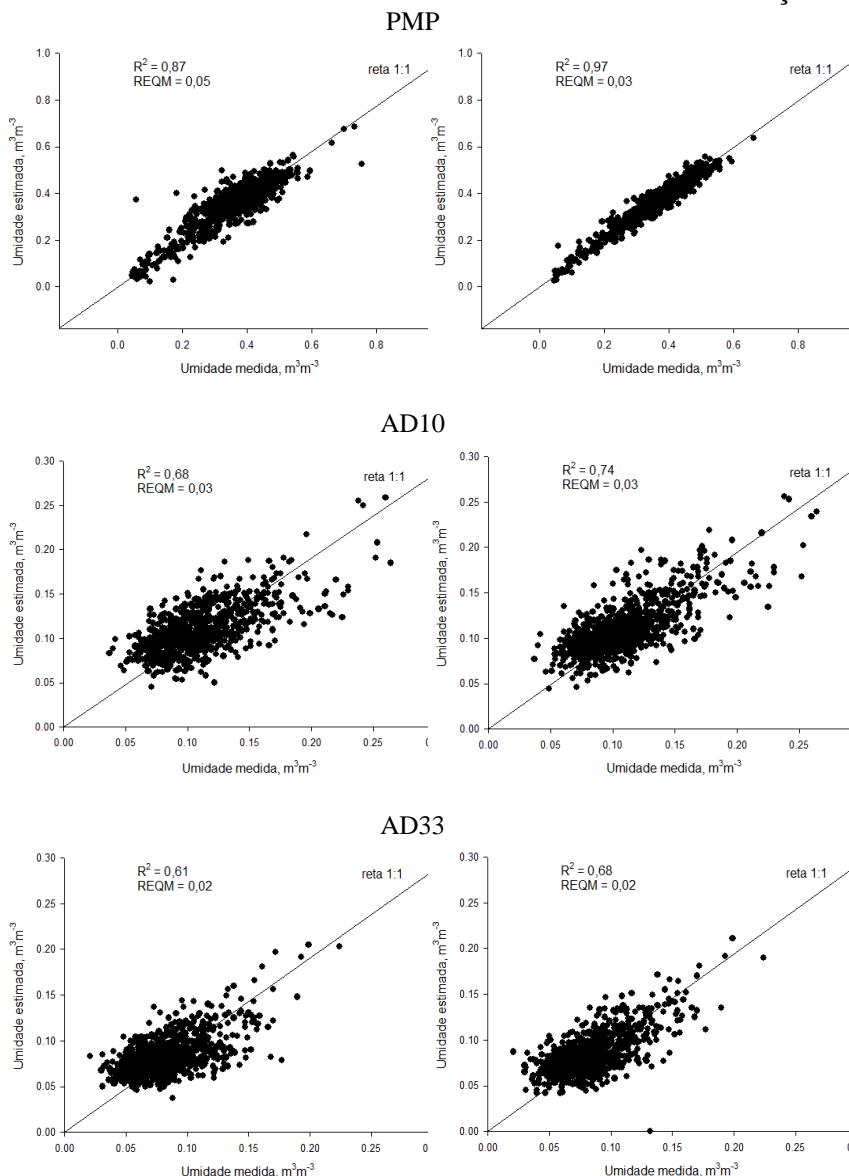
Para os demais pontos da CRA, a RNA gerada a partir dos dados de entrada, que foram selecionados a partir da análise de correlação destes atributos, geraram uma FPT mais eficiente que aquelas geradas a partir dos modelos do item 6.2 e também melhores que aquelas geradas a partir de RMs (Figura 16). Merdun et al. (2006) encontraram que FPTs foram melhores utilizando-se RMs ao invés de RNAs, mas sem diferença significativa. Em seu trabalho, que visa estimar o PMP e a AD de 276 amostras de solo no Planalto de Erzincan, Turquia, os autores encontraram que o R^2 e a REQM variaram de 0,75 a 0,95 e de 0,02 a 0,04 $m^3 m^{-3}$ para RNAs e de 0,90 a 0,98 e de 0,02 a 0,03 $m^3 m^{-3}$ para RMs, respectivamente.

A partir dos dados observados, o modelo RNA2, com mais dados de entrada, estima com maior precisão a retenção de água na CC e no PMP e também a AD em relação ao modelo RNA1. Esta melhor estimativa pode ser visualizada na Figura 16, principalmente para CC e PMP.

Figura 16 – Gráficos de dispersão da umidade medida em laboratório *versus* a umidade estimada pelos modelos RNA1 e RNA2 para a capacidade de campo a 10 kPa (CC10) e 33 kPa (CC33), ponto de murcha permanente a 1.500 kPa (PMP) e água disponível a 10 e 33 kPa (AD10 e AD33) de 57 solos do estado de SC.



...continuação

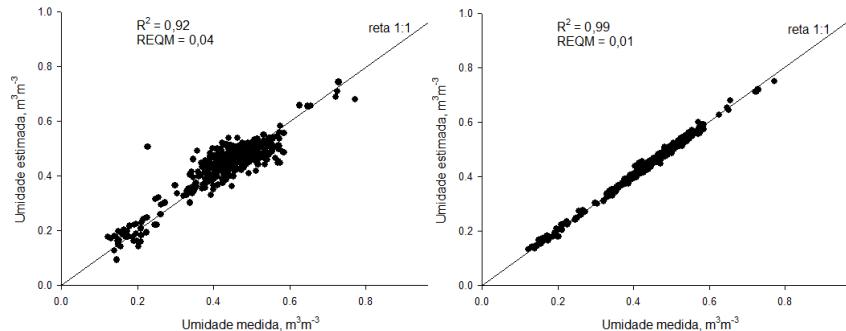


Continua...

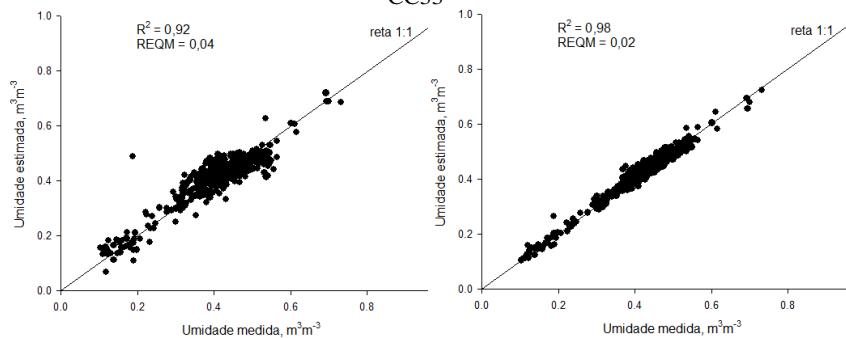
...continuação

MODELO RNA1

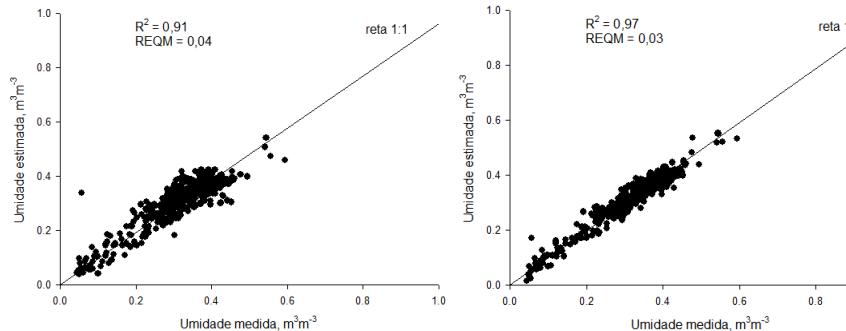
MODELO RNA2

HORIZONTE A
CC10

CC33

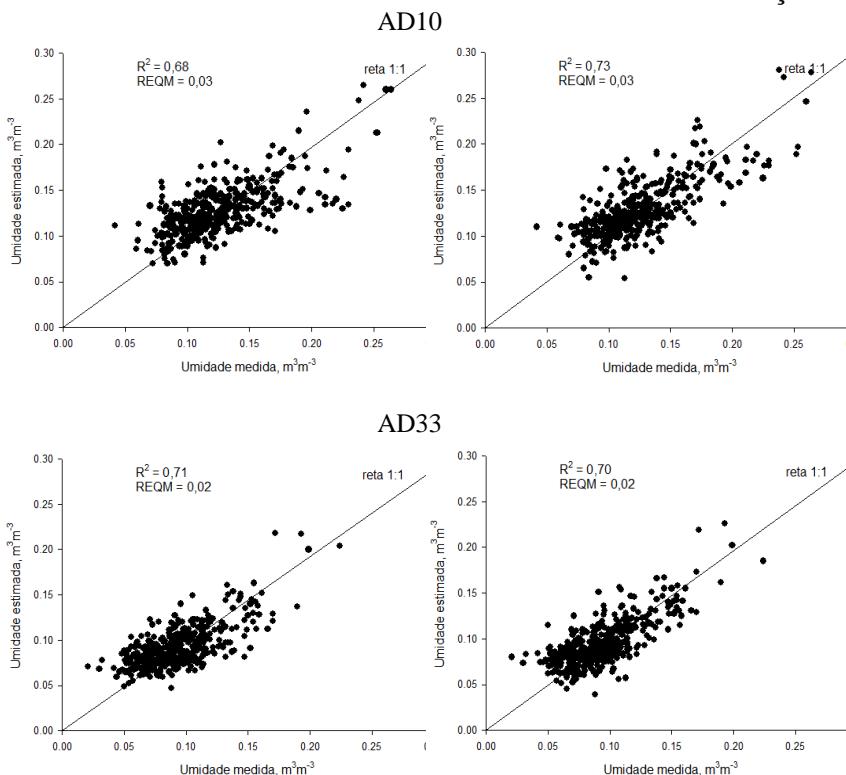


PMP



Continua...

...continuação

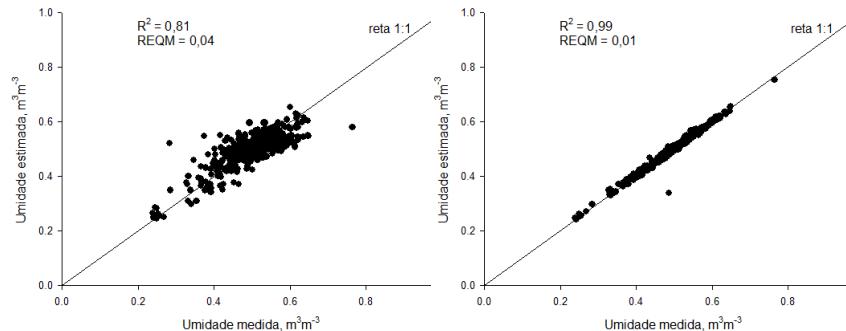


Continua...

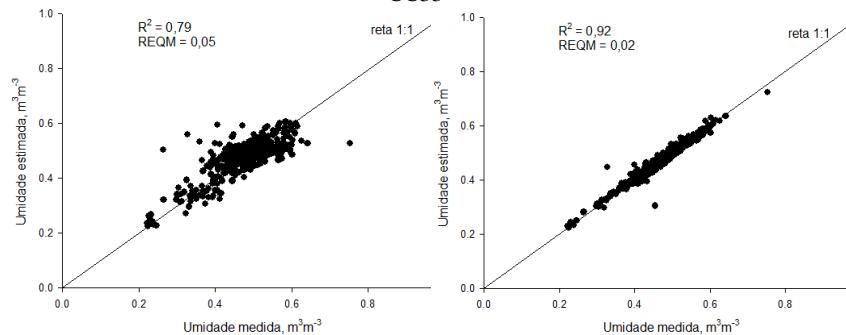
...continuação

MODELO RNA1

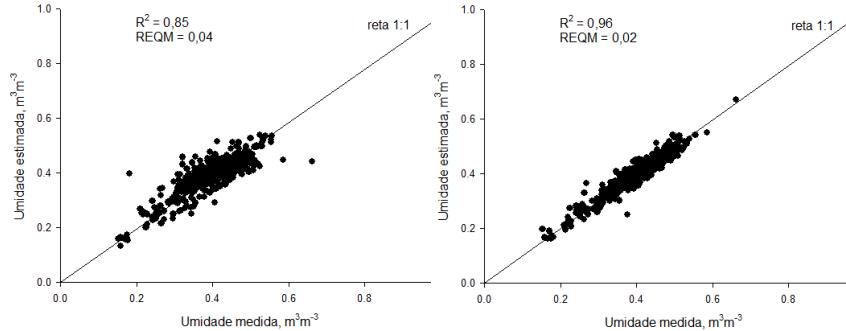
MODELO RNA2

HORIZONTE B
CC10

CC33

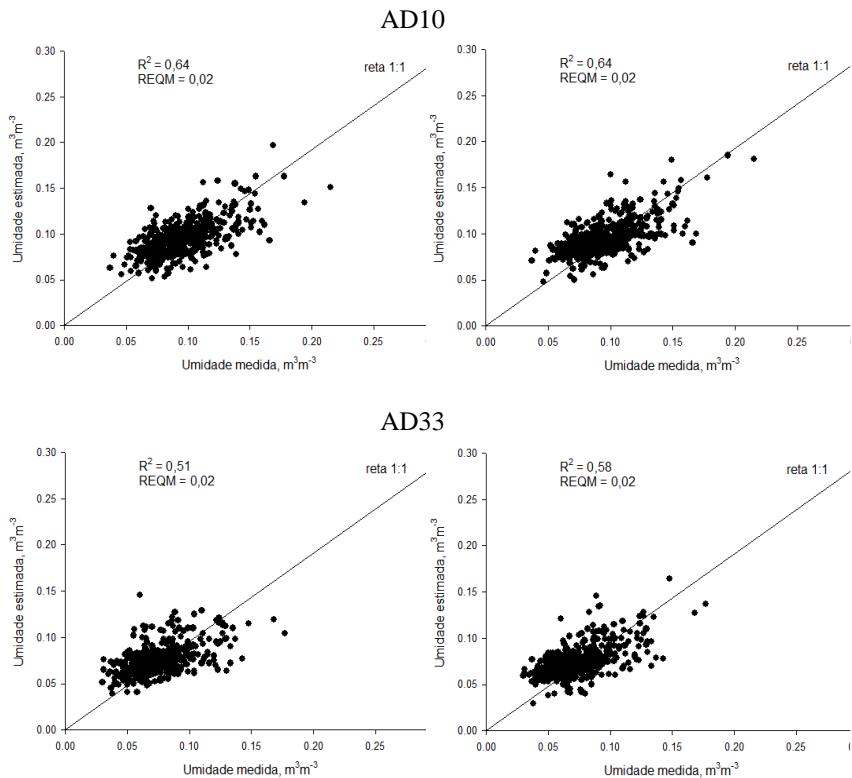


PMP



Continua...

