

FACULDADES INTEGRADAS DE CARATINGA

FACULDADE DE CIÊNCIA DA COMPUTAÇÃO

**UTILIZAÇÃO DE RNA RBF PARA PREDIÇÃO DE
QUANTIDADE DE ÁGUA NO SOLO**

GIÓRGIA ROBERTA NEVES E CARVALHO

CARATINGA
2010

Giórgia Roberta Neves e Carvalho

**UTILIZAÇÃO DE RNA RBF PARA PREDIÇÃO DE QUANTIDADE DE ÁGUA NO
SOLO**

Monografia apresentada ao Curso de Ciência da Computação das Faculdades Integradas de Caratinga como requisito parcial para a obtenção do título de bacharel em Ciência da Computação, sob orientação do professor Glauber Costa e co-orientação dos professores Diego Nunes Brandão e Juliana Mendes Nascente Silva.

Caratinga
2010

Giórgia Roberta Neves e Carvalho

UTILIZAÇÃO DE RNA RBF PARA PREDIÇÃO DE QUANTIDADE DE ÁGUA NO
SOLO

Monografia submetida à Comissão
examinadora designada pelo Curso de
Graduação em Ciência da Computação
como requisito para obtenção do grau de
Bacharel.

Prof. Glauber Costa
Faculdades Integradas de Caratinga

Prof. Jacson Rodrigues Correia Silva
Faculdades Integradas de Caratinga

Prof. Msc Fabrícia Pires Souza Tiola
Faculdades Integradas de Caratinga

Caratinga, 09/12/2010

Dedico este trabalho à minha família e
à todos que passam os dias em busca de respostas.

AGRADECIMENTOS

Aquele que acredita não pode deixar de agradecer a DEUS, pois sem Ele não teríamos os dons, as condições e a vida para realizarmos nosso trabalho.

Agradeço a minha mãe ANA e ao meu pai NIRLEY pela criação, pela liberdade de escolhas, pela fé em mim depositada e por estarem sempre ao meu lado em todos os momentos.

Ao meu irmão WILLIAM DOUGLAS pela confiança, amizade, consideração, compreensão e companheirismo.

Ao meu namorado e amigo GLAUBERT, por ter sido um amigo quando isso é o que se espera de um namorado, e por ter sido meu namorado quando isso é o que menos se espera de um amigo.

Aos meus amigos, orientador GLAUBER COSTA e co-orientadores DIEGO NUNES BRANDÃO e JULIANA MENDES NASCENTE SILVA, pela paciência, pelas conversas, pelo apoio e pela confiança no meu trabalho.

Aos amigos de república, pelas inúmeras conversas e pela tão boa amizade que construímos.

Aos amigos que com certeza participaram do meu trabalho, pela preciosa amizade e pelo constante apoio e incentivo, em especial minha amiga, MARA.

Precisamos dar um sentido humano às nossas construções. E, quando o amor ao dinheiro, ao sucesso nos estiver deixando cegos, saibamos fazer pausas para olhar os lírios do campo e as aves do céu.

Érico Veríssimo

RESUMO

Este trabalho teve como objetivo o desenvolvimento de um sistema para a predição de quantidade de água no solo. Para isso, foram utilizados conceitos de Inteligência Artificial por meio de Redes Neurais Artificiais, que é amplamente utilizada em reconhecimento de padrões.

A predição pode ser feita através de diferentes métodos. Para isso é necessário que amostras do solo sejam recolhidas e analisadas em laboratórios específicos de física do solo, esses resultados são então utilizados como variáveis na modelagem.

Neste trabalho, o método utilizado foi a Rede Neural *Radial Bases Function*, construída através do simulador JavaNNS. A rede teve como entradas as variáveis que mais influenciavam na retenção de água no solo, tais como areia, argila, silte, densidade do solo, material orgânico e porosidade, como saída foram estabelecidos os valores da Capacidade de Campo e do Ponto de Murcha Permanente, ambos de suma importância para a predição de água no solo.

Após treinamento, a validação dos dados foi realizada e os resultados encontrados foram comparados com os resultados de outros estudos, verificou-se então que o método utilizado obteve resultados satisfatórios e uma melhora significativa em comparação com os demais.

Este trabalho poderá ser utilizado na predição de água no solo com intuito de melhorar o processo em relação ao tempo e custo encontrados com os métodos atuais.

Palavras-chave: Redes Neurais Artificiais, Predição de Água no Solo, Capacidade de Água Disponível, Capacidade de Campo, Ponto de Murcha Permanente.

ABSTRACT

This paper aims to describe the development of a system to predict the quantity of water in the soil. For that, Artificial Intelligence concepts were used, such as Artificial Neural Networks. Those networks are commonly used to patterns recognition.

Prediction can be made through different methods. For that, it is necessary to obtain samples of soil and analyze them in soil physics labs. The results are then used as variables in the model.

The Neural Network Radial Bases Function was the method used in this work, it was built using the JavaNNS simulator. The variables that influenced soil water retention the most were used as network inputs, such as sand, clay, silt, soil density, organic material and porosity. The output are the values of Field Capacity and Permanent Wilting Point which are very important to prediction soil water.

After training, data validation was done and the results found were compared with results from other studies. We verified that our method obtained satisfactory results and a significative improvement over the others.

This work can be used to predict soil water retention in order to improve process time and costs of current practices.

Keywords: Artificial Neural Networks, Predict Soil Water, Available Water Capacity, Field Capacity, Permanent Wilting Point.

LISTA DE ILUSTRAÇÕES

FIGURA 1 - Perfil de um solo.....	20
FIGURA 2 - Capacidade de água disponível e estado físico do solo (VENZELA e ANDRADE, 2007).....	22
FIGURA 3 - Área para pesquisa após saturação do solo (PAIXÃO <i>et. al.</i> , 2004).....	24
FIGURA 4 - Exemplo da regra Hebb.....	27
FIGURA 5 - Estrutura Básica de um Neurônio.....	30
FIGURA 6 - Fenda sináptica.....	31
FIGURA 7 - Neurônio Artificial (GOEDTEL <i>et. al.</i> , 2006).....	31
FIGURA 8 - Neurônios conectados de forma total e unidirecional	39
FIGURA 9 - Neurônios conectados de forma parcial e bidirecional	39
FIGURA 10 - Rede de Base Radial (CASTRO, 2001).....	41
FIGURA 11 - RNA modelada no simulador JavaNNS (FISCHER <i>et. al.</i> , 2007).....	47
FIGURA 12 - Painel de Controle (FISCHER <i>et. al.</i> , 2007).....	48
FIGURA 13 - Exemplo de gráfico de erro (FISCHER <i>et. al.</i> , 2007).....	49
FIGURA 14 - Região Norte Fluminense e área do PROJIR (rachurada).....	51
FIGURA 15 - Exemplo de parte do Banco de Dados utilizado.....	52
FIGURA 16 - Arquitetura da RNA RBF.....	54
FIGURA 17 - Demonstração de parte da Arquitetura.....	56
FIGURA 18 - Exemplo de um padrão de treinamento.....	57
FIGURA 19 - Painel de Controle.....	59
FIGURA 20 - Erro gráfico.....	59
FIGURA 21 - Arquivo de registro gerado durante o treinamento da rede	60
FIGURA 22 - RNA após o treinamento.....	61

LISTA DE TABELAS

TABELA 1 - Modelo de entrada e saída da RNA.....	54
TABELA 2 - Resultados do RMSE e R2 obtidos.....	62
TABELA 3 - Principais resultados encontrados por Brandão <i>et. al.</i> (2006) ao prever CC e PMP simultaneamente.....	67

LISTA DE GRÁFICOS

GRÁFICO 1 - Função Linear.....	35
GRÁFICO 2 - Função Limiar.....	35
GRÁFICO 3 - Tangente Hiperbólica.....	36
GRÁFICO 4 - Função Sigmóide.....	36
GRÁFICO 5 - Função Limiar.....	36
GRÁFICO 6 - Demonstração dos mínimos locais e do mínimo global.....	38
GRÁFICO 7 - Valor de RMSE para CC e PMP preditos simultaneamente.....	64
GRÁFICO 8 - Valor de R2 para CC e PMP preditos simultaneamente.....	64
GRÁFICO 9 - Valor de RMSE para CC e PMP preditos individualmente.....	65
GRÁFICO 10 - Valor de R2 para CC e PMP preditos individualmente.....	66