...conclusão



Modelo RNA1 – Teores de Silte, Argila, Classe Areia Fina e Grossa, MO, Ds e Dp.

Modelo RNA2 – Teores de Silte, Argila, Classe Areia Fina, MO, Ds, PT e microporosidade.

Fonte: produção do próprio autor.

Portanto, os resultados do presente estudo sugerem que as FPTs desenvolvidas a partir de RNAs dos modelos RNA1 e RNA2 podem substituir as RMs. Como exemplo, para o PMP estimado para o horizonte A, o R^2 e a $REQM$ variaram para os modelos RNA1 e RNA2, respectivamente de 0,91 a 0,97 e de 0,03 a 0,04 $m^3 m^{-3}$. Sarmadian e Keshavarzi (2010), usando teores de silte, argila, MO, $CaCO_3$, Ds e percentagem da

saturação de água como dados de entrada de uma RNA, encontraram que a REQM e o R^2 para CC e PMP foram respectivamente de $0,02\text{ m}^3\text{m}^{-3}$ e $0,77$ e $0,03\text{ m}^3\text{m}^{-3}$ e $0,72$.

A estimativa do PMP foi maior para o BD A+B, e reduziu com a separação em BD A e BD B, sendo maior no BD A. Isso pode ser devido à elevada correlação entre o PMP e os teores de MO e de argila, que tem maior amplitude no BD A. Como exemplo, observa-se que o teor de MO varia de 7 a 150 g kg⁻¹ no horizonte A e de 3 a 76 g kg⁻¹ no horizonte B (Quadro 2). Para o teor de argila, varia de 15 a 789 g kg⁻¹ no horizonte A e de 184 a 841 no horizonte B (Quadro 2). Esta variação afeta a retenção de água no solo.

Os pesos gerados a partir destas RNAs estão no apêndice B. Uma breve metodologia do cálculo da FPT gerada também encontra-se neste apêndice.

Apesar de não ser significativa a correlação da Dp com a retenção de água, existe uma baixa correlação com a disponibilidade de água, por isso foi inserido esse atributo no modelo RNA1.

6 CONCLUSÕES

1. A retenção de água nos solos tem baixa correlação com a densidade de partículas. A capacidade de campo e o ponto de murcha permanente tiveram correlação com os teores de areia, silte, argila, matéria orgânica, porosidade total e densidade do solo. A disponibilidade de água teve correlação com os teores de silte e matéria orgânica, entretanto esta correlação é baixa.

2. As FPTs geradas a partir de RNAs são mais eficientes do que as RMs para estimar a retenção de água na capacidade de campo e no ponto de murcha permanente e o teor de água disponível. Esta maior eficiência é observada principalmente nos modelos com menor quantidade de dados de entrada. A separação do banco de dados melhora a estimativa do teor de água disponível para o banco de dados do horizonte A, mas modifica pouco a estimativa para a retenção de água na capacidade de campo e no ponto de murcha permanente. Para estimar a disponibilidade de água devem ser utilizadas as FPTs pontuais que utilizam as cinco classes de areia, silte, argila, a matéria orgânica, a densidade do solo e de partículas e a porosidade total.

3. Comparando o modelo 5 (teores de areia, argila, silte, MO, Ds, Dp e PT) com o modelo RNA1 (teores de Silte, Argila, Classe Areia Fina e Grossa, MO, Ds e Dp) observa-se que o aumento do banco de dados melhora a estimativa da retenção e da disponibilidade de água. Entretanto, a escolha dos dados de entrada é mais importante. Por exemplo, a inclusão de um ou mais pontos da curva de retenção (porosidade total e microporosidade) melhora um pouco a estimativa da disponibilidade de água e de forma mais clara a estimativa da retenção de água. Nesta caso a divisão do banco de dados em horizontes não aumenta a precisão da estimativa.

7 CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo comparar e gerar FPTs a partir de Redes Neurais utilizando um banco de dados de solos de Santa Catarina. Entretanto, pelos resultados obtidos, sugere-se que se remova *outliers* para geração dessas funções; que se utilize um banco de dados que possuam correlação alta com os atributos a serem estimados; que sejam geradas funções a partir de um banco de dados que separe os dados por classes texturais de solo; testar estruturas de redes para desenvolver um modelo que sirva para solos catarinenses; testar outros atributos físicos, químicos e mineralógicos para estimar a água disponível.

A partir desses resultados é possível desenvolver um programa que forneça o conteúdo de água num solo a partir de outros atributos do solo, a partir da função gerada pela RNA.

REFERÊNCIAS BIBLIOGRÁFICAS

ABROL, L.P.; KHOSTA, B.K.; BHUMBOLA, D.R. Relationship of texture to some important soil moisture contents. **Geoderma** 2:33-38, 1968.

ALMEIDA, J.A.; KÄMPF, N.; ALMEIDA, R. Caracterização mineralógica de Cambissolos originados de rochas pelíticas nos patamares do alto rio Itajaí e no planalto de Lages. **Revista Brasileira de Ciência do Solo**, 21:181-190, 1997.

ALMEIDA, J.A. ; MAÇANEIRO, K.C.; KLAMT, E. Mineralogia da fração argila de solos vermelhos com horizontes superficiais brunados do Planalto de Lages, SC. **Revista Brasileira de Ciência do Solo**, 24:815-828, 2000.

ALMEIDA, J.A.; TORRENT, J.; BARRÓN, V. Cor, formas do fósforo e adsorção de fosfatos em Latossolos desenvolvidos de basalto do extremo sul do Brasil. **Revista Brasileira de Ciência do Solo**, 27:985-1002, 2003.

AMINI, M.; ABBASPOUR, K.C.; KADEMI, H.; FATHIANPOUR, N. AFYUNI, M.; SCHULIN, R. Neural network models to predict cation exchange capacity in arid regions of Iran. **European Journal of Soil Science**, 53:748-757, 2005.

ANGELOTTI NETO, A. A estimativa da retenção de água no solo a partir do uso de equipamentos não convencionais, redes neurais artificiais e funções de pedotransferência. São Carlos, Escola de Engenharia de São Carlos da Universidade de São Paulo, 2007. 167p. (Tese de Doutorado).

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

ASCE - American Society of Civil Engineers. Criteria for evaluation of watershed models. **Journal of Irrigation and Drainage Engineering**, 119:429-442, 2000.

BARRETO, J.M. Introdução às redes neurais artificiais.
Florianópolis: UFSC, 2002. 57p.

BIRIKUNDAVYI, S.; LABIB, R.; TRUNG, H.T.; ROISSELLE, J. Performance of neural networks in daily streamflowforecasting. **Journal of Hydrologic Engineering**, 7(5):392-398, 2002.

BONFATTI, B.R. Geotecnologias aplicadas ao levantamento de solos e da aptidão agrícola da Microrregião Lajeado dos

Mineiros, São José do Cerrito, SC. Lages, Universidade do Estado de Santa Catarina, 2012. 136p. (Dissertação Mestrado).

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

BOUMA, J; van LANEN, J.A.J. Tranfer functions and threshold values, from soil characteristics to land qualities. In: Beek, K.J. (Ed). Quantified land evaluation. Enschede, The Netherlands, 6:106-110, ITC. **International Institute of Aerospace Survey and Earth Science**, 1987.

BRADY, N.C. **The Nature and Properties of Soils**. 9th ed. Macmillan Publishing Company. New York, 1984. 621p.

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

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

BRINGHENTI, I. **Mineralogia e gênese dos solos das serras litorâneas do norte catarinense**. Lages, Universidade do

Estado de Santa Catarina, 2010. 110p. (Dissertação de Mestrado).

BRITO, A.S.; LIBARDI, P.L; MOTA, J.C.A; MORAES, S.O. Estimativa da capacidade de campo pela curva de retenção e pela densidade de fluxo da água. **Revista Brasileira de Ciência do Solo**, Viçosa , 35(6). Disponível em : http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-06832011000600010&lng=en&nrm=iso. Acesso em 9 dez. 2014.

BROOKS, R.H.; COREY,A.T. Hydraulic properties of porous medium. **Hydrology paper** No.3, Civ. Engrg. Dept. Colorado State Univ., Fort Collins, Colo. 1964.

BUCKINGHAM, E. Studies on the movement of soil moisture, influence and connections. **Reviews of Geophysics**, 37:151–172. Bulletin 38. USDA Bureau of Soils, Washington, DC. 1907.

CÂMARA, V.R. **Rede neural para identificação do sexo de bovinos a partir de ressonância magnética nuclear de carnes**. São Carlos, Centro Universitário Central Paulista, 2006. 30p. (Monografia).

GERSHENFELD, N. The Nature of Mathematical Modelling. Cambridge University Press, Cambridge. 1999. 344p.

CORRÊA, J. Mineralogia e gênese das principais classes de solos de encostas basálticas do estado de Santa Catarina. Lages, Universidade do Estado de Santa Catarina, 2003. 110p. (Dissertação de Mestrado).

COSTA, A. Retenção e disponibilidade de água em solos de Santa Catarina: Avaliação e geração de funções de pedotransferência. Lages, Universidade do Estado de Santa Catarina, 2012. 423p. (Tese de Doutorado)

COSTA, F.S. Propriedades físicas e produtividade de culturas de um Latossolo Bruno sob sistemas de manejo do solo em experimentos de longa duração. Lages, Universidade do Estado de Santa Catarina, 2001. 98p. (Dissertação de Mestrado).

COSTA, A.; ALBUQUERQUE, J.A; ALMEIDA, J.A; COSTA, A.; LUCIANO, R.V. Pedotransfer functions to estimate retention and availability of water in soils of the state of Santa Catarina, Brazil. **Revista Brasileira de Ciência do Solo.** 37:889-910, 2013.

DALMAGO, G.A. **Dinâmica da água no solo em cultivo de milho sob plantio direto e preparo convencional**. Porto Alegre, Universidade Federal do Rio Grande do Sul, 2004. 219p. (Tese de Doutorado).

DAWSON, C. W.; WILBY, R. An artificial neural network approach to rainfall-runoff modelling. **Hydrology Science Journal**, 43(1):47-66, 1998.

DEMUTH, H.; BEALE, M. **Neural networks toolbox user's guide** - MATLAB. Versão 3.0. 1998. 371p.

EFRON, B.; TIBSHIRANI, R.J. **An introduction to the bootstrap**. Monographson statistics and applied probability. Chapman & Hall, London. 1993. 257p.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. Brasília, Embrapa Produção de Informação, Rio de Janeiro, Embrapa Solos. 1997. 212p.

EPEBINU, O.; NWADIALO, B. Predicting soil water availability from texture and organic matter content for Nigerian soils. **Communications in Soil Science and Plant Analysis**, 24(7:8):633-640, 1993.

FARREL.D.A.; LARSON,W.E. Modelling the pore structure of porous media. **Water Resource Research**, 3:699-706, 1972.

FERREIRA, E.J. **Abordagem genética para seleção de um conjunto reduzido de características para construção de ensembles de redes neurais: aplicação à língua eletrônica.** São Carlos, Escola de Engenharia de São Carlos, Universidade de São Paulo, 2005. p. (Dissertação de Mestrado).

FERREIRA, É.R.N.C. **Caracterização física e química de solos desenvolvidos de rochas alcalinas e ultrabásicas do Domo de Lages, SC.** Lages, Universidade do Estado de Santa Catarina, 2010. p. (dados não publicados). (Tese de Doutorado).

FREDLUNG.D.G.; XING,A. Equations for the soil the soil-water characteristic curve. **Canadian Geotechnical Journal**, 31:533-546, 1994.

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. 246p.

GARDNER, W.R. Some steady state solutions of the unsaturated moisture flow equation with application to evaporation from a water table. **Soil Science**, 8.5(4):228-232, 1958.

GEE, G. W.; BAUDER, J. W. Particle-size Analysis. In: BLACK, C.A. eds. **Methods of soil analysis**. Madison, part 1, American Society of Agronomy. 9:383-411, 1986.

GIVI, J.; PRASHER, S.O.; PATEL, R.M. Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. **Agricultural Water Management**, 70:83-96, 2004.

GOVINDARAJU, R.S.; RAO, A.R. **Artificial neural networks in hydrology**. Kluwer Academic, Dordrecht, The Netherlands. 2000. 332p.

GUBIANI, P.I; REINERT, D.J.; REICHERT, J.M. Método alternativo para a determinação da densidade de partículas do solo - exatidão, precisão e tempo de processamento. **Ciência Rural**, Santa Maria, 36(2):664-668, 2006.

GUPTA, S.C.; LARSON, W.E. Estimating soil water retention characteristics from particle size distribution, organic matter

percent, and bulk density. **Water Resource Research**, 15:1633-1635, 1979.

HAYKIN, S. **Neural Networks**: A comprehensive foundation. 2º ed. Prentice Hall, New Jersey. 1999. 842p.

HECHT-NIELSEN, R. **Neurocomputing**. Addison-Wesley, Reading, M.A. 1990. 433p.

HILLEL, D. **Fundamentals of soil physics**. New York, Academic Press, 1980. 413p.

HOCHREITER, S; SCHMIDHUBER, J. Long Short-Term Memory, **Neural Computation**, Vol 9 (8), pp: 1735-1780. 1997. In : ORR, G. Neural Networks. Lectures Notes. Willamete University. 1999. Disponível em: <<http://www.willamette.edu/~gorr/classes/cs449/intro.html>>. Acessado em 17 Jun, 2014.

HSU, K.L.; GUPTA, H.V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. **Water Resource Research**, 31(10):2517-2530, 1995.

HUSH, D.R.; HORNE, B.G. Progress in supervised neural networks. **IEEE Signal Processing Magazine**, 10(1):103-39. 1993.

JAIN, S.K.; DAS, A.; SRIVASTAVA, D.K. Application of ANN for reservoir inflow prediction and operation. **Journal of Water Resource Planning and Management**, 125(5):263-271, 1999.

JAIN, A.; KUMAR, A. An evaluation of artificial neural network technique for the determination of infiltration model parameters. **Applied Soft Computing**, 6: 272-282, 2006.