LISTA DE SIGLAS

CAD - Capacidade de Água Disponível

CC - Capacidade de Campo

PMP - Ponto de Murcha Permanente

PROJIR - Projeto de Irrigação e Drenagem do Norte Fluminense/RJ-Brasil

RBF - *Radial Basis Function*

RNA - Rede Neural Artificial

Kpa - Unidade padrão de pressão e tensão, Quilopascal(10^3)

Mpa - Unidade padrão de pressão e tensão, Megapascal(10^6)

SSE - Soma dos Erros Quadráticos

MSE - Erro Quadrático Médio

RMSE - Raiz Quadrada do Erro Médio

R2 - Coeficiente Múltiplo de Determinação

SUMÁRIO

1	INTRODUÇÃO.....	15
2	REFERENCIAL TEÓRICO.....	19
2.1	PREDIÇÃO DE QUANTIDADE DE ÁGUA NO SOLO.....	19
2.2	REDES NEURAIS ARTIFICIAIS.....	25
2.2.1	Histórico das RNAs.....	25
2.2.2	Conceitos de RNAs e suas Aplicações	29
2.2.3	Neurônio Biológico e Sistema Nervoso.....	30
2.2.4	Neurônio Artificial.....	31
2.2.5	Aprendizado – Treinamento.....	32
2.2.6	Função de Ativação(Φ).....	34
2.2.7	Funções de Saída ou de Transferência(f).....	34
2.2.8	Ajuste dos Pesos (w).....	37
2.2.9	Correção do Erro (Δ).....	37
2.2.10	Taxa de Aprendizagem (η).....	38
2.2.11	Topologia.....	38
2.2.12	Redes Neurais Multi-Camadas.....	40
2.2.13	Algoritmo de Treinamento Backpropagation.....	40
2.2.14	Tipos de Redes Neurais.....	41
2.2.14.1	Rede Neural com Função de Base Radial – RBF.....	41
2.2.14.2	Redes Competitivas – Mapa Auto-Organizável de Kohonen.....	44
2.2.14.3	Redes Recorrentes	45
2.2.14.4	Redes Neurais de Memória Associativa	45
2.2.15	Aplicações.....	46
2.2.16	Simulador de Rede Neural Artificial JavaNNS.....	46
3	METODOLOGIA.....	50
3.1	REDES NEURAIS ARTIFICIAIS RBF APLICADAS NA PREDIÇÃO DE QUANTIDADE DE ÁGUA NO SOLO.....	50
3.1.1	Coleta e Separação dos Dados.....	50
3.1.2	Aplicação de Redes Neurais.....	52
3.1.2.1	Padrões de Entrada.....	55
3.1.2.2	Treinamento.....	56

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	62
5 CONCLUSÃO.....	68
6 REFERÊNCIAS	70

1 INTRODUÇÃO

Ao longo das últimas décadas, o mundo vem passando por mudanças significativas no que diz respeito a utilização de recursos naturais, em especial a água. O consumo de água por pessoa vem aumentando juntamente com a diminuição de sua disponibilidade. Para agravar a situação, o desperdício de água está se tornando cada vez mais intenso com vazamentos pelas ruas, banhos demorados, torneiras abertas sem necessidade, falta de planejamento na gestão dos recursos hídricos na agricultura e na pecuária, entre outros.

“Atualmente, a agricultura irrigada ocupa 17% das terras aráveis do planeta, sendo responsável por 40% da produção mundial de alimentos. Estima-se que até 2025, a atividade agrícola com uso da irrigação irá crescer de 20 a 30 %” (DBO, 2002).

De acordo com a Agência Nacional de Águas (ANA), criada em julho de 2000, tendo como missão “implementar e coordenar a gestão compartilhada e integrada dos recursos hídricos e regular o acesso a água, promovendo seu uso sustentável em benefício da atual e das futuras gerações” (ANA, 2007), a agricultura irrigada é a que mais desvia água da natureza, 70% do volume total extraído de rios, lagos e mananciais subterrâneos.

“A tendência da irrigação, de expandir-se exponencialmente nas regiões onde ainda é pouco usada, aumenta a preocupação com a sustentabilidade da agricultura em muitas regiões do mundo. Já hoje há um superbombeamento de águas subterrâneas e de superfície para a irrigação, e parcela dessas águas é devolvida aos aquíferos e rios, poluída por agroquímicos. Há a urgente necessidade de priorizar atenção e conscientização sobre a importância da água e de assegurar sua disponibilidade futura” (DESOUZART, 2010).

Para auxiliar o uso racional da água na agricultura, faz-se necessário a adoção de técnicas e equipamentos eficientes, pois estima-se que apenas a metade da água utilizada para irrigação chegue até as raízes das plantas (ANA, 2007). No sentido de realizar o manejo correto dos recursos hídricos, algumas técnicas são usadas com o intuito de predizer a quantidade de água existente em uma determinada área a partir de algumas amostras.

A predição de água no solo consiste em fazer uma estimativa da quantidade de água através de amostras do solo recolhidas dentro de uma área e então analisá-las em laboratórios específicos de física do solo utilizando os resultados obtidos em análises estatísticas que permitirão a predição da quantidade de água na área total. Entretanto, tais análises são difíceis e exigem tempo. Sendo assim, a utilização de métodos computacionais capazes de melhorar o processo de predição em relação ao tempo e ao custo tornam-se ferramentas de grande importância.

“A avaliação do processo da redistribuição da água no solo, demanda considerável tempo e apreciável custo, porque as propriedades hidráulicas do solo sofrem extensa variabilidade espacial e estão sujeitas à freqüentes alterações no tempo” (LOYOLA & PREVEDELLO, 2003).

Atualmente vários métodos vem sendo utilizados para predizer a quantidade de água no solo. Nascimento *et. al.* (2005) utiliza o método de funções de pedotransferências, que são funções preditivas utilizadas para estimar a retenção de água no solo a partir de características físicas do solo de fácil determinação, porém a alta margem de erro obtida entre os valores estimados e os observados das funções de pedotransferência indica que outros modelos matemáticos devem ainda ser testados.

Koekkoek e Booltink (1999) utilizaram RNAs para a predição da quantidade de água em solos com pouca variação de textura. Tal trabalho foi aplicado em solos europeus e obteve resultados satisfatórios. Brandão *et. al.* (2006) utilizou a mesma metodologia para predição de água em solos brasileiros. Para solos com grandes variações de textura tal método não se mostrou eficiente porque a rede utilizada construiu aproximações globais e como o solo em questão possui maior heterogeneidade os resultados não foram satisfatórios.

As RNAs podem ser definidas como modelos matemáticos do cérebro, que permitem a representação do processamento da informação dos neurônios biológicos através de suas interconexões em redes. Possuem como princípio a aquisição de conhecimento feito através de exemplos fornecidos para a rede. A partir dessa aquisição a rede passa a associar pontos em comum toda vez que processa as entradas, e após repetir várias vezes a computação, consegue identificar através do levantamento anterior, quais os passos seguintes e como resolver determinada

rotina.

Através de um grande número de elementos simples, denominados neurônios artificiais, conectados entre si as RNAs representam a informação de forma distribuída. Esses elementos executam a soma ponderada de suas entradas e a partir de um certo limiar criam suas saídas.

Uma característica extremamente importante das RNAs é que, diferentemente da análise tradicional, as redes não requerem prévio conhecimento sobre distribuição dos dados para analisá-los. Desde que haja uma relação subjacente entre os dados, mesmo que desconhecida sua representação analítica e/ou estatística, as RNAs podem apresentar um melhor desempenho dos que os métodos estatísticos tradicionais (CASTRO, 2001).

Devido ao fato das RNAs terem se desenvolvido muito nos últimos tempos, obtendo resultados satisfatórios, tornou-se viável a utilização de tal ferramenta neste trabalho, para isso, foi utilizada uma RNA diferente da utilizada por Brandão *et. al.* (2006), com intuito de melhorar os resultados encontrados na classificação de padrões para solos com maior heterogeneidade, verificando assim a capacidade de retenção de água no solo.

Existem vários programas que podem ser utilizados para simular uma RNA, neste trabalho, é utilizado o simulador de Redes Neurais JavaNNs, uma ferramenta desenvolvida pelo Instituto Wilhelm-Schickard de Ciência da Computação, em Tubigen, na Alemanha, para facilitar a elaboração de projetos utilizando RNAs (FISCHER *et. al.*, 2007). Através deste simulador, foi criada e analisada a rede para o problema.

As amostras do solo foram cedidas pelo Departamento de Solos do Instituto de Agronomia da Universidade Federal Rural do Rio de Janeiro (UFRRJ). Essas amostras foram separadas de forma que fossem utilizadas como entrada para a rede algumas variáveis que influenciam na retenção de água no solo. Dessa forma, arquivos foram criados contendo dados para o treinamento e para validação da rede.

Após o treinamento da rede e distinção dos perfis e das características do solo, os arquivos com os dados restantes foram utilizados para os testes de validação. Com isso a rede refletirá em sua saída a representação do estado que o solo se encontra.

Os resultados encontrados foram então comparados com os resultados obtidos por Brandão *et. al.* (2006) onde percebe-se uma melhora significativa ao utilizar a metodologia presente neste trabalho.

Este trabalho está estruturado em seis capítulos. No segundo capítulo é apresentada uma visão geral sobre a predição de quantidade de água no solo, destacando alguns dos modelos desenvolvidos para realizar esta estimativa e o problema em relação ao tempo para se obter respostas devido a complexidade da análise realizada. Apresenta-se também uma introdução às Redes Neurais e ao simulador JavaNNS, fazendo uma descrição dos principais tipos de redes e métodos de aprendizagem, as principais etapas do projeto de uma rede neural, suas principais vantagens e áreas de aplicação.

A descrição do modelo implementado pode ser vista no terceiro capítulo, juntamente com a metodologia empregada e os resultados obtidos.

No quarto capítulo encontra-se a análise e discussão dos resultados.

No quinto e sexto capítulo encontra-se respectivamente a conclusão, sugestões para o desenvolvimento de trabalhos futuros e referências bibliográficas utilizadas.

2 REFERENCIAL TEÓRICO

2.1 PREDIÇÃO DE QUANTIDADE DE ÁGUA NO SOLO

Vários fatores afetam a retenção da água em um solo, mas o principal deles é a textura. Esta determina, diretamente, a área de contato entre as partículas sólidas e a água (REICHARDT, 1990). As partículas sólidas formam um arranjo poroso tal que os espaços vazios, denominados poros, tem a capacidade de armazenar líquidos e gases e se constituem de partículas classificadas de acordo com o tamanho médio dos grãos em areia, silte e argila, cujas proporções determinam a textura do solo (ASSIS, 2007).

Através desse tamanho, os poros podem ser classificados em dois tipos. Macroporos, os quais perdem água com mais facilidade, de acordo com a força da gravidade exercida sobre eles. Microporos que entram em equilíbrio com a força da gravidade, evitando assim que a infiltração ocorra de forma excessiva.

A constituição do solo pode ser vista como um sistema trifásico, onde encontra-se a parte sólida (areia, argila, carbono...), parte líquida (soluções do solo) e parte gasosa (ar do solo). A parte líquida e gasosa ocupam os espaços livres do solo, constituídos pelos poros (VENZELA e ANDRADE, 2007).

O solo é dividido em camadas distintas, no qual um horizonte é qualquer camada que pode ser distinguida visual ou texturalmente das camadas vizinhas acima e abaixo, o conjunto destes horizontes constituem um perfil. O solo do topo é a zona de primeira importância para o agricultor, pois é nele que as sementes são lançadas, as plantas transplantadas e as culturas estabelecidas. Depois do estabelecimento, as raízes exploram também o subsolo que tende a ser menos rico em nutrientes, mas, pelo menos, tão importante quanto o solo do topo pelo fornecimento de água. Abaixo do subsolo, está a camada de rocha (ASSIS, 2007).

Entre as diferentes séries de solo a espessura dos horizontes pode variar enormemente. Os solos geralmente não apresentam todos os tipos de horizontes bem definidos, mas possuem pelo menos parte deles. Para que o tipo de solo seja

definido, o mesmo recebe classificações, como especificado em alguns perfis mostrados na FIG. 1, onde:

- **O:** horizonte com predomínio de matéria orgânica em decomposição;
- **A:** horizonte mais afetado pelas atividades agrícolas, encontra-se material orgânico com estado avançado de decomposição misturado com a fração mineral;
- **B:** horizonte no qual não se pode reconhecer vestígios de rocha-mãe¹;
- **C:** horizonte onde encontra-se muitas características e estruturas da rocha-mãe.

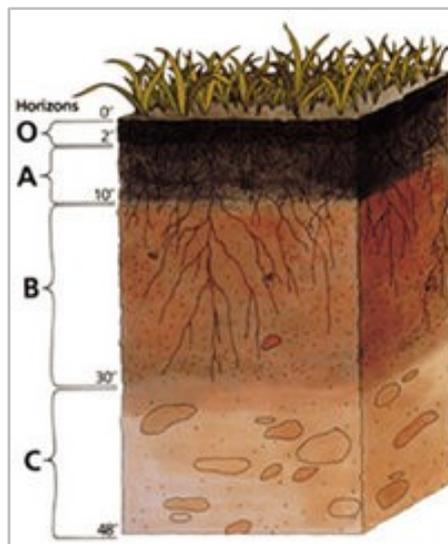


FIGURA 1 - Perfil de um solo

Fonte: <http://www.jornallivre.com.br/128167/quais-sao-os-tipos-de-solo.html>

O processo de predição de água no solo consiste na verificação do ponto de murcha permanente (ausência de água e inviabilidade de determinadas plantações) e da capacidade de campo (presença de água suficiente para o cultivo) nos perfis do solo. Baseado nesses dados, pode-se calcular a retenção de água no solo.

Atualmente é feito um estudo criterioso do solo para identificar qual a melhor

1 Rocha mãe: Rocha sobre a qual há a formação de solo devido a desagregação da mesma. A desagregação pode ocorrer devido a vários fatores, dentre eles, os processos erosivos como o vento e a chuva que desagregam a rocha e provocam alterações químicas que levam à sua fraturação, a temperatura que provoca contrações/dilatações fazendo com que apareçam fendas e a ação dos seres vivos (bactérias, fungos, insetos, etc.) que se instalam nos fragmentos rochosos contribuindo também para a sua desagregação.

utilização em relação as possíveis plantações. Esse estudo envolve a análise de diferentes componentes do solo, dentre os quais, segundo Prado(1995) destacam-se:

- **Areia:** Identificada como fragmento de mineral ou rocha, sendo classificada de acordo com seu diâmetro, podendo ser encontrada como “areia fina” ($>1/16\text{mm}$ e $<1/4\text{mm}$), “areia média” ($>1/4\text{ mm}$ e $<1\text{ mm}$) e “areia grossa” ($> 1\text{ mm}$ e $< 2\text{mm}$). O solo arenoso, onde encontra-se mais de 70 % de areia, tem boa aeração e por isso não retém água.
- **Argila:** Seus grãos são bem menores que os grãos de areia, suas partículas são menores do que $1/256\text{ mm}$ ($0,004\text{mm}$), com isso retêm mais água, sendo pouco permeáveis e bem menos arejados, visto que os espaços são menores dificultando o escoamento de água e a entrada de ar.
- **Silte:** É todo e qualquer fragmento mineral ou de rocha, menor que a areia fina e maior que a argila, compreendendo o intervalo de $1/256 = 0,004$ a $1/16 = 0,064\text{ mm}$.
- **Matéria orgânica:** Compreende elementos vivos e não-vivos que contém compostos de carbono.
- **Densidade do solo:** É a relação entre a massa de uma amostra de solo seco a $110\text{ }^{\circ}\text{C}$ e o volume dessa amostra não deformada, incluindo os espaços ocupados pelo ar e pela água. Também conhecida como massa específica aparente. Geralmente é expressa em g/cm^3 .