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

KOVÁCS, Z.L. **Redes Neurais Artificiais**: fundamentos e aplicações. São Paulo, Editora Acadêmica, 1996. 163p.

KUMAR, M.; RAGHUVANSHI, N.S.; SINGH, R.; WALLENDER, W.W.; PRUITT, W.O. Estimating evapotranspiration using artificial neural network. **Journal of Irrigation and Drainage Engineering**, 128(4), 224-233, 2002.

LAKE, H.R; AKBARZADEH, A.; TAGHIZADEH MEHRJARDI, R. Development of pedotransfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zone of Caspian Sea, **Journal of Ecology and Natural Environment**, 1(7):160-172, 2009.

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

MARCOLIN, C.D. **Uso de funções de pedotransferência entre atributos físicos de solos sob plantio direto**. Passo Fundo: Universidade de Passo Fundo, 2009. 187p. (Tese Doutorado).

MARCOS, Z.Z. **Estrutura, agregação e água do solo**. Piracicaba, ESALQ, 1968. 55p. (Tese de Doutorado).

MARTORANO, L.G.; BERGAMASCHI, H.; DALMAGO, G.A.; FARIA, R.T.; MIELNICZUK, J.; COMIRAN, F. Indicadores da condição hídrica do solo com soja em plantio direto e preparo convencional. **Revista Brasileira Engenharia Agrícola Ambiental**, 13:397-405, 2009.

MASUTI, M.M. Caracterização da água disponível a partir de parâmetros físico-hídricos em solos da zona da mata do estado de Pernambuco. Recife, Universidade Federal Rural de Pernambuco. 1997. 69p. (Dissertação de Mestrado).

McKEE,C.R.; BUMB, A.C. The importance of unsaturated flow parameters in designing a monitoring system for hazardous wastes and environmental emergencies.
Proceedings of Hazardous Materials Control Research Institute, 50-58p, 1984.

MCKEE, C.R; BUMB, A.C. Flow-testing coalbed methane production wells in the presence of water and gas. **SPE Formation Evaluation**. Dec, 599-608p, 1987.

MEDINA, H.P.; GROHMANN, F. Características de umidade dos principais solos do Estado de São Paulo. **Bragantia**, 21:285-295, 1962.

MERDUN, H; ÇINAR, Ö; MERAL, R.; APAN, M. Comparison of artificial neural network and regression pedotranfer functions for prediction of soil water retention and saturated hydraulic conductivity. **Soil & Tillage Research**, 90:108-116, 2006.

MEYER, P.D.; GEE, G.W. Flux-based estimation of field capacity. **Journal of Geotechnical and Geoenvironmental Engineering**, 125:595-599, 1999.

MICHELON, C.J.; CARLESSO, R.; OLIVEIRA, Z.B.; KNIES, A.E.; PETRY, M.T.; MARTINS, J.D. Funções de pedotransferência para estimativa da retenção de água em alguns solos do Rio Grande do Sul. **Ciência Rural**, Santa Maria, 40(4):848-853, 2010.

MINASNY, B. **Efficient methods for predicting soil hydraulic properties**. University of Sydney. Land, Water & Crop Sciences. 2006. 352p. (Tese de Doutorado).

MINASNY, B.; HARTEMINK, A. Predicting soil properties in the tropics. **Earth-Science Reviews**, 106(1-2):52-62, 2011.

MINASNY, B.; McBRATNEY, A.B. Theneuro-*m* methods for fitting neural network parametric pedotransferfunctions. **Soil Science Society of America Journal**, 66:352-361, 2002.

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

MINASNY, B.; HOPMANS, J.W.; HARTER, T. ; ECHING, S.O.; TULI, A.; DENTON, M.A. Neural networks prediction of soil hydraulic functions for alluvial soils using multistep outflow data. **Soil Science Society of America Journal**, 68:417–429, 2004.

MINNS, A.W.; HALL, M.J. Artificial neural networks as rainfall-runoff models. **Hydrology Science Journal**, 41(3):399–417, 1996.

NAJAFI, M.; GIVI, J. Evaluation of prediction of bulk density by artificial neural network and PTFs. **10th Iranian Soil Science Congress**. Karaj. 680-681. 2006.

NASCIMENTO, G.B.; ANJOS, L.H.C.; PEREIRA, M.G.; FONTANA, A.; SANTOS, H.G. Funções de pedotransferência do conteúdo de água em Latossolos Amarelos e Argissolos Amarelos. **Revista Brasileira de Ciências Agrárias**, Recife, 5(4):560-569, 2010.

OLIVEIRA, L.F.C.; SARVASI, F.O.C. Determinação da curva de retenção de umidade de um latossolo vermelho-escurinho da região de Alfenas por tensiometria. **Ciência e Agrotecnologia**, 21:91-95, 1997.

OLIVEIRA, L.B; RIBEIRO, M.R.; JACOMINE, P.K.T. ; RODRIGUES, J.J.V.; MARQUES, F.A.. Funções de pedotransferência para predição da umidade retida a potenciais específicos em solos do estado de Pernambuco. **Revista Brasileira de Ciência do Solo**, 26(2):315-323, 2002.

OLIVEIRA, L.C. **Erosão hídrica e alguns processos hidrológicos em plantio de Pinus, mata e campo nativos e estrada florestal**. Lages, Universidade do Estado de Santa Catarina, 2012. 93p. (Tese de Doutorado)

ORR, G. Neural Networks. Lectures Notes. Willamete University. 1999. Disponível em: <<http://www.willamette.edu/~gorr/classes/cs449/intro.html>>. Acessado em 17 Jun, 2014.

PACHEPSKY, Y.A.; TIMLIN, A.D. Neural networks to estimate transport phenomena in soils, Agronomy Abstract, **American Society of Agronomy**, Madison, WI, 239p, 1994.

PACHEPSKY, Y.A.; RAWLS, W.J. (eds.). Development of pedotransfer functions in soil hydrology. Amsterdam, **Elsevier**, 30:1-512, 2004.

PACHEPSKY, Y.A.; TIMLIN, A.D.; VARALLYAY, G. Artificial neural networks to estimate soil water retention from

easily measurable data. **Soil Science Society of American Journal**, 60:727-733, 1996.

PAES SOBRINHO, J.B.; ALMEIDA, J.A.; ERHART, J. Mineralogia, propriedades químicas e classificação de solos das Serras do Leste Catarinense. **Revista Ciência Agroveterinária**, 8:9-24, 2009.

PORTELA, J.C.; LIBARDI, P.L.; VAN LIER, Q.J. Retenção da água em solo sob diferentes usos no ecossistema tabuleiros costeiros. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande , v.5, n.1, Abr. 2001. Disponível em:<http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662001000100009&lng=en&nrm=iso>. Acesso em 15 Dec. 2013.

RAMAN, H.; SUNILKUMAR, N. Multivariate Modelling of Water Resources Using Artificial Neural Networks. **Hydrological Sciences**, 40(2):145-163, 1995.

RAWLS, W.J.; BRAKENSIEK, D.L. **Prediction of soil water properties for hydrologic modeling**. In: JONES, E.; WARD, T.J. (eds.): Watershed Management in the Eighties. Proc. Symposium of Irrigation and Drainage Division ASCE, Denver, ASCE, New York. 1985.

REICHERT, J.M.; ALBUQUERQUE, J.A.; REINERT, D.J.; KAISER, D.R. Water retention estimation and plant availability for subtropical Brazilian soils. 19th World Congress of Soil Science, Soil Solutions for a Changing World 1, 197-200, Brisbane, Australia. 2010.

REICHARDT, K.; TIMM, L.C. **Solo, Planta e Atmosfera: conceitos, processos e aplicações**. São Paulo: Editora Manole, 2012. 500p.

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

REICHERT, J.M.; KAISER, D.R.; REINERT, D.J.; RIQUELME, U.F.B. Variação temporal de propriedades físicas do solo e crescimento radicular de feijoeiro em quatro sistemas de manejo. **Pesquisa Agropecuária Brasileira**, Brasília, 44(3):310-319, 2009.

REINERT, D.J.; REICHERT, J.M. Coluna de areia para medir a retenção de água no solo: protótipos e teste. **Ciência Rural**, 36:1931-1935, 2006.

REZENDE, S.O. (org.). **Sistemas inteligentes: fundamentos e aplicações**. 1^a ed. 1^a reimpressão. Barueri, Manole, 2005. 525p.

RICHARDS, L. Methods of measuring moisture tension. **Soil Science**, 58:95-112, 1949.

ROSENBLATT, F. The Perceptron: A probabilistic model for information storage and organization in the brain. **Psychology Review**, 65:386-408, 1958.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by back-propagating errors. **Nature**, 323:533-536, 1986.

SALTER, P.J.; BERRY, G.; WILLIAMS, J.B. The influence of texture on moisture characteristics of soils: III. Quantitative relationships between particle size, composition, and available-water capacity. **Journal of Soil Science**, 17(1):93-98, 1966.

SARMADIAN, F; KESHAVARZI, A. Developing PTFs for estimating some soil properties using ANN and multivariate regression approaches. **World academy of Science, Engineering an Technology**, 72:501-507, 2010.

SARMADIAN, F.; MEHRJARDI, R.T. Modeling of Some Soil Properties Using Artificial Neural Network and Multivariate

Regression in Gorgan Province, North of Iran. **Global Journal of Environmental Research**, 2(1):30-35, 2008.

SARMADIAN, F.; MEHRJARDI, R.T.; AKBARZADEH, A. Optimization of Pedotransfer Functions Using an Artificial Neural Network. **Australian Journal of Basic and Applied Sciences**, 3(1):323-329, 2009.

SAS - STAT Procedures Guide for Personal Computers. Version 6. 3ed. Cary, SAS Institute Inc., 1990. 705p.

SAXTON, K.E.; RAWLS, W.J. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. **Soil Science Society of American Journal**, 70:1569-1578, 2006.

SCARDUA, R. **Porosidade livre de água de dois solos do Município de Piracicaba, SP.** Piracicaba, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, 1972. 83p. (Dissertação de Mestrado)

SOCIEDADE BRASILEIRA DE CIÊNCIA DO SOLO – SBCS. Reunião nacional de correlação e classificação de solos, Florianópolis. Guia de Excursão. Florianópolis, EPAGRI/UDESC/SBCS/CNPS, 2008. 181p.

SCHAAP, M.G.; LEIJ, F.J. Using neural networks to predict soil water retention and soil hydraulic conductivity. **Soil Tillage Research** 47:37-42, 1998.

SCHAAP, M.G; LEIJ, F.J. Improved prediction of unsaturated hydraulic conductivity with Mualem-van Genuchten model. **Soil Science Society of American Journal**. 64:843-851, 2000.

SCHAAP, M.G.; BOUTEN, W. Modeling water retention curves of sandy soils using neural networks. **Water Research Resource**, 32:3033-3040, 1996.

SCHAAP, M.G.; LIEJ, F.J.; van GENUCHTEN, M.Th. Neural network analysis for hierarchical prediction of soil hydraulic properties. **Soil Science Society of American Journal**, 1998.

SCHAAP, M.G.; LEIJ, F.J.; van GENUCHTEN, M.T. Rosetta: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. **Journal of Hydrology**, 251:163-176, 2001.

SCHEINOST, A.C.; SINOWSKI, W.; AUERSWALD, K. Regionalization of water retention curves in a highly variable

soilscape: I. Developing a new pedotransfer function. **Geoderma** 78:129-143. 1997.

SCHUH, W.M.; CLINE, R.L.; SWEENEY, M.D. Comparison of laboratory procedure and a texture model predicting in situ soil water retention. **Soil Science Society of America Journal**, 52:1218-1227, 1988.

SCOTT, D.H. **Soil water principles**. In: Soil physics: agricultural and environmental applications. Ames: Iowa State University Press, 2000. 165-212.

SILVA, A.J.N.; CABEDA, M.S.V.; LIMA, J.F.W.F. Efeito de sistemas de uso e manejo nas propriedades físico-hídricas de um Argissolo Amarelo de Tabuleiro Costeiro. **Revista Brasileira de Ciência do Solo**, 29:833-842, 2005.

SILVA, E.R. **Um percurso pela história através da água: passado, presente e futuro**. XXVII Congresso Interamericano de Engenharia Sanitária e Ambiental. Porto Alegre, 2000.

Disponível em:

<<http://www.bvsde.paho.org/bvsaidis/saneab/xi-009.pdf>>. Acessado dia 06 Ago, 2013 às 12:14.

SILVA, V.R. **Propriedades físicas e hídricas em solos sob diferentes estados de compactação**. Santa Maria,

Universidade Federal de Santa Maria, 2003. 171p. (Tese de Doutorado).

TAMARI, S.; WOSTEN, J.H.M.; RUIZ-SUÁREZ, J.C. Testing an artificial neural network for predicting soil hydraulic conductivity. **Soil Science Society of American Journal** 60:1732-1741, 1996.

TEDESCO, M.J.; GIANELLO, C.; BISSANI, C.A.; BOHNEN, H; VOLKWEISS, S.J. **Análises de solo, plantas e outros materiais**. 2. ed. Porto Alegre: Universidade Federal do Rio Grande do Sul, 1995. 174p.

TESKE, R. **Relações solo – litologia numa sequência de solos desenvolvidos de rochas efusivas no Planalto Sul de Santa Catarina**. Lages, Universidade do Estado de Santa Catarina, 2010. 121p. (Dissertação de Mestrado)

TOMASELLA, J.; PACHEPSKY, Y.; CRESTANA, S.; RAWLS, W.J. Comparison of two techniques to develop pedotransfer functions for water retention. **Soil Science Society of America Journal**, 67:1085-1092, 2003.

VALENÇA, M. **Aplicando redes neurais: um guia completo**. Olinda, Editora do Autor, 2005. 284p.

van den BERG, M.; KLAMT, E.; van REEUWIJK, L.P.; SOMBROEK, W.G. Pedotransfer functions for estimation of moisture retention characteristics of Ferralsols and related soils. **Geoderma**, 78:161-180, 1997.

van GENUCHTEN, M.Th. A closed-form equation for predicting the conductivity of unsaturated soils. **Soil Science Society of American Journal**, Madison, 44:892-898, 1980.

VEIGA, M.M. Agrotóxicos: eficiência econômica e injustiça socioambiental. **Ciência & Saúde Coletiva**, 12(1):145-152, 2007.

VEIHMEYER, F.J; HENDRICKSON, A.H. Methods os measuring field capacity and wilting percentages of soil. **Soil Science**, 68:75-94, 1949.