De acordo com VENZELA e ANDRADE (2007) o solo pode ser classificado de acordo com a Capacidade de Água Disponível (CAD) em :

- **Saturado:** Onde não ocorre nenhuma infiltração, pois os poros já se encontram preenchidos de água;
- **Solo na Capacidade de Campo (CC):** É a capacidade máxima que o solo consegue armazenar de água sem que haja perda, onde a planta consegue encontrar água suficiente para seu desenvolvimento sem gastar energia para procurá-la;
- **Ponto de Murcha Permanente (PMP):** É o mínimo que o solo consegue reter de água e mesmo que a planta faça muito esforço, não

consegue retirar água suficiente para sua sobrevivência.

Na maioria dos solos e na maioria das situações é inferido que o solo se encontra no limite de umidade superior (CC) e inferior (PMP) quando a tensão de água ou potencial matricial do solo oscila em torno de -33 kPa e -1500 kPa, respectivamente (REICHARDT, 1990). Para determinar a umidade atual e conseqüentemente o armazenamento de água no solo, é utilizado um aparelho chamado tensiômetro que mede a tensão de água ou potencial matricial do solo, que pode ser convertido para umidade do solo (VENZELA e ANDRADE, 2007).

Define-se então a CAD de acordo com a diferença entre os limites de umidade superior (CC) e inferior (PMP), podendo variar muito de solo pra solo e até mesmo dentro do mesmo tipo de solo de acordo com as suas propriedades físicas, como textura, teor de matéria orgânica, tipo de argila, proporção e distribuição dos macroporos e dos microporos, mostrados na FIG. 2:

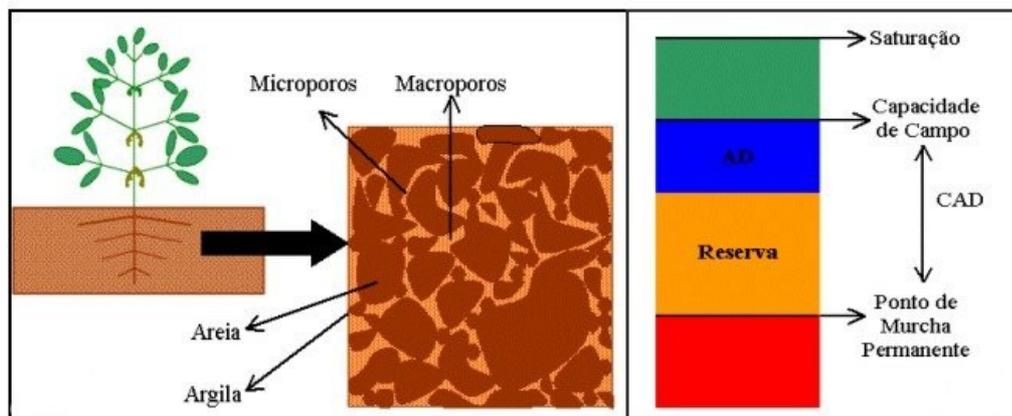


FIGURA 2 - Estado físico do solo e Capacidade de água disponível. (VENZELA e ANDRADE, 2007)

Fonte: <http://www.agr.feis.unesp.br/manejoirrigacao.html>

A forma como é feita a redistribuição de água no solo é de grande importância para a Ciência do Solo em relação a irrigação, erosão, drenagem, entre outros, e para Engenharia Civil, pois é fundamental na determinação da estabilidade da obra. Estes são alguns dos fatores que tornam a predição de água no solo de extrema necessidade para a sociedade.

Atualmente é na agricultura que se usa maior quantidade de água, e a forma como vem sendo utilizada é preocupante, pois em alguns lugares, os recursos

hídricos são utilizados de forma irracional, não dando tempo para que eles se renovem. Em outros lugares, o desperdício em uma área, priva o seu uso em outros lugares.

O solo é um reservatório natural de água para as plantas e todas as práticas de manejo na irrigação visam promover condições ideais para o crescimento das culturas. Muitos investigadores têm procurado quantificar a capacidade de armazenamento desse reservatório, como também os fluxos que ocorrem tanto na superfície (infiltração e evaporação) quanto na profundidade no solo (drenagem interna). Esses fluxos que ocorrem dentro do solo fazem parte de importantes processos do ciclo hidrológico (LOYOLA e PREVEDELLO, 2003).

O objetivo de estimar a quantidade de água no solo é proporcionar conhecimento da situação em que o solo se encontra, para proporcionar um uso adequado do mesmo juntamente com os recursos hídricos, ou seja, a aplicação de água na quantidade ideal para aperfeiçoar as produções com a eficiência máxima do uso de água e ao mesmo tempo garantir a danificação mínima do solo.

A predição é uma técnica que vêm sendo utilizada não somente para quantificar água no solo, mas também em áreas como medicina com trabalhos relacionados em predições de testes diagnósticos (MELLO, 2001), na veterinária com perspectiva para a tipificação de carcaça bovina (FELÍCIO, 1999), computação para predição de falhas em *links* de redes ópticas (RNP, 2003), entre outros.

Na agronomia, uma utilização desta técnica é a estimativa de quantidade de água no solo. Vários trabalhos são feitos para realizar a predição visando através de amostras de algumas áreas do terreno obter o valor da área total em relação a situação hídrica que o solo se encontra. Esta técnica vem sendo observada quanto a sua importância em relação a utilização e a eficiência dos resultados encontrados.

Para a realização da predição é feito uma estimativa de valores para as propriedades hidráulicas do solo podendo ser feitas através de funções empíricas ou estatísticas chamadas de pedotransferência (ROSSATO, 2001). Vários métodos podem ser usados nesse processo de predição, através das análises em laboratórios, onde primeiramente é feita a abertura de trincheiras no solo e então recolhidas as amostras de acordo com a profundidade da perfuração. Essas amostras são mandadas para laboratórios específicos de física do solo onde são

analisadas e o resultado disponibilizado como variáveis na modelagem matemática que será feita para finalizar a predição de água na área total.

Um dos métodos utilizados é o método de regressão, o qual designa equações matemáticas, buscando através de variáveis previamente escolhidas fazer estimativas em relação ao problema proposto, entretanto, exige um conhecimento *a priori*² dos dados para mostrar como as variáveis estão relacionadas, evitando assim que uma variável interfira de forma negativa nos resultados, sendo esta correlacionada com outra.

Um outro exemplo dessa predição é a amostragem única onde uma área do terreno é escolhida e saturada de água, logo após é coberta por lonas plásticas para evitar as perdas naturais de água, garantindo assim que a água será distribuída pelo perfil do solo, como mostra a FIG. 3. As amostras são então recolhidas com material e recipiente específicos, os quais são pesados, os valores da massa úmida anotados e levados ao interior de estufas, onde permanecem por período de 24 horas para que a amostra (única) seja então analisada.



FIGURA 3 - Área para pesquisa após saturação do solo. (PAIXÃO *et. al.*, 2004)
Fonte: <http://redalyc.uaemex.mx/pdf/500/50040220.pdf>

Pode-se destacar ainda o método padrão, que também tem suas amostras levadas para estufas, porém as análises são feitas até que se identifique a variação

² *A priori*: Expressão que designa uma etapa para se chegar ao conhecimento, que consiste no pensamento dedutivo.

do teor de umidade, no período de 24 horas.

Como a estrutura do solo está relacionada com o arranjo de partículas, agregados e poros que constituem o meio poroso, qualquer mudança causa alterações na distribuição dos poros, o que demanda considerável tempo e apreciável custo no processo de avaliação da predição de água no solo (PIRES, 2006). Além da dificuldade em relação a variabilidade espacial, o tempo para se obter respostas em relação a predição é grande, pois a modelagem é complexa devido a análise que é feita para se obter as melhores variáveis a serem usadas proporcionando resultados significativos.

Quanto maior for o tempo de retorno às pesquisas, menores serão as condições dos agricultores esperarem pelos resultados, tanto na parte econômica quanto em relação ao momento certo de estabelecerem o cultivo apropriado para a determinada região juntamente com a irrigação, se esta for realmente necessária.

É observado então, uma necessidade de métodos que ajudem a agilizar o processo, para que além de viável, se torne mais acessível, no intuito de garantir de fato um melhor aproveitamento da propriedade em questão.

2.2 REDES NEURAS ARTIFICIAIS

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (BRAGA *et.al.*, 2007).

2.2.1 Histórico das RNAs

Uma RNA é uma estrutura computacional projetada para mimetizar a maneira pela qual o cérebro desempenha uma particular tarefa de seu interesse (CASTRO, 2001).

O primeiro trabalho sobre RNA foi realizado em 1943, por McCulloch e Pitts (EBERHART e DOBBINS, 1990). Foi realizado um estudo do comportamento do cérebro com o intuito de desenvolver um modelo matemático para o neurônio biológico. Essa pesquisa foi de fundamental importância para futuras implementações computacionais do neurônio.

Foram definidos os seguintes comportamentos (EBERHART e DOBBINS, 1990):

- A atividade do neurônio é tudo ou nada;
- A atividade de qualquer sinapse inibitória previne a excitação do neurônio naquele instante.

Na primeira definição o neurônio estará ativo, se sua saída ultrapassar um limiar, sendo então transmitida à outros neurônios da rede, caso contrário ficará em repouso. Na segunda afirmação, tem-se o conceito de pesos, cada entrada do neurônio terá um valor associado, se positivo, tenderá a excitar a célula, caso negativo, tenderá a inibi-la.

Em 1949, Donald O. Hebb no livro *Organization Of Behavior* definiu o conceito de atualização de pesos sinápticos. Hebb deixou junto com seus estudos quatro pontos importantes (EBERHART e DOBBINS, 1990):

- Numa Rede Neural a informação é armazenada nos pesos;
- O coeficiente de aprendizagem é proporcional ao produto dos valores de ativação do neurônio;
- Os pesos são simétricos (o peso da conexão A para B é igual ao da de B para A).

Deste modo, se duas unidades são ativadas simultaneamente, suas interconexões tendem a se fortalecer. Se i recebe o sinal de entrada de j , o peso W_{ij} é modificado de acordo com :

$$\Delta W_{ij} = \lambda a_i a_j$$

onde λ é uma constante de proporcionalidade representando a taxa de aprendizado e a_i e a_j são ativações das unidades i e j respectivamente, como mostra a FIG. 4.

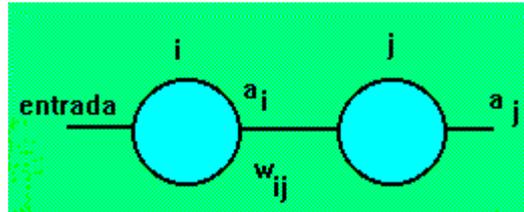


FIGURA 4 - Exemplo da regra Hebb
 Fonte: http://www.eps.ufsc.br/disciplinas/fialho/aprenant/grupo_6/grupo_61.html

Apesar de vários estudos, o primeiro modelo de Rede Neural foi implementada por Frank Rosenblatt em 1958, era uma rede simples, chamada “*perceptron*”, construído de uma camada de entrada e uma de saída. Para cada entrada tem-se um peso relacionado, sendo que o valor de saída será a soma dos produtos de cada entrada com seu respectivo peso. Para definir quando o neurônio estará ativo ou em repouso faz-se necessário estabelecer uma função limiar.

Rosenblatt estabeleceu a base para os algoritmos de treinamento dos modelos não-supervisionados (limita-se a fazer uma representação da distribuição de probabilidade de padrões de entrada da rede) como o de Kohonen e para modelos supervisionados (treinados a partir de uma saída pré-determinada) como o *Backpropagation* (EBERHART e DOBBINS, 1990).

Apesar do sucesso que foi o *perceptron*, as pesquisas de Redes Neurais sofreram problemas fundamentais como a carência de resultados teóricos que justificassem a manutenção do interesse científico pela área, ocasionando a redução de novas idéias e ao aplicarem os conceitos de matemática moderna como topologia e teoria de grupos com o objetivo de analisar as capacidades adaptativas e computacionais dos neurônios, foi concluído que apesar de ser capaz de executar as operações de AND e OR, não era capaz de executar outras operações elementares como XOR (MINSKY e PAPERT, 1969).

Após esses resultados alguns pesquisadores passaram a buscar alternativas para solucionar o problema, porém muitos não acreditavam que esse pudesse ser superado, fazendo com que os anos 70 fossem marcados por um grande êxodo nas pesquisas.

Nos anos 80 alguns fatores contribuíram para o ressurgimento das pesquisas em Redes Neurais:

- Neurofisiologistas foram adquirindo um maior conhecimento sobre o processamento de informações nos organismos vivos;
- Avanços tecnológicos tornaram disponíveis um maior potencial computacional a baixo custo, viabilizando ou facilitando simulações e testes com modelos neurais;
- Novas teorias para a implementação de algoritmos adaptativos foram desenvolvidas, permitindo a aplicação em sistemas reais.

Os modelos de Redes Neurais podem ser classificados como *feedback*, onde a rede partindo de um estado inicial, chega ao estado final de aprendizado através de iterações, onde as saídas são canalizadas para as entradas, ou *feedforward* que transforma um conjunto de sinais de entrada em sinais de saída.

Uma das novas evoluções dos trabalhos de Redes Neurais foi a criação do modelo de Hopfield, desenvolvido por John Hopfield, podendo ser considerado como um sistema dinâmico com um número finito de estados de equilíbrio que podem ser utilizados como dispositivos de memória, permitindo que a Rede evolua com o tempo para um de seus estados de equilíbrio (HOPFIELD, 1987).

O *perceptron* teve sua validade provada no modelo *backpropagation*, que possibilitou a implementação da terceira camada necessária para o aprendizado do XOR. O resultado da comparação entre a saída desejada e a saída real da rede é definido como erro, o qual é utilizado pelo modelo *backpropagation* para realizar uma retro-propagação desse erro para as camadas anteriores, juntamente com a função limiar possibilitando a representação de funções não-lineares.

Broomhead e Lowe, descreveram em 1988, um procedimento para o projeto de uma Rede Neural (*feedforward*), usando funções de base radial, conhecidas na literatura como "*Radial Bases Function*"(RBF). Sua estrutura permite que as camadas sejam desacopladas em duas fases, que lhe confere um desempenho na aprendizagem sensivelmente superior ao de outras arquiteturas conhecidas atualmente (BROOMHEAD e LOWE, 1988).

2.2.2 Conceitos de RNAs e suas Aplicações

O cérebro humano é composto por bilhões de neurônios interconectados entre si por meio de sinapses. Esta complexa conexão é responsável pelas características atribuídas a inteligência, com isso surgiu a idéia de representar por meio de determinados programas seu funcionamento, com o intuito de aprender, errar e fazer descobertas através do conhecimento adquirido com a experiência.

A discussão sobre RNAs é norteada pela análise dos seguintes aspectos:

- Neurônio: Unidade computacional básica da rede;
- Arquitetura: Estrutura topológica de como os neurônios são conectados;
- Aprendizado: Processo que adapta a rede de modo a computar uma função desejada ou realizar uma tarefa.

O aprendizado das RNAs consiste em uma fase de treinamento, onde a Rede absorve dados, e à partir destes dados vai modificando os parâmetros da sua entrada, e a fase de aplicação ou desenvolvimento na qual já se encontra com os pesos determinados para testar padrões ou resolver problemas de otimização.

As RNAs podem ser aplicadas em várias áreas de pesquisas, entre elas destacam-se (LOESCH e SARI 1996):

- Análise de assinatura;
- Análise de características demográficas para marketing;
- Análise do grau de satisfação de um cliente;
- Controle de processos industriais;
- Detecção de cartões de crédito falsos;
- Monitoramento para manutenção de motores;
- Previsão da bolsa de valores e cotação de moedas;
- Previsão do mercado financeiro;
- Reconhecimento de caracteres e impressões digitais;

- Reconhecimento ótico de caracteres.