VEERECKEN, H.; DIELS, J.; van ORSHOVEN, J. ; FEYEN, J.; BOUMA, J. Functional evaluation of pedotransfer functions for the estimation of soil hydraulic properties. **Soil Science Society of American Journal**, Madison, 56(5):1371-1378, 1992.

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

VIEIRA, M.L.; KLEIN, V.A. Propriedades físicas e hidráticas de um Latossolo Vermelho submetido a diferentes sistemas de manejo. **Revista Brasileira de Ciência do Solo**, 31:1271-1280, 2007.

TUZLUKOV, V. P. **Signal Processing Noise: The Electrical Engineering and Applied Signal Processing Series**, Boca Raton, CRC Press. 2010. 688 p.

WILLIAMS, R.D.; AHUJA, L.R.; NANNEY, J.W. Comparison of methods to estimate soil water characteristics from soil texture, bulk density, and limited data. **Soil Science**, 153:172-184, 1992.

WILLIAMS, J.; PREBBLE, R.B.; WILLIAMS, W.T.; HIGNETT, C.T. The influence of texture, structure and clay mineralogy on the soil moisture characteristics. **Australian Journal of Soil Research**, 21:15-32, 1983.

WITTEN, I.H.; EIBE, F. **Data Mining**: practical machine learning tools and techniques, San Francisco: 2nd Edition, Morgan Kaufmann, 2005, 525p.

WÖSTEN, J.H.M.; van GENUCHTEN, M.T. Using texture and other soil properties to predict the unsaturated soil hydraulic functions. **Soil Science Society of America Journal**, 52:1762-1770, 1988.

WÖSTEN, J.H.M.; FINKE, P.A.; JANSEN, M.J.W. Comparison of class and continuous pedotransfer functions to generate soil hydraulic characteristics. **Geoderma** 66:227-237, 1995.

WÖSTEN, J.H.M.; PACHEPSKY, Y.A.; RAWLS, W.J. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. **Journal of Hydrology**, 251:123-150, 2001.

BIBLIOGRAFIA CONSULTADA

A irrigação no Brasil: situação e diretrizes / Ministério da Integração Nacional -- Brasília: IICA, 2008. 132p.

ALLAHYARIPOUR, F.; FAZLI, L. Investigation artificial neural networks for point simulation of soil water retention curve. **Research Journal of Fisheries and Hydrobiology**, 6(4):383-389, 2011.

BOUCKAERT, R.R.; FRANK, E.; HALL, M.A.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. WEKA – Experiences with a Java Open-Source Project. **Journal of Machine Learning Research**, 11:2533-2541, 2010.

CHAGAS, C.S. Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros. Viçosa, Universidade Federal de Viçosa. 2006. 233p. (Tese de Doutorado).

Disponível em:

<<http://soils.usda.gov/technical/aids/investigations/texture/>>
Acessado dia 20/09/2013 às 20:51.

FOMBY, T. **Artificial neural networks** (ANNs). Dallas, Department of Economics, Southern Methodist University, Mar. 2008. (Lecture Notes).

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

Introduction to WEKA. Disponível em:

<https://www.cs.auckland.ac.nz/courses/compsci367s1c/tutorials/IntroductionToWeka.pdf>. Acessado dia 06 Ago, 2013 às 12:14.

LIMA, J.E.F.W.; FERREIRA, R.S.A.; CHRISTOFIDIS, D. **O uso da irrigação no Brasil**. Disponível em: <https://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&soucre=web&cd=2&cad=rja&uact=8&ved=0CDAQFjAB&url=http%3A%2F%2Fcanapedeagua.com.br%2Findex.php%3Foption%3Dcom_docman%26task%3Ddoc_download%26gid%3D18%26Itemid%3D11&ei=uDeBU6UHyaxBKLmgOgD&usg=AQjCNHrKOHHnxUpqYtrF2d0cioUCF330w&bvm=bv.67720277,d.cWc>. Acessado dia 06 Ago, 2013 às 13:10.

MAXIMINO, A.P. **Comparação de algoritmos de aprendizado de máquina para classificação de padrões em uma base de dados médicos**. Ribeirão Preto, Centro Universitário Barão de Mauá, 2007. 48p. (Monografia).

MICHELON, C.J. Pedofunções para retenção de água de solos do Rio Grande do Sul irrigados por aspersão. Santa Maria, Universidade Federal de Santa Maria. 2010. 109p. (Tese de Doutorado).

SARMADIAN, F; MEHRJARDI, R.T. Development of pedotransfer functions to predict soil hydraulic properties in Golestan Province, Iran. **19th World Congress of Soil Science, Soil Solutions for a Changing World**, Brisbane, Australia. 59-62, 2010.

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

APÊNDICE

Apêndice A – Descrição morfológica dos 13 perfis de solo estudados

Perfil 1

DATA: 22 de julho de 2008

CLASSIFICAÇÃO: CAMBISSOLO HÁPLICO Alítico típico

LOCALIZAÇÃO: Trecho da localidade vigia em direção à localidade do Bodegão, entrando à direita para a localidade do Rincão do Perigo, aproximadamente 800 metros a partir do entroncamento estrada geral da Coxilha Rica.

LOCALIZAÇÃO GEOGRÁFICA: 28°16'02,88"S; 50°29'54,26"O

ALTITUDE: 1004 m (GPS); 1030 (barômetro)

LITOLOGIA: Rochas efusivas intermediárias

FORMAÇÃO: Serra Geral

PERÍODO: Cretáceo Superior

MATERIAL DE ORIGEM: Produto da decomposição das rochas supra cima, com possível retrabalhamento do material de origem mais superficial.

PEDREGOSIDADE: ligeiramente pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: terço superior de encosta

RELEVO LOCAL: suave ondulado REGIONAL:

ondulado

EROSÃO: não aparente

DRENAGEM: moderado (apresenta poucos mosqueados)

VEGETAÇÃO: campo subtropical (dominância palha fina)

USO ATUAL: pastagem natural

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antônio de Almeida, Rodrigo Teske, Artur Lorenzini.

DESCRIÇÃO MORFOLÓGICA:

A1 0 – 10 cm bruno muito escuro (úmido: 10YR 2,5/2; seco 5YR 2,5/2); muito argiloso; forte pequena e muito pequena granular; dura, friável, plástico e ligeiramente pegajoso; transição clara e plana.

A2 10 – 21 cm bruno muito escuro (úmido: 10YR 2,5/2; seco: 7,5YR 3/2); muito argiloso; moderada pequena e muito pequena granular,

moderado pequeno blocos subangulares; dura, friável, plástico e ligeiramente pegajoso; transição clara e plana.

AB 21 – 47 cm bruno acinzentado muito escuro (úmida: 10YR 3/2 - seco: 10YR 4/3); muito argiloso; moderada pequena e muito pequena blocos subangulares; dura, friável, plástico e pegajoso; transição clara e plana.

BA 47 – 60 cm bruno amarelado escuro (úmida: 10YR 3,5/4 – seco: 10YR 4/3); muito argiloso; moderada pequena blocos subangulares; muito dura, friável, plástico e pegajoso; transição clara e plana.

Bi1 60 – 80 cm bruno amarelado escuro (úmida: 10YR 4/4 – seco: 10YR 4/4); muito argiloso; moderada pequena a média blocossangulares; extremamente dura, friável a firme, muito plástico e pegajoso a muito pegajoso; transição : gradual e plana.

Bi2 80 – 102 cm bruno amarelado escuro (úmida: 10YR 4,5/4 – seco :10YR 5/4); muito argiloso; moderada a fraca média blocos subangulares; extremamente dura, friável a firme, plástico e pegajoso a muito pegajoso; transição: gradual e plana.

BC 102 – 120/130 cm bruno amarelado (úmida: 10YR 5/5 – seco: 10YR 5/4); muito argiloso; fraca media e grande blocos subangulares; extremamente dura, firme, plástico e pegajoso a muito pegajoso; transição abrupta e ondulada.

C 120/130 – 132/150 cm bruno forte (úmida: 7,5YR 4/6 – seco: 10YR 6/4); muito argiloso; fraca grande blocossangulares; dura a extremamente dura, firme: plástico a ligeiramente plástico e ligeiramente pegajoso; transição: abrupta irregular. Mosqueados: (7,5YR 4/6); média comum e distinto.

CR 132/150 – 170 cm+ cinzento brunado claro (úmida: 10YR 6/2 – seco: 10YR 7/2); argiloso.

RAÍZES: no A1 muitas, fasciculadas e finas; no A2 comuns, fasciculadas e finas; no AB e BA poucas a comuns, fasciculadas, finas; Poucas no Bi1 e Bi2; no BC raras e no C e Cr ausentes.

Obs.: Dia nublado. Presença de cascalho até 20cm no AB e no BA Presença de cascalho no AB e BA (até 20cm).

Perfil 2

DATA: 23 de julho de 2008

CLASSIFICAÇÃO: CAMBISSOLO HÁPLICO Alítico típico

LOCALIZAÇÃO: aproximadamente 500 m da propriedade de Cândido Vieira em direção à Fazenda Negreiro, lado direito. Encontra-se a 19 km da calha do rio Lava-tudo, Lages, Santa Catarina.

LOCALIZAÇÃO GEOGRÁFICA: 28°18'27,65"S; 50°23'30,63"O

ALTITUDE: 1100 m (altímetro); 1084 (GPS)

LITOLOGIA: Riodacito Vermelhado

FORMAÇÃO: Serra Geral

PERÍODO: Cretáceo Superior

MATERIAL DE ORIGEM: Produto da alteração do Riodacito Vermelhado com deposição coluvionar superficial.

PEDREGOSIDADE: não pedregoso.

ROCHOSIDADE: não rochoso.

SITUAÇÃO DECLIVE/COBERTURA: topo de elevação com aproximadamente 5 % de declividade no local. Cobertura de pastagem natural com predomínio de capim palha fina.

RELEVO LOCAL: suave ondulado

REGIONAL:

EROSÃO: não aparente.

DRENAGEM: moderada.

VEGETAÇÃO: primária campo subtropical.

USO ATUAL: pastagem natural

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antônio de Almeida, Rodrigo Teske, Artur Lorenzini.

DESCRIÇÃO MORFOLÓGICA:

A1 0 – 13 cm preto (úmido: 10YR 2/1, seco 10YR 4/2); argiloso; moderada, média, blocos subangulares e angulares que se desfazem em moderada a forte, média granular e moderada, muito pequena e pequena granular; macia, friável, plástico e ligeiramente pegajoso; transição gradual e plana.

A2 13 – 26/30 cm bruno avermelhado escuro (úmida: 5YR 3/3 - seco: 10YR 4/2); muito argiloso; fraca a moderada média e grande blocos subangulares que se desfaz em moderada, muito pequena e pequena granular; macia, friável; plástico e ligeiramente pegajoso; transição clara e ondulada.

BA 26/30 – 42 cm bruno escuro (úmida: 7,5YR 3/3 – seco: 10YR 4/3); muito argiloso; moderada a fraca, pequena e média blocossubangulares; macia, friável, plástico e pegajoso; transição clara e plana.

Bi 42 – 70/76 cm bruno escuro (úmida: 7,5YR 4/4 – seco: 10YR 6/4); muito argiloso; moderada, média e pequena blocos subangulares; dura,

friável a firme, plástico e ligeiramente pegajoso a pegajoso; transição: abrupta e ondulada.

C 70/76 – 97/78 cm vermelho escuro (úmida: 3,5YR 3/6 – seco: 5YR 6/3); argiloso; moderada, média e pequena blocos angulares e subangulares; ligeiramente dura, muito friável; ligeiramente plástico a plástico e ligeiramente pegajoso a pegajoso; transição: abrupta e irregular.

Cr 97/78 – 110+ cm bruno avermelhado escuro (úmido: 2,5YR 3/4, seco 10R 6/3); argila siltosa; moderada a forte, média blocos angulares. Consistência seca: macia, úmida: firme; ligeiramente plástico, ligeiramente pegajoso.

RAÍZES: no A1 e A2 muitas, fasciculadas; no BA e Bi fasciculadas comuns; No C poucas e no Cr raras.

Obs.: Presença expressiva de linha de pedras disseminada no horizonte BA e parte superior do Bi com fragmentos de calcedônea. Fragmentos semintemperizados de Riodacito e com dimensões métricas e decimétricas.

Perfil 3

DATA: 03 de novembro de 2011

CLASSIFICAÇÃO: CAMBISSOLO HÁPLICO Tb Eutroférreco típico

LOCALIZAÇÃO: Microbacia Arroio dos Mineiros - São José do Cerrito/SC

LOCALIZAÇÃO GEOGRÁFICA: 27°32'03,79"S; 50°43'12,54"O

ALTITUDE: 953 m

LITOLOGIA: andesito-basalto ou riodacito

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produto de alteração da rocha citada com forte influência de colúvio superficial entre A e Bi1

PEDREGOSIDADE: ligeiramente pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: Terço médio de encosta íngreme. Declividade de aproximadamente 25 %. Cobertura de capoeira.

RELEVO LOCAL: forte ondulado

REGIONAL: forte

ondulado

EROSÃO: laminar moderada

DRENAGEM: bem drenado

VEGETAÇÃO: Floresta Ombrófila Mista

USO ATUAL: Capoeira

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime, Benício, Letícia e Gleison

DESCRIÇÃO MORFOLÓGICA:

A 0 – 22 cm Estrutura moderada pequena e muito pequena, granular 5YR 3/2 firme Clara e plana Muitas finas e médias fasciculadas

Bi1 22 – 45 cm Moderada a fraca, pequena e média blocossubangulares 3,5YR 4/4 friável a firme Clara e plana Comuns, finas, médias fasciculadas

Bi2 45 – 75/85 cm Moderada média pequena blocos subangulares e angulares 2,5YR 4/6 firme Clara e ondulada Poucas, médias fasciculadas

BC 75/85 – 120+ cm Fraca a moderada, média blocos subangulares e angulares 2,5YR 4/8 com manchas de material alterado da rocha bem como fragmentos alterados 7,5YR 5/6 friável a firme Poucas, médias fasciculadas

Obs.: Perfil apresenta variação de espessura ao longo do corte de estrada com horizonte Bi variando desde 40 cm até 70 cm / Linhas de pedra variando de 2 cm a 10 cm de diâmetro entre o horizonte A e o Bi1.

Perfil 4

DATA: 03 de novembro de 2011

CLASSIFICAÇÃO: NITOSSOLO BRUNO Distroférrico típico

LOCALIZAÇÃO: Microbacia Arroio dos Mineiros - São José do Cerrito/SC

LOCALIZAÇÃO GEOGRÁFICA: 27°33'07,97"S; 50°42'10,79"O

ALTITUDE: 977 m

LITOLOGIA: basalto ou andesito basalto

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produtos de alteração de rocha, com possível contribuição de material coluvial alterado da mesma rocha (linha de cascalho no Bi1).

PEDREGOSIDADE: não pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: Topo de elevação próximo ao terço superior de encosta, declividade aproximadamente 8%. Cobertura de gramíneas.

RELEVO LOCAL: suave ondulado ondulado e ondulado

REGIONAL: suave

EROSÃO: não aparente

DRENAGEM: bem a moderadamente drenado

VEGETAÇÃO: Floresta Ombrófila Mista

USO ATUAL: Pastagem

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime, Benito, Letícia e Gleison

DESCRIÇÃO MORFOLÓGICA:

A1 0 – 14 cm Moderada, muito pequena e pequena granular 7,5YR 3/3 friável a firme Clara e plana muitas, finas e médias.

AB 14 – 30 cm Moderada, média, blocos subangulares e moderada média granular 7,5YR 3/4 firme Clara e plana comuns, finas, médias, fasciculadas.

BA 30 – 45 cm Moderada, média, prismática, prismas médios que se desfazem em blocos moderada a média 6,5YR 4/6 Moderada e comum firme Gradual e plana comuns, finas, médias, fasciculadas.

B1 45 – 70 cm Moderada, grande e média prismática que se desfaz em grande e média blocossubangulares 6YR 4/6 Fraca e comum firme Gradual e plana poucas, fasciculadas, finas

B2 70 – 123 cm Moderada média prismática que se desfaz em moderada média blocos subangulares 7,5YR 4/6 firme Gradual e plana raras, fasciculadas, finas

BC 123 – 150+ cm Moderada a fraca, média e pequena blocossubangulares 7,5YR 5/6 firme ausentes

Obs.: linha de cascalhos no centro do horizonte B1 composta de fragmentos centimétricos de basalto semi-intemperizado / coletado em dia nublado/ alguns fragmentos de rochas semi-intemperizadas no interior do perfil, com dimensão entre 20 e 100 cm

Perfil 5

DATA: 09 de novembro de 2011

CLASSIFICAÇÃO: NEOSSOLO REGOLÍTICO Eutroúmbricoléptico

LOCALIZAÇÃO: Microbacia Arroio dos Mineiros - São José do Cerrito/SC LOCALIZAÇÃO GEOGRÁFICA: 27°33'32,01"S; 50°43'54,76"O

ALTITUDE:

LITOLOGIA: basalto

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: Material coluvial proveniente da intemperização do basalto

PEDREGOSIDADE: pedregoso

ROCHOSIDADE: ligeiramente rochoso

SITUAÇÃO DECLIVE/COBERTURA: Terço superior de segunda encosta. Declividade de aproximadamente 25 % a 30 %.

RELEVO LOCAL: forte ondulado REGIONAL: forte ondulado

EROSÃO: ligeira laminar

DRENAGEM: bem drenado

VEGETAÇÃO: Floresta Ombrófila Mista

USO ATUAL: pastagem azevém

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime, Benito e Heraldo

DESCRIÇÃO MORFOLÓGICA:

A 21 Estrutura Moderada média granular e fraca pequena blocos subangulares cor úmida 7,5YR 3/3 consistência úmida friável transição Gradual e plana Raízes Muitas fasciculadas finas e médias

AC 40/45 Moderada média granular e fraca pequena blocos subangulares 7,5YR 3/3 friável Gradual e ondulada Comuns fasciculadas finas e médias

A/C1 55/70 Moderada a fraca média granular e fraca média blocos subangulares 7,5YR 3/3 friável Gradual e ondulada Comuns fasciculadas finas e médias

A/C2 85 Fraca média granular 7,5YR 3/4 friável Clara e plana Poucas fasciculadas médias

Obs.: Fragmentos de basalto intemperizado (calhaus com cor de alteração amarelada), pouco visíveis no A/C1 e abundantes no A/C2 com pouco material terroso // Horizonte CR/R constituído de fragmentos de calhaus mais e menos alterados com cores de alteração amarelas e cinzentas. Muitos recobertos por deposição de óxidos de manganês.

Perfil 6

DATA: 09 de novembro de 2011

CLASSIFICAÇÃO: NEOSSOLO LITÓLICO Chernossólico típico

LOCALIZAÇÃO: Microracia Arroio dos Mineiros - São José do Cerrito/SC

LOCALIZAÇÃO GEOGRÁFICA: 27°33'29,52"S; 50°45'08,32"O

ALTITUDE: 812 m

LITOLOGIA: basalto

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produto da alteração do basalto

PEDREGOSIDADE:

ROCHOSIDADE:

SITUAÇÃO DECLIVE/COBERTURA: Terço inferior de encosta.

Declividade aproximadamente 30 %

RELEVO LOCAL: forte ondulado

REGIONAL: forte

ondulado

EROSÃO: não aparente

DRENAGEM: bem drenado

VEGETAÇÃO: Floresta Ombrófila Mista

USO ATUAL:

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime, Benito e Heraldo

DESCRIPÇÃO MORFOLÓGICA:

A 0 – 10/25 cm Estrutura moderada pequena e muito pequena granular; cor úmida 7,5YR 3/2 Consistência úmida muito friável; Transição abrupta e irregular; Raízes abundantes médias e finas fasciculadas, poucas pivotantes grossas.

Obs.: R constituído de basalto semi-intemperizado fragmentado em planos horizontais e verticais // coletado em área de mata remanescente

Perfil 7

DATA:

CLASSIFICAÇÃO: CAMBISSOLO HÁPLICO Alumínicoúmbrico.

LOCALIZAÇÃO: Estrada Lages-morinhos a 10,8 km após a ponte do Rio Caveiras no limite urbano da cidade, ao lado direito.

LOCALIZAÇÃO GEOGRÁFICA: 27°55'48,3"S; 50°16'23,8"O.

ALTITUDE: 1037 m.

LITOLOGIA: rochas eruptivas básicas e basalto

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: Produto da alteração das rochas supracitadas com possível contribuição de material coluvial, provavelmente de mesma natureza, no horizonte A.

PEDREGOSIDADE: Ligeiramente pedregoso.

ROCHOSIDADE: Não rochoso.

SITUAÇÃO DECLIVE/COBERTURA: Coletado em posição de cimeira em área de declive convexo próximo a um topo de elevação, com aproximadamente 5% de declive no local. Campo subtropical com araucária.

RELEVO LOCAL: Suave ondulado.

REGIONAL:

Ondulado, com partes forte ondulado.

EROSÃO: Não aparente.

DRENAGEM: Bem drenado.

VEGETAÇÃO:

USO ATUAL: Pastagem.

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antonio Almeida, Élen Ramos N. C. Ferreira.

DESCRIÇÃO MORFOLÓGICA:

A 0 – 23/27 cm, bruno-escuro (7,5 YR 3/3, úmido) e bruno-avermelhado-escuro (5 YR 3/3, seco); muito argiloso; moderada, pequena e média granular; friável, duro a muito duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e ondulada.

Bi 23/27 – 40/47 cm; vermelho-amarelado (5 YR 4/6,5, úmido) e bruno-avermelhado-escuro (5 YR 3,5/4, seco); muito argiloso; moderada a fraca, pequena e média blocos sub-angulares; firme, duro a muito duro, pegajoso e ligeiramente plástico; transição gradual e ondulada. BC/CR 40/47 – 52/58 cm; vermelho-amarelado (5 YR 4/6,5, úmido) e bruno-avermelhado (5 YR 4,5/4, seco); argila; fraca pequena, blocos sub-angulares nas partes do BC; firme, duro a muito duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e ondulada.

CR 52/58 – 65+ cm; amarelo-avermelhado (5 YR 6/6,5, úmido) e vermelho-amarelado (5 YR 5/6, seco); franco argiloso; maciça; firme, duro a muito duro, não pegajoso e não plástico.

RAÍZES: muitas, fasciculares, médias e finas no A e Bi; poucas, fasciculares, finas no BC/CR; raras no CR.

Obs.: presença de fragmentos de basalto ou riocitosemi-intemperizados no contato entre A e Bi. Presença de nucleações brancas no CR (calcedônea ou zeólita) com forte deposição de óxidos de Mn ao redor dos fragmentos da rocha semi – intemperizada, bem como em zonas paralelas nos núcleos de material esbranquiçado. Presença de grande quantidade de cupins no horizonte A. Perfil coletado em barranco.

Perfil 8

DATA:

CLASSIFICAÇÃO: NEOSSOLO REGOLÍTICO

LOCALIZAÇÃO: às margens da BR 282 trecho Lages - Florianópolis, 7,5 de Lages, barranco ao lado direito.

LOCALIZAÇÃO GEOGRÁFICA: 27°46'43,8"S; 50°13'55,4"E.

ALTITUDE: 970 m

LITOLOGIA: fonolito

FORMAÇÃO: corpo alcalino de Lages

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: Produto da alteração das rochas supracitadas.

PEDREGOSIDADE: não pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: topo de elevação, declive aproximado de 20 %, cobertura com campo subtropical.

RELEVO LOCAL: suave ondulado REGIONAL:
ondulado

EROSÃO: não aparente

DRENAGEM: bem drenado

VEGETAÇÃO:

USO ATUAL: pastagem

CIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antonio Almeida, Élen Ramos N. C. Ferreira, Rodrigo Teske, Ezequiel Saretta.

DESCRIÇÃO MORFOLÓGICA:

A 0 – 16/20 cm; bruno-acinzentado muito escuro (10 YR 3/2, úmido) e bruno-escuro (10 YR 3/3, seco); argila; moderada, pequena, média, granular; muito friável, ligeiramente duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e ondulada.

AC 16/20 – 42/60 cm; bruno escuro (10 YR 3/3, úmido) e bruno (10 YR 4/3, seco); argila; fraca, pequena, granular; muito friável, ligeiramente duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e irregular/quebrada.

C1 42/60 – 70/80 cm; bruno amarelado (10 YR 5/8, úmido) e amarelo brunado (10 YR 6/6, seco); argila; maciça; friável, muito duro, ligeiramente pegajoso, ligeiramente plástico; transição clara e ondulada.

C2 70/80 – 120/130 cm; amarelo-avermelhado (7,5YR 6/8, úmido) e amarelo-avermelhado (7,5 YR 7/6 seco); argila; maciça; friável, muito duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual e ondulada.

C3 120/130+ cm

RAÍZES: Muitas, fasciculares, finas e médias no A; comuns, fasciculares, finas no AC; poucas, fasciculares, finas no C1; ausentes no C2 e C3.

Obs.: horizonte AC composto de material do A em mistura com grande quantidade de cascalhos centimétricos representados por fragmentos de fonolitosemi-intemperizado de cor esbranquiçada. Horizonte C1 apresenta crostas duras perpendiculares e transversais de cor esbranquiçada com nucleações pretas, com algumas partes rosadas. Crostas com aproximadamente 1-3 cm de espessura. No C2 núcleos de cor esbranquiçada branco rosada. C3 - não coletado.

Perfil 9

DATA:

CLASSIFICAÇÃO:

LOCALIZAÇÃO: Rodovia SC Lages - Palmeira, entrar a direita Estrada vicinal Palmeira, Localidade Cadeados, percorrer 5,7 km, entrando a esquerda, percorrer 850 m

LOCALIZAÇÃO GEOGRÁFICA: 27° 38'37,4"S; 50°09'51,3"O.

ALTITUDE: 923 m

LITOLOGIA: Sienito

FORMAÇÃO: corpo alcalino de Lages

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: Produto da alteração da rocha supracitada.

PEDREGOSIDADE: não pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: 1/3 superior da encosta, próximo ao topo da elevação, declividade 12%, cobertura vegetal com (xaxins, araucárias, amora, goiaba serrana).

RELEVO LOCAL: ondulado REGIONAL: ondulado

EROSÃO: não aparente

DRENAGEM: bem a moderadamente drenado

VEGETAÇÃO:

USO ATUAL: mata

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antonio Almeida, Élen Ramos N. C. Ferreira, Rodrigo Teske, Samara Alves Testoni.

DESCRIÇÃO MORFOLÓGICA:

A 0 – 23 cm; bruno-escuro (10YR 3/3 úmido) e bruno (10 YR 4/3 seco); argila; moderada, pequena a muito pequena, granular e fraca, média blocos sub-angulares; friável, firme, duro a muito duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual e plana.

AB 23 – 36 cm; bruno-amarelado-escuro (10YR 3/4 úmido) e bruno-amarelado-escuro (10 YR 4/4 seco); argila; fraca a moderada, média

blocos sub-angulares; friável, muito duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual e plana.

BA 36 – 57 cm; bruno-amarelado-escuro (10YR 3/6 úmido) e bruno-amarelado (10 YR 5/6 seco); muito argiloso; fraca a moderada, média blocos sub-angulares e fraca a moderada pequena granular; friável, duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual.

B 57 – 82/93 cm; bruno-amarelado-escuro (10YR 4/4 úmido) e bruno amarelado (10 YR 5/4 seco), mosqueados (5 Y 8/2 úmido); muito argiloso; fraca a moderada, média blocos sub-angulares e fraca a moderada pequena granular; friável, muito duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual e ondulada.

BC 82/93 – 110/135 cm; bruno-amarelado-escuro (10YR 4/6 úmido) e amarelo-brunado (10 YR 6/6 seco); muito argiloso; fraca, média e pequena blocos sub-angulares; friável, muito duro, ligeiramente pegajoso e ligeiramente plástico; transição abrupta e ondulada.

CR 110/135+ cm; amarelo-brunado (10YR 6/6 úmido) e bruno-amarelado-claro (10 YR 6/4 seco); franco arenoso; maciça; friável, muito duro, ligeiramente pegajoso e ligeiramente plástico; transição abrupta e ondulada.

RAÍZES: comuns, fasciculares, finas no A e AB; poucas, fasciculares, finas no BA e B; raras, fasciculares no BC.

Obs.: alguns fragmentos de sienitossemi-alterados no volume do perfil, principalmente nos horizontes B e BC. No contato solo saprólico intensa deposição de óxidos de manganês, que se distribuem transversalmente no saprólico. Intensa atividade de cupins e formigas até o horizonte BA. Coleta de horizonte CR (saprólico) em barranco na beira da estrada vacinal cadeados.