2.2.3 Neurônio Biológico e Sistema Nervoso

O sistema nervoso é formado por um conjunto complexo de células, chamadas de neurônios. Estas desempenham um papel extremamente importante na determinação do funcionamento e comportamento do corpo humano juntamente com o raciocínio. Os neurônios são formados pelos dendritos (terminais de entrada), pelo corpo central e pelos axônios (terminais de saída), como mostra a FIG. 5.

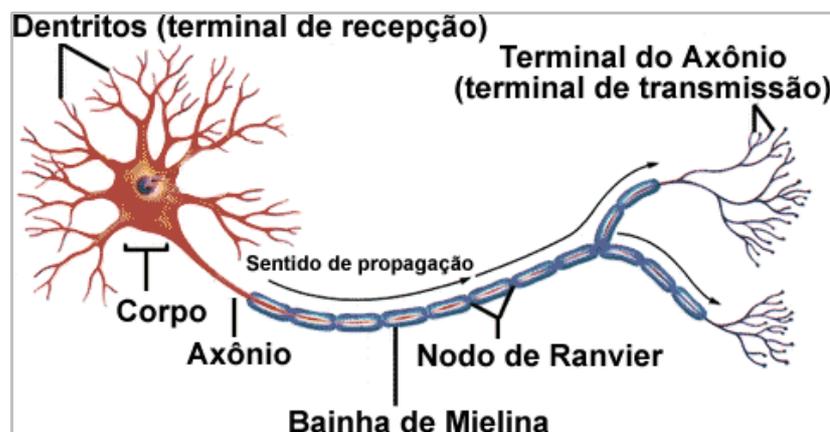


FIGURA 5 - Estrutura Básica de um Neurônio
 Fonte: http://www.Incc.br/~labinfo/tutorialRN/frm1_inspiracaoBiologica.htm

Para que a comunicação entre os neurônios possa ser feita eles precisam estar de algum modo interconectados para que aconteça a propagação, como não existe uma continuidade celular de um neurônio para outro, os pulsos de eletricidade são propagados por espaços chamados sinapse, preenchidos por um fluido.

O sinal não pode ultrapassar eletricamente esse espaço. Assim, substâncias químicas especiais, chamadas neurotransmissores, desempenham esse papel. Elas são liberadas pela membrana emissora pré-sináptica e se difundem através do espaço para os receptores da membrana do neurônio receptor pós-sináptico. A ligação dos neurotransmissores para esses receptores tem como efeito permitir que

íons (partículas eletricamente carregadas) fluam para dentro e para fora da célula receptora (CARDOSO, 2000), como mostra a FIG. 6.

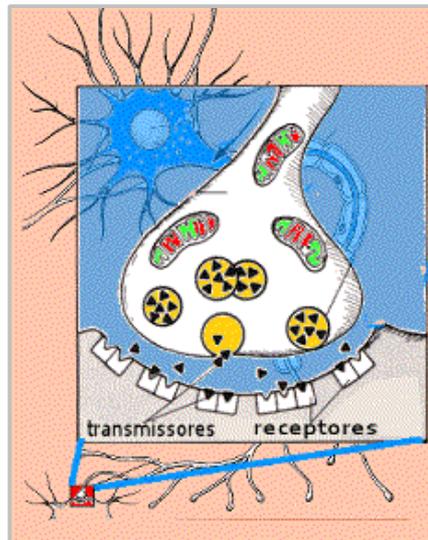


FIGURA 6 - Fenda sináptica

Fonte: <http://www.qmc.ufsc.br/qmcweb/exemplar18.html>

2.2.4 Neurônio Artificial

O neurônio artificial é uma estrutura lógico-matemática, que tenta simular os neurônios biológicos com suas funções e comportamentos, conseguindo uma aproximação, visto que o cérebro é muito complexo e sua neurodinâmica ainda pouco conhecida, causa uma dificuldade em sua modelagem. A FIG. 7 mostra um exemplo de um neurônio artificial.

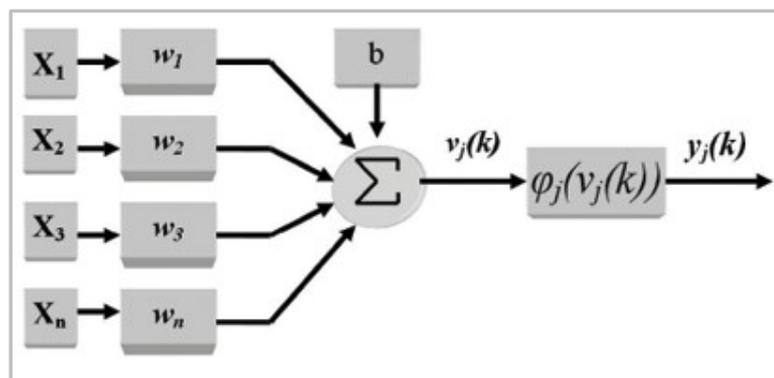


FIGURA 7 - Neurônio Artificial (GOEDEL *et al.*, 2006)

O neurônio artificial é composto por:

- **X_i** : Entradas, podendo ser do meio externo ou de outros neurônios;
- **w_i** : Pesos, responsáveis pelo ajuste das conexões sinápticas;
- **B** : Bias, entrada especial, com o intuito de aumentar ou diminuir o valor das entradas;
- **Σ** : Somatório do produto entre as entradas e os pesos;
- **V** : Função de ativação;
- **Q** : Função de saída.

2.2.5 Aprendizado – Treinamento

As RNAs podem ser classificadas de acordo com a direção que o sinal flui (HAYKIN, 2001):

- **Feedforward**: Sinais se propagam em uma única direção, à partir da camada de entrada passando pela camada intermediária até chegar na camada de saída;
- **Feedback**: Os sinais podem se propagar da saída de qualquer neurônio até a entrada de outro.

O aprendizado de uma RNA ocorre quando ela atinge uma solução generalizada para uma classe de problemas, fazendo com que o processo de aprendizagem ocorra através de um processo iterativo de ajustes aplicados em seus pesos.

A maioria dos modelos de RNAs são capazes de extrair regras básicas à partir de dados reais. Através de exemplos as redes “aprendem”, ajustam os pesos das conexões de acordo com os padrões apresentados, estabelecendo assim uma regra de treinamento.

Os principais tipos de aprendizagem podem ser classificados como:

- **Aprendizado Supervisionado**: Utiliza um agente externo, professor,

que indica a resposta desejada a rede de acordo com o padrão de entrada, se o resultado da rede se adequar com o valor fornecido pelo professor, a rede estará treinada.

- **Aprendizado Não-supervisionado:** Não existe um agente externo. A rede forma representações internas codificando as características da entrada, estabelecendo assim uma regularidade estatística.

- **Aprendizado por Reforço:** O aprendizado é feito com um agente sem conhecimentos prévios aprendendo através de interações com o ambiente.

- **Aprendizado Competitivo:** Somente um neurônio chega a saída, através da competição mútua. Possui apenas uma camada de saída conectada nos neurônios da camada de entrada, não possuindo camada intermediária.

- **Aprendizado através da Regra Hebb:** O peso de uma conexão sináptica deve ser ajustado se houver sincronismo entre os níveis de atividade das entradas e saídas.

Segundo Hebb (1949), quando um axônio de uma célula A está próximo o suficiente de excitar a célula B e repetidamente ou persistentemente participa da ativação desta, um processo de crescimento ou mudança metabólica ocorre em uma ou ambas as células, de tal forma que a eficiência de A em ativar B é aumentada.

Pode-se representar o postulado de Hebb em termos matemáticos a partir da equação:

$$Dw_{ij} = h y_i(t) x_j(t)$$

onde:

- w_{ij} : peso da conexão;
- h : constante positiva que determina a taxa de aprendizado;
- x_j : sinal pré-sináptico do neurônio j , no tempo t ;
- y_i : sinal pós-sináptico do neurônio i , no tempo t ;

2.2.6 Função de Ativação

Responsável pela definição da saída de um neurônio em termos de uma entrada. Possui uma ativação interna fazendo com que o próprio neurônio decida o que fazer com o valor resultante da soma ponderada, esta decisão influenciará somente o próprio neurônio (ALMEIDA, 2000).