Cerosidade: Fraca e pouca no BA e B.

Perfil 10

DATA:

CLASSIFICAÇÃO: CAMBISSOLO HÁPLICO Alumínico típico

LOCALIZAÇÃO: Trevo do município da Palmeira com a SC 425 em estrada de terra rumo a oeste em direção a Correia Pinto entrando 1 km a esquerda após o trevo, percorrendo 7,8 km entra a direita, percorre 2 km, entrando a esquerda rumo a mineração Rio Pomba, Empresa Rio Desertos, a esquerda mais 100 metros, perfil ao lado esquerdo.

LOCALIZAÇÃO GEOGRÁFICA: 27°33'48,9"S; 50°14'23,2"O.

ALTITUDE: 945 m

LITOLOGIA: Fonolitoporfíritico, com intensa coluviação superficial.

FORMAÇÃO: Corpo Alcalino de Lages

PERÍODO: Juro-cretáceo.

MATERIAL DE ORIGEM: Produto da alteração da rocha supracitada.

PEDREGOSIDADE: não pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA: 1/3 médio de encosta, declive de aproximadamente 15%. Cobertura vegetal de gramíneas, ao lado de reflorestamento de pinus.

RELEVO LOCAL: ondulado

REGIONAL: forte ondulado

EROSÃO: não aparente

DRENAGEM: bem a moderadamente drenado.

VEGETAÇÃO:

USO ATUAL: reflorestamento

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Antonio Almeida, Élen Ramos N. C. Ferreira, Samara Alves Testoni.

DESCRIÇÃO MORFOLÓGICA:

A 0 – 22 cm; bruno-escuro (7,5 YR 3/3, úmido) e bruno (7,5 YR 4,5/4, seco); argila; fraca a moderada, muito pequena e pequena granular e fraca, média, blocos subangulares; friável, macio a ligeiramente duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e plana.

AB 22 – 42 cm; bruno-escuro (7,5 YR 3/4, úmido) e bruno-forte (7,5 YR 4/6, seco); argila; fraca, pequena granular e fraca, média, blocos subangulares; friável, macio a ligeiramente duro, pegajoso e plástico; transição gradual e plana.

2Bi 42 – 75 cm; bruno (7,5 YR 4/4, úmido) e bruno-forte (7,5 YR 5/6, seco); muito argiloso; fraca, média, blocos subangulares; friável, ligeiramente duro a duro, ligeiramente pegajoso e ligeiramente plástico; transição gradual e plana.

2BC 75 – 100/120 cm; bruno-forte (7,5 YR 5/8, úmido) e bruno-forte (7,5 YR 5,5/8, seco); argila; fraca, média e pequena blocos subangulares e fraca pequena e muito pequena granular; friável, ligeiramente duro a duro, ligeiramente pegajoso e ligeiramente plástico; transição clara e descontínua (quebrada).

2C1 100/120 – 155+ cm; amarelo-avermelhado (7,5 YR 6/8, úmido) e amarelo-avermelhado (7,5 YR 7/6, seco); franco argiloso; aspecto de maciça que se desfaz em blocos e prismas grandes; friável, macio a ligeiramente duro, ligeiramente pegajoso e ligeiramente plástico. 2C2 195 – 215 cm; vermelho-amarelado (5 YR 5/8, úmido) e amarelo-avermelhado (5 YR 7/6, seco), mosqueados branco, preto e amarelo-

brunado (5 Y 8/2, 5 Y 2,5/1, 10 YR 6/8 úmido); argila; firme, duro a muito duro, ligeiramente pegajoso e ligeiramente plástico.

RAÍZES: Muitas, fasciculadas, finas no A e AB; Comuns, fasciculadas, finas no 2Bi; Poucas no 2BC; raras no 2C1.

Obs.: horizonte 2C2 coletado com trado entre 195-215. Linhas de cascalhos e calhaus na base do AB e topo do B, juntamente com matacões de fonolitoporfíritico disseminados no AB e B. Intensa atividade biológica no B, BC e C representada por cupins e formigas. Horizonte C1 com intensa precipitação de óxidos de Mn pretos. Núcleos do 2C1 no interior do BC. Coletado em barranco em área a montante, próximo do perfil, próximo da jazida de exploração de bauxita.

Perfil 11

DATA: 2011

CLASSIFICAÇÃO: LATOSSOLO BRUNO

LOCALIZAÇÃO: município de Campo Belo do Sul, Santa Catarina

LOCALIZAÇÃO GEOGRÁFICA: 27°59'12,65"S; 50°48'14,55"O.

ALTITUDE: 956 m

LITOLOGIA: riolito, irodacito com amígdalas

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produto da alteração da rocha citada anteriormente

PEDREGOSIDADE:

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA:

RELEVO LOCAL: suave ondulado

ondulado

REGIONAL:

EROSÃO: não aparente

DRENAGEM: bem drenado

VEGETAÇÃO: campo nativo

USO ATUAL: plantio de pinus

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Almeida, Luciane Costa de Oliveira, Fabrício Tondello e Ildegardis Bertol

DESCRIÇÃO MORFOLÓGICA:

A1 0 – 20 cm; (7,5 YR 2/2,5, úmido) e (7,5 YR 2/3, seco); argila; fraca a moderada; média; blocos angulares e granular esferoidal; friável a firme; transição clara e plana.

A2 20 – 34 cm; (7,5 YR 3/2,5, úmido) e (7,5 YR 2/3, seco); argila; fraca; média; blocos subangulares; friável a firme; transição clara e plana.

A/B1 34 – 47 cm; (7,5 YR 3/2,5, úmido) e (7,5 YR 4/4, seco); argila; fraca a moderada; média; blocos subangulares; friável a firme; transição gradual e plana.

A/B2 47 – 62 cm; (7,5 YR 3/2,5, úmido) e (7,5 YR 4/4, seco); argila; fraca a moderada; pequena e média; blocos subangulares; friável; transição gradual e plana.

B/A 62 – 81 cm; (7,5 YR 3/3, úmido) e (7,5 YR 4/3, seco); argila; fraca a moderada; média; blocos subangulares; fraca; friável a firme; transição clara e plana.

B1 81 a + 133 cm; (7,5 YR 6/4, úmido) e (7,5 YR 6/5, seco); argila; fraca a moderada; média; blocos subangulares; fraca; friável a firme.

Obs: Cerosidade comum no B/A e no B1.

Perfil 12

DATA: 2011

CLASSIFICAÇÃO: NITOSSOLO HÁPLICO

LOCALIZAÇÃO: município de Campo Belo do Sul, Santa Catarina

LOCALIZAÇÃO GEOGRÁFICA: 28°00'33,86"S; 50°49'31,15"O.

ALTITUDE: 948 m

LITOLOGIA: riodacito

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produto da alteração da rocha citada anteriormente

PEDREGOSIDADE:

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA:

RELEVO LOCAL: suave ondulado REGIONAL:

ondulado

EROSÃO: não aparente

DRENAGEM: bem drenado

VEGETAÇÃO: campo nativo

USO ATUAL: campo nativo

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Almeida, Luciane Costa de Oliveira, Fabrício Tondello e Ildegardis Bertol

DESCRIÇÃO MORFOLÓGICA:

A1 0 – 17 cm; TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) - COR: anexo 03 - ESTRUTURA: Grau (fraca a moderada); Tamanho (pequena e média); Tipos (blocos angulares e granular esferoidal) - CONSISTÊNCIA: úmida (firme a muito firme)

A2 - PROFUNDIDADE: 17 – 42 cm - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) - COR: anexo 03 - ESTRUTURA: Grau (fraca); Tamanho (pequena e média); Tipos (blocos subangulares) - CONSISTÊNCIA: úmida (firme)

A/B - PROFUNDIDADE: 42 – 61 cm - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) - COR: anexo 03 - ESTRUTURA: Grau (fraca a moderada); Tamanho (média); Tipos (blocos subangulares) - CEROSIDADE: Quantidade (comum); Grau (fraca) - CONSISTÊNCIA: úmida (firme)

B/A - PROFUNDIDADE: 61 – 78 cm - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) 31 - COR: anexo 03 - ESTRUTURA: Grau (fraca); Tamanho (média e grande); Tipos (prismática que se desfaz em moderada a fraca) - CEROSIDADE: Quantidade (comum); Grau (fraca) - CONSISTÊNCIA: úmida (firme)

B1 - PROFUNDIDADE: 78 - 99 cm - COR: anexo 03 - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) - COR: anexo 03 - ESTRUTURA: Grau (fraca a moderada); Tamanho (média); Tipos (prismática que se desfaz em moderada média/pequena e blocos subangulares) - CEROSIDADE: Quantidade (comum); Grau (fraca) - CONSISTÊNCIA: úmida (firme)

B2 - PROFUNDIDADE: 99 a + 140 cm - COR: anexo 03 - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Gradual) - COR: anexo 03 - ESTRUTURA: Grau (moderada); Tamanho (pequena e média); Tipos (prismática que se desfaz em blocos subangulares) - CEROSIDADE: Quantidade (comum); Grau (moderada) - CONSISTÊNCIA: úmida (firme)

Perfil 13

DATA: 2011

CLASSIFICAÇÃO: NEOSSOLO LITÓLICO

LOCALIZAÇÃO: município de Campo Belo do Sul, Santa Catarina

LOCALIZAÇÃO GEOGRÁFICA: 28°01'33,41"S; 50°50'48,16"O.

ALTITUDE: 909 m

LITOLOGIA: riolito, irodacito com amígdalas

FORMAÇÃO: Serra Geral

PERÍODO: Juro-cretáceo

MATERIAL DE ORIGEM: produto da alteração da rocha citada anteriormente

PEDREGOSIDADE: ligeiramente pedregoso

ROCHOSIDADE: não rochoso

SITUAÇÃO DECLIVE/COBERTURA:

RELEVO LOCAL: suave ondulado
ondulado

REGIONAL:

EROSÃO: não aparente

DRENAGEM: bem drenado

VEGETAÇÃO: mata de araucária

USO ATUAL: plantio de pinus

CLIMA: Cfb (Köppen)

DESCRITO E COLETADO POR: Jaime Almeida, Luciane Costa de Oliveira, Fabrício Tondello e Ildegaridis Bertol

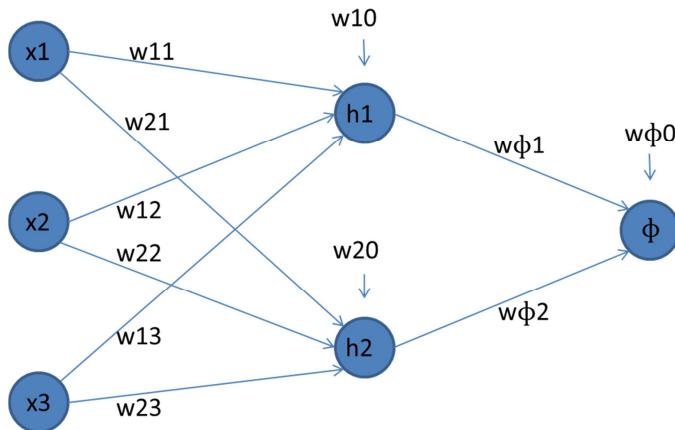
DESCRIPÇÃO MORFOLÓGICA:

A1 - PROFUNDIDADE: 0 - 13 cm - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Clara) - COR: anexo 03 - ESTRUTURA: Grau (fraca); Tamanho (média e grande); Tipos (blocos angulares e subangulares) - CONSISTÊNCIA: úmida (firme) - OBSERVAÇÃO: evidência de compactação superficial

A2 - PROFUNDIDADE: 13 - 33 cm - TRANSIÇÃO: topografia (Horizontal/Plana); Nitidez (Clara) - COR: anexo 03 - ESTRUTURA: Grau (fraca a moderada); Tamanho (pequena e média); Tipos (blocos subangulares e granular esferoidal) - CONSISTÊNCIA: úmida (friável a firme)

Apêndice B – Pesos das RNAs gerados pelo software WEKA

Procedimento para calcular a FPT gerada pela RNA. Seja a rede abaixo:



onde x_1 , x_2 e x_3 são as entradas, h_{11} e h_{12} são os nós da camada oculta, w 's são os pesos associados às entradas, e $w\phi$'s são as 'bias'.

Então os dois nós da camada oculta são representados por:

$$h_1 = \frac{1}{1+e^{-z_1}} \text{ e } h_2 = \frac{1}{1+e^{-z_2}}$$

onde

$$z_1 = w_{10} + w_{11} \cdot x_1 + w_{12} \cdot x_2 + w_{13} \cdot x_3$$

e

$$z_2 = w_{20} + w_{21} \cdot x_1 + w_{22} \cdot x_2 + w_{23} \cdot x_3$$

Finalmente a camada de saída é dada por:

$$\phi = w_{\phi 0} + w_{\phi 1} \cdot h_1 + w_{\phi 2} \cdot h_2$$

Seguindo o exemplo acima, calcular a FPT (ϕ) gerada a partir dos dados da tabela abaixo (CC10, A+B).

Calculando os z's.

$$z1 = -2,48 + 0,89silte + 0,91argila + 0,88ClasseAF \\ + 0,49ClasseAG + 0,59mo - 0,44Dp \\ - 2,98Ds$$

$z2, z3, z4, z5$ e $z6$ são calculados como $z1$ e os pesos correspondem aos valores correspondentes aos nós 2, 3, 4, 5 e 6 da tabela. Substituindo $z1$ em $h1 = \frac{1}{1+e^{-z1}}$, obtemos o $h1$.