O valor de ativação do neurônio é atualizado através da função de ativação (Φ) após se determinar o NET (soma ponderada das entradas do neurônio), o valor de saída (Y) do neurônio é produzido pela função de saída (f). Existindo somente em neurônios dinâmicos, onde seus estados futuros são determinados tanto pelo NET de entrada como pelo estado atual do neurônio, demonstrado a seguir:

$$A_i^{t+1} = (\Phi_i^t, NET_i^t)$$

2.2.7 Funções de Saída ou de Transferência(f)

Segundo Haykin (2001) existem várias funções que podem ser usadas como função de saída em um modelo neural, dentre elas, as mais comuns são:

Função Linear: Função simples, dada por uma reta.

$$F(x) = ((x * A) + B)$$

Representação do gráfico da função:

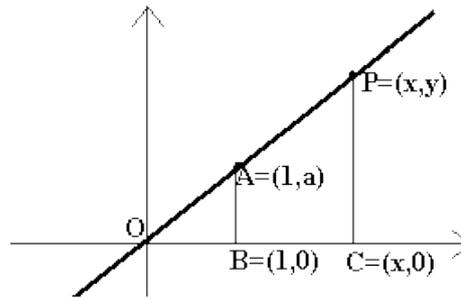


GRÁFICO 1 - Função Linear

Função de Limiar: Demonstra tudo ou nada.

Onde: $F(x) = 1$ se $NET \geq 0$ e

$F(x) = 0$ se $NET < 0$; sendo $x = NET$.

Representação do gráfico da função:

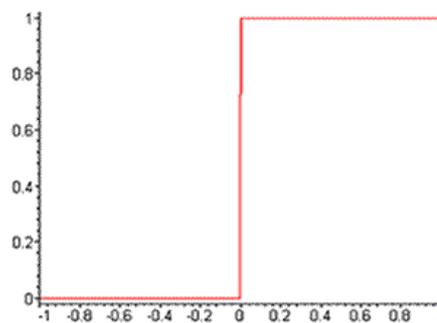


GRÁFICO 2- Função Limiar

Função Tangente Hiperbólica: Os valores tendem a -1 e a 1, mas nunca chegam a tais valores, representada por:

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

onde:

$x = (NET/T)$.

Representação do gráfico da função:

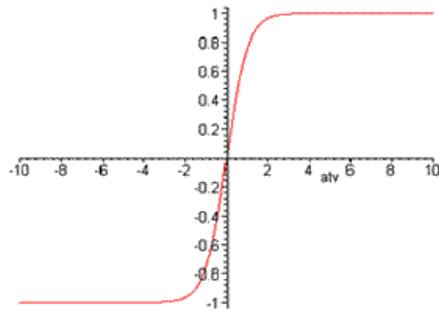


GRÁFICO 3 - Tangente Hiperbólica

Função Sigmóide: Pode ser classificada como simétrica, gerando valores entre -0,5 e 0,5, ou assimétricas gerando valores entre (0 e 1) ou (-1 e +1).

$$F(x) = \frac{1}{1 + e^{\frac{-x}{T}}}$$

Representação do gráfico da função:

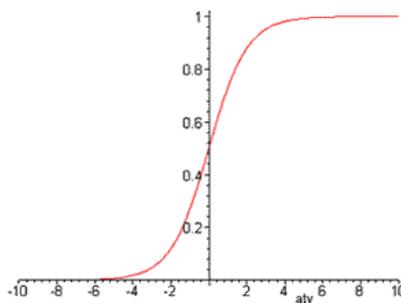


GRÁFICO 4 - Função Sigmóide

Se o valor do parâmetro T for aumentado, a função comporta-se como a função limiar.

Representação do gráfico da função:

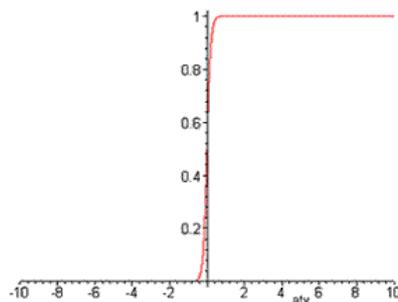


GRÁFICO 5 - Função Limiar

2.2.8 Ajuste dos Pesos (w)

Os pesos são inicializados de forma aleatória ou por dados de informações *a priori*, onde uma boa escolha influencia diretamente na velocidade de aprendizagem e na qualidade da solução final. Os pesos (w) devem ser necessariamente determinados para que a rede possa responder corretamente aos padrões de entrada, e os ajustes feitos de acordo com o modelo escolhido para o treinamento da rede.

2.2.9 Correção do Erro (δ)

O erro é calculado a partir da diferença entre a saída real e a saída desejada. Demonstrada pela seguinte equação:

$$e_k = d_k - y_k$$

onde:

- **e**: Sinal do erro;
- **d**: Saída desejada apresentada durante o treinamento;
- **y**: Saída real da rede após a apresentação do estímulo de entrada.

Os erros são calculados sucessivamente no aprendizado supervisionado para assim se aproximarem de um valor satisfatório. A curva de erros gerado no gráfico depende do modelo do neurônio utilizado, podendo ser linear ou não-linear.

Nos modelos lineares encontram-se apenas um valor mínimo na superfície de erro, já nos modelos de neurônios não-lineares, podem ser encontrados diversos valores mínimos na superfície de erro, chamados de mínimos locais, também podem ser encontrados mínimos globais, difíceis de serem atingidos pela dificuldade de conhecer o formato de toda curva de erro do problema, como mostra o GRAF. 6.

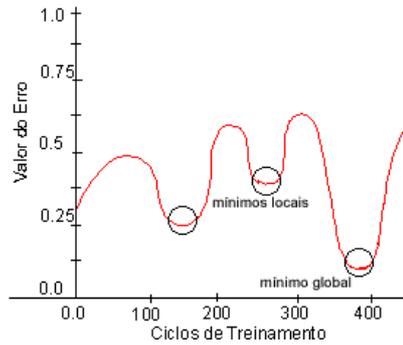


GRÁFICO 6 - Demonstração dos mínimos locais e do mínimo global

2.2.10 Taxa de Aprendizagem (η)

Os valores de “ η ” são limitados ao intervalo de $0 < \eta \leq 1$, para que assim possa manter a estabilidade da trajetória dos pesos e as mudanças de seus valores nas conexões sejam menores, favorecendo a procura do mínimo global. Dependendo da aplicação o valor da taxa de aprendizado pode ser fixo, ou pode conter incrementos variáveis onde seu cálculo é feito através da fórmula : $\eta = 1/\sqrt{z}$.

2.2.11 Topologia

Segundo Barreto (1999), qualquer dígrafo (grafo dirigido) pode dar lugar a uma topologia de RNA. Os neurônios podem estar conectados de forma total ou parcial, sendo bi ou unidirecionais.

Na FIG. 8 é apresentado um exemplo de neurônios conectados de forma total e unidirecional. Cada neurônio de uma camada está conectado em todos os neurônios da camada seguinte (forma total). Todos os neurônios estão conectados apenas aos neurônios da camada imediatamente posterior, não havendo realimentação (comunicação unidirecional) nem conexões entre neurônios da mesma camada.

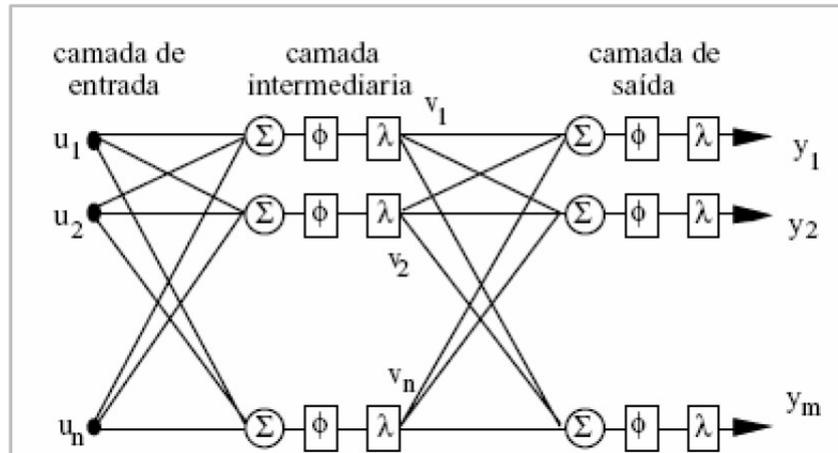


FIGURA 8 - Neurônios conectados de forma total e unidirecional
 Fonte: http://www.eps.ufsc.br/disciplinas/fialho/aprenant/grupo_6/grupo_61.html

Na FIG. 9 é apresentado um exemplo de neurônios conectados de forma parcial e bidirecional. Os neurônios de uma camada não estão conectados em todos os neurônios da camada seguinte (forma parcial). Além de estarem conectados em alguns dos neurônios da camada posterior, também recebem sinais vindos diretamente dos neurônios da saída, havendo realimentação (comunicação bidirecional).