Finalmente

$$\phi = 0,21 - 2,67 \cdot h1 - 2,22 \cdot h2 + \dots - 0,80 \cdot h6$$

Modelo RNA1

HORIZONTE A+B

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-2.4884773	-3.4774779	0.0649668	-1.3650235	-3.0916358	-2.8618965			
	node1	node2	node3	node4	node5	node6	linearnode	Teta(L)	
silte	0.8948542	2.1680638	-0.8006359	0.3705497	1.3760545	-0.7035413	-2.6757838	0.2146789	
argila	0.9061473	2.4634636	-0.971188	-1.1358799	3.6154184	4.2398209	-2.2223002		
ClasseAF	0.8820339	-1.0660556	0.8632314	1.2719166	-2.0277293	-1.2431166	2.1862096		
ClasseAG	0.4953553	1.3844001	0.7063467	1.3571828	1.2479435	0.9534294	-2.2729128		
mo	0.5915236	1.5608822	4.6603806	-0.4913476	0.0468744	2.0495822	0.9422402		
Dp	-0.4456706	-2.3140558	0.3085888	0.254135	-2.2482952	-1.5321353	-0.8034617		
Ds	-2.985571	3.3238438	-1.0738817	-0.1673763	-2.6573228	-5.2914627			

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-1.7467538	-3.1897512	-1.1982924	-1.6108598	-4.3396	-3.0483583		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	0.5546931	3.4588353	1.0569285	0.9777692	1.375224	0.0681891	-1.4838712	0.1152067
argila	-0.5959268	0.8362057	-0.3026777	-1.4077289	2.6931915	2.1240449	-2.5675764	
ClasseAF	0.8989199	-0.3787243	-0.1457806	1.5007959	0.3105454	0.5873547	3.3384724	
ClasseAG	1.6138423	1.0342354	1.3390376	1.236186	1.2638403	0.9178682	-1.3553908	
mo	-0.2886617	6.3093445	3.2377883	-1.1938473	-4.5485057	-1.3787585	0.8682734	
Dp	-0.2353783	-2.769151	-0.7566635	0.1815995	-0.770352	-0.494691	-1.0522411	
Ds	1.4445057	1.0562641	-1.0353321	-2.099595	-3.1053853	-5.838981		

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-1.097701	-0.8910445	-5.0740139	-0.3361055	-1.9423523	-0.1728095		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	3.1518219	-3.2536817	2.4164515	-1.1660377	0.6286123	1.3658379	-0.6342985	0.1532748
argila	-2.5476275	0.6583286	2.5693184	-0.7112959	-2.1145695	-2.3120176	1.1184379	
ClasseAF	0.6434627	-0.7777804	1.0019913	1.7214162	1.0543316	0.6016246	1.6284152	
ClasseAG	1.1485852	4.3185514	0.7300996	0.2332683	3.5679102	1.1451274	-0.7592087	
mo	-1.0645292	3.3749867	-4.4445388	0.0574916	0.5447722	2.6727444	-1.8858072	
Dp	-1.1042463	1.6914	-0.6831737	-0.0762449	0.923065	-1.8312029	0.4857799	
Ds	3.5767503	-1.8020741	0.0283412	-5.1144931	-0.4993219	-2.3444982		

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-1.6169578	-5.1603897	-2.990013	-2.4203098	-0.3026223	-0.0706013		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	2.5342198	3.1400819	-1.5166502	0.3833967	-1.2104143	1.0355765	-1.5281216	-0.1116061
argila	-3.9702765	2.8229183	2.1686861	0.6998022	1.8863493	-1.8612832	-1.1991177	
ClasseAF	2.6141887	3.1390878	2.5658767	2.3495304	0.4286444	2.2505773	2.3969319	
ClasseAG	1.8993847	-0.6349449	-0.3182736	-0.7026374	-1.5123076	-1.3881607	-1.2796827	
mo	1.1781591	0.487609	2.3147744	-1.3833038	2.0203348	2.6184872	-0.5039318	
Dp	-0.9735509	-4.1703273	-2.0547059	1.1271222	-1.2086835	-1.1042024	1.5424704	
Ds	-0.1659939	-3.3271149	-1.9297961	-2.0547955	7.4641979	0.1913118		

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-1.4228862	-4.6552131	-1.1708857	-2.0269539	-3.7162443	-0.3314163		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	-1.115779	2.3517344	2.1977441	-1.3885412	1.6379614	-1.023087	-1.603416	-0.284926
argilla	0.1458031	2.1681918	0.2515767	1.1531081	3.5834924	-1.4082785	-1.6139958	
ClasseAF	1.5593252	0.9143926	-0.0611039	0.9026487	-0.3257849	3.9234541	0.9561252	
ClasseAG	0.9132951	0.7752942	0.2059719	1.5476082	-0.2638769	-1.906421	2.3867982	
mo	0.3085723	1.1663282	2.7539532	3.07516	0.7059541	3.7030308	-1.3014953	
Dp	-0.3983831	-4.9625326	0.2138767	-0.9286345	0.4856051	-4.813009	0.7674698	
Ds	0.3278501	-3.0228084	0.9176243	-0.4774226	2.4379593	-1.533252		

HORIZONTE A

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-2.8759371	-0.5908352	-0.3836253	-1.5671522	1.291464	-0.029623			
	node1	node2	node3	node4	node5	node6		linearnode	Teta(L)
silte	2.7358622	-1.3388618	2.2612169	0.2767598	-2.9488941	-1.4175665		-2.8393796	-1.2188223
argila	1.395947	0.2295932	-1.4196308	0.6997802	2.3060955	-0.2812114		2.8889026	
ClasseAF	-0.2375814	0.7029897	-0.0086188	0.7501501	-0.1485834	1.9044609		1.3302965	
ClasseAG	0.3070422	0.7911635	0.287296	0.1673223	-1.8200931	-0.7620076		0.5086165	
mo	4.2951387	6.1850197	1.246796	0.0483374	2.4365714	1.998793		1.3397694	
Dp	-1.8668125	-0.4718024	0.254089	-0.299161	-0.3150847	0.9774775		-0.7232888	
Ds	1.7858632	0.5026608	0.9598602	-0.4862882	-1.5511395	-3.2288583			

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-2.9592806	-0.1220118	-1.3412844	-1.645812	-0.6521405	-0.9048258			
	node1	node2	node3	node4	node5	node6		linearnode	Teta(L)
silte	2.5559999	-1.0577591	1.4398291	0.464811	-1.1449352	-2.0864757		-2.4517143	-0.1439932
argila	1.2050845	-0.6553867	-0.7130766	-1.0801065	3.0913987	2.8366794		3.0856512	
ClasseAF	0.4198944	0.9792659	0.354569	1.2433953	-0.5115841	0.2482408		1.2244929	
ClasseAG	-0.02885	0.6035498	1.0295124	1.6229178	-1.1978871	-0.5911223		-1.773293	
mo	4.0158945	6.2811007	1.4159168	-0.8013751	3.955067	3.6757394		1.05644	
Dp	-1.9880044	-0.2848046	1.4788436	0.9487546	-0.7523916	0.106439		-1.0285991	
Ds	0.8983738	0.7012885	1.07505	0.2714922	-2.2192991	-3.5701429			

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-1.5553954	-1.0479808	-1.2863895	-2.3833757	-1.5851569	0.5445445			
	node1	node2	node3	node4	node5	node6		linearnode	Teta(L)
silte	-0.248857	0.2870836	-1.8955195	1.6470022	-2.1539807	-0.1748036		-1.70026	-0.385469
argila	-0.4538832	-0.35162	0.0190616	0.1858032	2.3122668	0.6419601		0.9721185	
ClasseAF	0.7356409	1.0004583	-1.7601175	-1.9041446	0.6362056	-3.7437546		2.8464167	
ClasseAG	1.9317987	0.3995291	5.6637011	4.0972548	0.6437901	3.322317		-3.0283407	
mo	-1.1595953	1.2014334	4.1731295	-0.9692526	2.1764612	-0.4827064		-0.6427569	
Dp	1.6258992	0.4823739	1.3758845	-0.1591347	0.7281965	0.266434		0.9016988	
Ds	-0.5277209	-0.4139627	-0.787077	-0.8202591	-4.2370939	-0.945747			

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-0.6984367	0.3521772	-0.2378352	0.1596367	-3.4734337	-1.8785951			
	node1	node2	node3	node4	node5	node6		linearnode	Teta(L)
silte	-0.0553448	-1.2441787	-4.8729689	-4.7700242	0.4892291	3.0375079		0.7685489	-0.4515592
argila	0.1080619	-0.6085084	-0.1720735	0.6181778	3.0157613	-1.4143132		1.1649111	
ClasseAF	0.1319128	-1.3137445	7.0878084	1.5323601	1.0226657	0.3384134		1.8046926	
ClasseAG	0.6652502	3.0779219	-4.2415195	1.3283032	-0.4133712	1.1024456		-2.1201263	
mo	1.8471356	2.0441052	3.810846	2.2659665	3.3345855	3.6567107		-1.3448102	
Dp	-0.4049431	0.1155705	-0.6059074	-0.0655128	-1.0512545	1.8794565		1.6345879	
Ds	0.3124051	1.0705837	-1.7945491	1.8241743	0.3625666	2.5993128			

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.5060031	0.1213119	-1.2797989	0.5836734	-2.0458501	3.1571093			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	-1.2933097	-0.6236247	-1.0831815	-0.7695054	2.0160547	-2.0683455	1.1239065	-0.4751405	
argila	0.8079916	-0.3697749	-0.4932051	-1.3701477	0.1713362	-3.989236	0.6218638		
ClasseAF	0.5717387	-2.2513095	4.3596004	0.8116655	-0.9906392	4.084886	1.1440087		
ClasseAG	1.477442	3.7608321	-2.2725627	0.5148741	2.2519162	-3.0646607	-2.2499139		
mo	2.7701301	0.5187436	1.5641691	0.9276252	0.2479811	3.7420468	2.0775465		
Dp	0.4809765	0.0381523	-1.6359329	1.9633949	2.1030434	2.1141184	1.0518332		
Ds	-0.903917	1.6071413	2.3179979	2.5074007	1.641399	2.5216891			

++++++

HORIZONTE B

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.9825587	-0.7539985	-0.9594153	-1.6190455	-1.1641074	-1.2863309			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	2.0038854	3.6340309	-0.6169489	2.0161288	-0.7284973	-0.0220916	2.1051026	-0.035898	
argila	-0.3404693	-3.2187865	-0.4741892	-0.2284611	-1.1509194	-0.221932	-1.1262783		
ClasseAF	-1.3435887	1.233341	-2.9384882	1.6529905	-0.9152563	-0.6747754	1.1876782		
ClasseAG	2.9927786	0.6536618	5.3318441	-0.6328685	4.4954971	2.7320945	1.608688		
mo	3.4466252	0.6151932	-2.9420076	0.6459302	-3.6519579	0.7218597	-0.8525272		
Dp	-3.0428871	1.2360026	-2.3697432	0.963843	-1.4197848	-2.3791172	-1.973005		
Ds	-1.9593743	-1.5678115	1.5641546	1.390369	6.4182197	-1.505446			

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-3.0931379	-3.1656547	-2.2224137	-3.672957	-1.4114621	-2.4855728			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	0.4050012	2.1515636	-0.0299955	1.8307433	-0.2907858	-0.1097632	-1.383195	0.0791056	
argila	1.8841042	0.0952409	4.618576	0.0980977	-1.5154904	0.5502889	-1.266362		
ClasseAF	-0.1538954	1.2264937	-1.008585	1.8959608	1.1586648	1.5750149	0.9101665		
ClasseAG	2.0398413	1.4855487	3.6133931	2.8479104	2.758823	1.2844232	-2.3426862		
mo	-1.0019728	-1.6278316	-5.1808826	-2.7258624	-4.2793708	-1.8312896	-0.7015481		
Dp	-1.7402958	2.399864	-2.4559599	-1.4880092	-2.215413	-0.4240607	-1.6135596		
Ds	0.0028992	-1.9160532	1.5492055	1.2193437	7.3792434	-3.402192			

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-2.1422965	-1.3860792	0.2514871	-4.9335954	-0.6714355	-1.5672948			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	2.0081718	0.2082593	-0.5012539	4.5457797	0.9829181	3.6234878	-0.6799826	0.1136561	
argila	1.3526068	0.1672609	-2.9980144	3.9131014	-1.3124119	-0.1226265	0.0263169		
ClasseAF	1.4418476	0.7379732	1.6850885	-2.1674446	0.4535142	-0.8918953	-1.3290833		
ClasseAG	-1.6201304	0.7624604	1.6402222	1.3278701	1.2750615	0.5898787	2.0337303		
mo	0.8359576	1.2398664	2.6086828	-2.019134	4.1574314	0.0399124	1.6250805		
Dp	0.2062557	0.1809163	-2.2089531	-0.3788939	-2.1801736	0.2095741	-0.8543928		
Ds	-4.2462684	-0.7683512	-1.4695919	0.941892	-1.4302684	2.0526722			

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-2.8412594	-1.6803842	-0.2933562	-0.5090867	0.2972472	-3.1876528			
	node1	node2	node3	node4	node5	node6			
silte	0.1667102	0.4849803	-1.3276221	-3.3346038	0.3996897	3.5204328	linearnode	Teta(L)	
argila	1.7156102	-0.9850978	-1.9068641	-1.9563253	-1.4991213	4.7478452		3.0354763	-0.4045249
ClasseAF	-1.8289242	2.0936479	1.1681356	-0.1964871	-4.2468833	-5.2276835		1.4336815	
ClasseAG	3.7758908	0.8496529	2.3541242	5.5538947	5.4599298	2.0245892		-1.5488299	
mo	1.0891531	1.1634333	3.7545498	2.7818879	3.4829117	1.8545353		-1.9891461	
Dp	-0.4601908	-2.6113495	1.2469391	-2.7393597	-0.1391019	-0.9814248		1.6329302	
Ds	-2.2256827	-0.6429295	-3.5381672	-0.2098318	1.1863273	4.4064459		-0.6172097	

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.4399449	-1.6813584	-1.3320486	-0.508968	0.4586459	-3.237824			
	node1	node2	node3	node4	node5	node6			
silte	-0.3810492	1.1171345	-2.9203084	-0.7893701	1.527686	4.1897006	linearnode	Teta(L)	
argila	-1.5214042	-2.1934518	-2.3306842	-0.3696203	-1.5786811	4.5813459		2.1294344	-0.3570382
ClasseAF	1.7224824	1.0591521	0.1631347	0.6672344	-5.3197352	-6.360289		-1.864662	
ClasseAG	2.1293508	2.809882	6.5619157	0.9399419	5.585582	2.9584336		-1.4248738	
mo	1.5993842	-1.3266135	2.5180168	2.3167028	3.5615544	1.6312882		1.3429664	
Dp	-3.5621444	1.3032855	-5.3618369	0.5746083	0.310642	-0.564151		-0.6499456	
Ds	0.218603	-3.405401	1.2484561	0.4294891	2.5850642	5.1172452			

Modelo RNA2

HORIZONTE A+B

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-0.4990401	-0.4762154	-0.5787303	-0.9401396	-0.9490813	-0.4691724			
	node1	node2	node3	node4	node5	node6			
silte	-0.005085	0.0049656	0.104338	-0.1651503	-0.1192354	0.0259718	linearnode	Teta(L)	
argila	-0.2161827	-0.1496773	-0.4753032	0.0366396	-0.1558846	-0.1498543		0.653493	
AF	0.3124604	0.171562	0.2171171	-0.1266086	-0.1302428	0.1994044		-0.7990099	
mo	0.1457103	0.2595082	-0.0982423	0.1357597	-0.1510162	0.2814914		-1.2627816	
PT	-0.0364626	0.0945036	-0.0194805	-0.0157827	-0.1421142	0.0630107		1.4713176	
0,06	-0.367594	0.7413269	-0.4986721	-1.044766	1.3390681	0.6602943		0.5678461	
Ds	0.0734723	0.0238197	0.2629587	-0.042292	0.2305494	-0.0273998			

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.0639587	-1.0809735	-1.2831814	-1.7521761	-2.1726425	-1.0294124			
	node1	node2	node3	node4	node5	node6			
silte	0.1610431	-0.0126058	0.2329425	-0.1751123	0.0215492	0.1979674	linearnode	Teta(L)	
argila	-0.2880113	-0.6937737	-0.5937031	0.150443	0.2608379	-0.4940084		0.3819733	
AF	0.4743621	0.3612276	0.684887	-0.4642835	-0.1301132	0.4482269		-0.914626	
mo	0.5004606	0.71717	0.1773297	0.0463727	-0.238379	0.6581799		-0.9989673	
PT	-0.1325802	0.1092743	-0.0518089	-0.083099	-0.2357034	0.0394853		1.4375894	
0,06	-0.5389632	0.6061213	-1.5310505	-1.9676814	2.6366026	0.4271044		0.2320886	
Ds	0.1608005	-0.1023821	0.2734381	-0.3904072	0.4954168	-0.1141791			

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	0.6590777	-1.4494983	-3.4185408	-1.5147162	-2.551001	-0.3591014		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	1.1181029	0.045839	0.7728314	0.0327542	-0.4621642	-0.8711187		-0.0925904
argila	-0.5746405	0.309342	0.4091268	0.2483909	0.5354641	0.8308869		
AF	3.356035	0.9616446	-0.9478515	0.6593868	-0.8317151	0.7488907		
mo	0.1770458	0.9540332	-0.3528049	0.8110973	-0.1910004	-0.3175513		
PT	0.6441478	0.1734604	0.813266	-0.0436934	-0.3239009	-0.8473528		
0,06	-0.4202004	0.167301	0.2299669	-0.79408	-4.0634763	-0.3907199		
Ds	0.8038305	-0.043553	0.8463468	0.2099021	0.3228284	1.44128		

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-3.5856667	-6.3070134	0.3688923	-2.3796399	-0.7012024	-0.0052908		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	1.3764452	4.9354078	-0.8380649	-0.3024748	-3.7634045	2.1078887	-2.2846138	-0.277677
argila	-5.2348134	4.2030859	-1.6384798	-0.4935908	0.2552842	-2.5275279	-1.8470859	
AF	1.4000426	0.422701	3.5949643	2.5614137	-0.1374128	2.351593	0.6901619	
mo	3.2114883	-2.9753079	1.2965327	3.9037203	1.0633473	1.4483873	2.2260299	
PT	0.0352538	1.6432239	-0.1877781	0.4880005	0.0536739	1.3934149	-0.3158978	
0,06	-0.3522637	0.7006528	9.7265565	0.1878358	1.3419583	1.4118724	0.7735634	
Ds	-0.3508945	1.4639727	-3.6248157	-0.2598752	6.0040673	2.6503255		

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-2.2130706	0.2821636	-2.0719158	-3.6542377	-5.4595025	-0.4935029		
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)
silte	-0.0241951	0.1882798	0.7920516	2.3807728	4.3913003	2.8669113	-0.9700	0.1476495
argila	1.0645372	3.008881	3.7363728	3.9441211	4.6104497	1.9876266	-0.7178102	
AF	1.3136056	-1.5435588	3.5851372	-0.2445244	0.5565825	5.404652	1.4711115	
mo	-2.8306484	2.7000747	-0.3795745	-0.5737548	-1.4309816	0.6876879	0.8384372	
PT	-0.638461	-0.2257427	-0.8105659	-2.7728184	1.2722364	1.2703182	-2.0658294	
0.06	0.0863554	-5.6559643	0.504315	-2.4534455	1.1867279	3.1491813	2.711648	
Ds	-0.0299149	0.4741066	-2.6395076	1.9646967	3.0760898	0.6361092		

+++++

HORIZONTE A

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)		
	-0.7671222	-0.7881455	-0.3586344	-0.3920474	-0.5740833	-0.5481952		
node1	node2	node3	node4	node5	node6		linearmode	Teta(L)
silte	-0.3242473	-0.2176623	-0.109205	0.0159869	-0.1054463	0.0365224	-1.2333892	-0.2740833
argila	-0.1480731	-0.2868663	-0.1495501	-0.001994	-0.3955234	-0.6472874	1.1946821	
AF	-0.2609944	-0.38396	0.1967824	0.2334011	-0.1825179	0.0282805	0.4766467	
mo	0.5363236	0.2389071	0.1585029	0.201612	0.221788	-0.0322654	0.0773335	
PT	-0.0603655	-0.09552374	0.1045086	0.0217694	-0.1040524	-0.0386709	1.0819175	
0,06	-0.9666018	1.1488845	0.5030586	0.1032191	0.10710322	-0.5657917	-0.9414087	
Ds	0.2820917	0.480809	-0.1270944	0.0083243	0.2842076	0.3106917		

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.2935792	-2.1663886	-0.9175303	-0.9174196	-1.3089822	-1.4471416			
	node1	node2	node3	node4	node5	node6			
silte	-0.1869809	-0.9931265	0.0239264	1.19E-04	0.3678959	0.2206093	linear node	Teta(L)	
argila	0.3271996	0.3198738	-0.3123182	-0.0682055	-0.4799717	-0.6333857			1.3168899
AF	-0.0724364	0.0555562	0.4960513	0.5557176	-0.722491	0.0504462			0.3281947
mo	1.0941466	0.4787536	0.3615991	0.4340569	0.2804984	-0.4228326			0.0746968
PT	-0.0029342	0.0357863	0.0057624	-0.0024844	0.1789922	0.1974822			1.0438621
0,06	-1.698572	2.0768469	0.5128684	0.1064019	1.2032284	-1.2661807			-1.1433585
Ds	0.3095213	1.0730067	-0.1893619	-0.0127628	0.6905851	0.2314199			

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.3067866	-1.5477541	-1.5362785	0.6099947	-2.5729679	-2.9889221			
	node1	node2	node3	node4	node5	node6	linear node	Teta(L)	
silte	-1.2819984	0.1222709	0.1142336	0.1691472	0.4429863	-1.1986471			-1.4278076 0.4808739
argila	0.8712693	-0.0636935	-0.0691988	-0.5295474	0.0943932	0.6263186			-0.0454554
AF	1.088379	0.3318205	0.3885901	3.1296353	-1.3229199	0.1395605			-0.0647905
mo	1.4915844	0.4655385	0.4470004	-1.5406717	0.501225	0.6060881			-0.7341442
PT	1.00121213	-0.2302203	-0.2509321	-0.5204097	0.2748162	1.0440525			-1.3308652
0,06	-0.138345	0.7035272	0.6561921	0.2738048	-3.9892522	3.4416057			1.6990
Ds	0.0087955	0.246027	0.1717829	-1.5578942	0.8121945	1.6989172			

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-2.0062004	-2.1926874	-1.4210062	-0.3016097	-0.2073458	-0.7097814			
	node1	node2	node3	node4	node5	node6	linear node	Teta(L)	
silte	1.0151424	-2.8098906	-0.2360304	2.473656	-4.3279431	4.6878238			-1.5629438 0.9921135
argila	-1.5999635	2.9677352	-0.3862583	1.0198098	1.7642539	-0.3384795			1.3678062
AF	1.5449671	1.8818568	2.4378444	-3.326868	3.5852462	2.8680373			1.2754781
mo	1.0419741	2.2448916	0.1470705	0.3588331	1.1942265	0.6063921			-1.4800301
PT	-1.0431334	1.0749788	1.1420016	0.3383586	-0.2008053	-1.0721208			-1.6565451
0,06	-0.6427693	2.2439273	1.0514456	-8.371353	6.4163021	-1.1800961			0.818366
Ds	-0.1768715	-0.3818929	1.6425549	1.6144652	0.5518406	0.3406987			

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-2.0964817	-2.2444564	-2.1840126	-0.9513318	-1.0036274	-1.659794			
	node1	node2	node3	node4	node5	node6	linear node	Teta(L)	
silte	1.674742	-0.8049683	-0.1063961	-0.0758883	-0.3740342	-0.1143373			2.1921758 0.5682362
argila	1.2738081	2.0507841	0.6747416	1.797894	-1.1416752	2.4655777			0.5627705
AF	0.753411	1.7292548	0.4330332	4.2020494	2.3491395	2.5706628			-1.2594386
mo	2.1993318	0.928642	0.2440897	1.4230548	0.6956288	2.0877945			-0.9072884
PT	-3.1109338	0.7087728	-0.0871624	0.441241	-4.7889519	1.0365072			-1.0553928
0,06	1.9926777	-0.238424	1.3976907	-6.0822921	0.1147597	0.4397796			1.7611308
Ds	2.3359578	-0.3588832	1.1112958	1.5672437	-1.7728981	0.6156618			

++++++

HORIZONTE B

CC10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-0.5807161	-0.5131003	-0.6943531	-0.8333288	-0.9663482	-1.1231626			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	0.2303622	-0.0466547	0.1139594	-0.0702781	0.2002553	-0.1924379		-0.0620118	0.0705305
argila	-0.1149474	-0.01157	-0.0011401	-0.2525505	0.2602072	-0.4149217		0.7642731	
AF	0.3878345	0.1861281	0.1065538	0.256294	-0.1181176	0.3522267		1.2655789	
mo	0.3615015	0.2362216	0.3889775	0.4843803	0.0860325	0.638064		-0.6504935	
PT	0.0133909	0.2149631	-0.0685302	-0.0253589	0.003836	0.1185652		-1.3189037	
0,06	0.0717516	0.9439293	1.5281832	-0.2973772	-1.5542333	-0.3776856		-0.8762149	
Ds	-0.0101611	0.090862	0.1624386	0.5654585	-0.3684334	0.7573151			

CC33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-0.8563647	-0.8369746	-1.5381354	-0.9790656	-0.8879317	-1.4333432			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	0.1550918	0.1056926	0.1949297	0.1475838	-0.0549459	0.1367987		-0.0813806	0.3342817
argila	-0.1705128	-0.0449199	0.5281517	-0.1317979	0.2692155	-0.5366136		0.3354585	
AF	0.5041926	0.5189191	0.4522047	0.2342482	-0.1309162	0.5521559		1.1598651	
mo	0.5012524	0.4281786	0.1737447	0.6691863	-0.216281	0.8121734		-0.4882185	
PT	0.0057743	-0.0754975	-0.0355239	-0.1339617	0.0683406	-0.023593		-1.1156949	
0,06	-0.1360003	0.775847	0.20922954	-0.4905352	-2.4881992	-0.956997		-0.922387	
Ds	0.0681142	0.0355244	-0.3168886	0.6280365	-0.9435044	0.9974234			

PMP	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.3992365	-1.2415119	-1.6032641	-1.9595886	-0.7113667	-1.971816			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	-0.8880531	0.2722194	-0.1238762	1.8614269	0.4546786	-0.0559014		0.8280915	-0.0080561
argila	-0.2056393	-0.3141442	-0.5145663	0.20868649	-0.8257661	0.8245676		-0.2708029	
AF	0.0136217	0.7195035	0.5445785	0.572977	0.4934804	0.0553382		0.7646686	
mo	0.2858848	0.6067645	1.7476166	-0.6396213	0.7531506	-0.018982		1.2756398	
PT	0.1820405	0.1778633	-0.0225602	0.2881002	0.7975507	-0.4113921		-1.0583313	
0,06	1.1778409	-0.1845574	0.4169281	1.5954037	-0.8152959	-2.6452707		-1.1373673	
Ds	0.3844802	-0.0339935	-0.2681004	1.2798905	1.5317225	-0.7743883			

AD10	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-1.0109573	-0.5420748	-2.3703923	-1.9148718	-2.1063655	-1.6474961			
	node1	node2	node3	node4	node5	node6	linearmode	Teta(L)	
silte	-0.4749969	-3.4774822	4.064852	1.1964503	-0.8513023	1.0682033		1.7461371	-0.0899913
argila	-3.9588677	-4.343018	3.0350528	-0.2679428	-1.1287808	2.656043		-1.4582459	
AF	-0.0662379	2.1310749	2.1154165	1.6486068	1.6737974	-1.0926263		-2.1494342	
mo	2.0390742	1.0276199	-1.0284643	3.5491642	-1.8975649	-0.899494		-2.1635415	
PT	0.2242817	-2.0139476	-0.339784	0.8506856	1.2897889	2.6927413		1.1405486	
0,06	3.4892226	0.9199704	-0.0494531	-0.4460257	-1.6243498	-1.5655955		-0.7624117	
Ds	-0.1957699	-2.5817349	-0.6511218	-0.2731688	2.1501647	6.376034			

AD33	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)	Teta(S)			
	-5.0311131	-4.0877073	-2.3518038	-2.5300631	-0.8042507	-4.0389568			
	node1	node2	node3	node4	node5	node6			
silte	-0.8081901	-2.6433173	0.7156591	-3.8587676	-1.7695035	3.8341783	0.6549723	-0.33199	
argila	2.0242956	-0.7292526	-1.5793959	-3.0680391	-3.1233051	5.3063542	-2.7924423		
AF	-0.5096849	-0.1952313	0.5480653	-1.6243932	-0.1521968	-0.9476202	0.8018217		
mo	0.3308371	3.4230038	-0.3221898	0.8789321	3.4554722	-1.1406849	-0.6237414		
PT	0.1980238	2.1924255	1.292058	1.7192461	1.592098	1.2122002	1.4965041		
0,06	7.6025059	1.9259952	-0.2075827	-1.4521364	3.9295696	0.5891229	-1.1168469		
Ds	-4.7079746	0.3023952	1.0681776	-1.2800485	1.5235664	2.8484052			