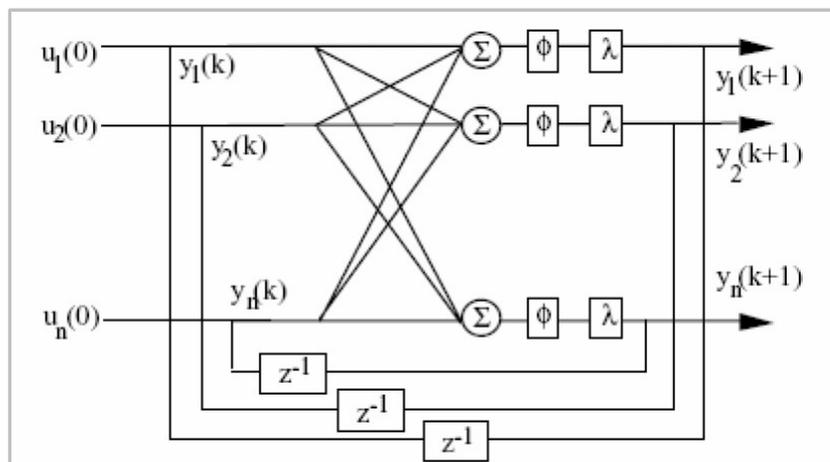


FIGURA 9 - Neurônios conectados de forma parcial e bidirecional
 Fonte: http://www.eps.ufsc.br/disciplinas/fialho/aprenant/grupo_6/grupo_61.html

2.2.12 Redes Neurais Multi-Camadas

As Redes Neurais multi-camadas são compostas por três níveis: camada de entrada, camada(s) intermediária(s) e camada de saída, não havendo ligações entre neurônios da mesma camada. A quantidade de neurônios da camada intermediária e a quantidade de camadas da rede não são especificados.

- **Camada de Entrada:** Possui um número de neurônios iguais ao tamanho do vetor ou matriz de entrada, esta distribui os dados ou sinais de entrada para os neurônios da camada intermediária ou escondida;
- **Camada(s) Intermediária(s):** Realiza uma soma ponderada e atribui este valor à função de ativação que irá gerar a saída dos neurônios, passando este sinal gerado para a camada de saída;
- **Camada de Saída:** Realiza uma soma ponderada dos valores ou sinais recebidos da camada intermediária e atribui este resultado à função de ativação gerando a saída da Rede, a qual irá propagar novamente este sinal no sentido contrário, fazendo a correção dos pesos, bias e calculando o delta no caso do aprendizado através da regra delta.

2.2.13 Algoritmo de Treinamento *Backpropagation*

O algoritmo *Backpropagation* é hoje em dia a técnica de aprendizado supervisionado mais utilizada para Redes Neurais unidirecionais multicamadas, seu aprendizado é supervisionado, possuindo duas etapas aplicadas sequencialmente:

- **Propagação:** Os padrões de entrada são apresentados a rede e propagados até a camada de saída, passando pela camada intermediária;
- **Retropropagação:** Os erros são calculados e os pesos ajustados objetivando a diminuição do erro.

Durante a fase de treinamento, é apresentado a entrada para a rede e o valor desejado para resposta à entrada. A saída é comparada ao valor desejado e o erro

global computado, o qual influenciará na correção dos pesos no passo de retropropagação. Este processo é muito utilizado por apresentar uma boa solução para o treinamento de *Perceptrons* Multi – Camadas, apesar de não haver garantias que a rede forneça uma solução ótima para o problema.

2.2.14 Tipos de Redes Neurais

Existem diversos tipos de RNAs e diferentes maneiras de classificá-las. A seguir, serão abordados alguns exemplos.

2.2.14.1 Rede Neural com Função de Base Radial – RBF

As Redes Neurais Artificiais do tipo *Radial Base Function* (RBF), possuem uma camada escondida definida por um conjunto de funções de base radial, derivando assim seu nome. São ferramentas extremamente flexíveis em um ambiente dinâmico. Elas têm capacidade de aprender rapidamente padrões complexos, e tendências presentes nos dados e de se adaptarem rapidamente à mudanças (CASTRO, 2001). A FIG. 10 mostra um exemplo de uma Rede RBF.

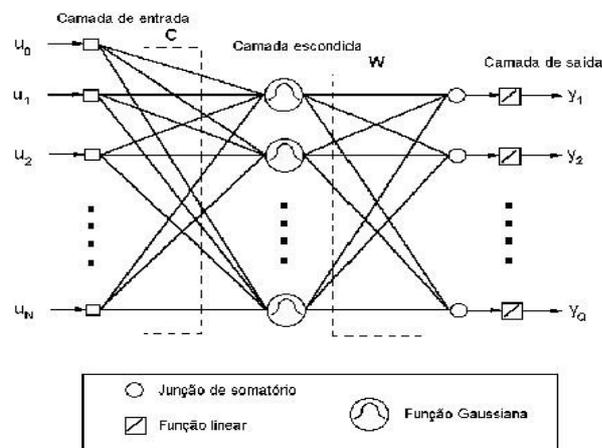


FIGURA 10 - Rede de Base Radial. (CASTRO, 2001)

O processo de aprendizagem é equivalente a ajustar uma superfície não-linear ao conjunto de dados, em um espaço multi-dimensional, de acordo com algum critério estatístico. O processo de generalização equivale a usar esta superfície multi-dimensional para interpolar outros pontos que não pertençam ao conjunto de treino, mas estejam em sua vizinhança (CASTRO, 2001).

As aplicações de rede RBF podem ser destacadas como classificadores de padrões e aproximadores de funções, se destacando pela rapidez de aprendizado. Os primeiros trabalhos nesta área foram feitos por: Broomhead e Lowe em 1988, sendo os primeiros a explorar o uso de RBF no projeto de RNA. Outras contribuições também foram surgindo como a dos pesquisadores: Moody e Darken em 1989, Renal em 1989 e Poggio e Girosi em 1990 e Girosi em 1992 (CASTRO, 2001).

As redes RBF possuem algumas características, podendo ser vistas como um modelo:

- **Multi-variável:** Está ligado ao número de variáveis do problema;
- **Regressão:** Pode ser vista como o aprendizado supervisionado;
- **Não paramétrico:** O modelo é estimado através de uma função com parâmetros sem significados, quando não se sabe *a priori* o modelo do problema.
- **Capacidade de interpolação:** Generalização, após a rede ter sido treinada esta generaliza o conhecimento respondendo a novas situações.

Principais funções matemáticas que descrevem as redes RBF, sendo a função de base radial mais utilizada do tipo Gaussiana :

- **Gaussiana:**

$$F(x) = \frac{e^{-(x-c)^2}}{r^2}$$

- **Multi-Quadrática:**

$$F(x) = \frac{\sqrt{r^2 + (x-c)^2}}{r}$$

- **Multi-Quadrática Inversa:**

$$F(x) = \frac{r}{\sqrt{r^2 + (x-c)^2}}$$

- **Pseudo Cúbica:**

$$|(x-c)^3|$$

Algumas diferenças entre redes MLPs e redes RBFs (CASTRO, 2001):

- O erro final de uma rede RBF é menor que o erro final atingido por uma MLP;
- A convergência de uma rede RBF pode chegar a ser uma ordem de grandeza mais rápida do que a convergência de uma rede MLP;
- A capacidade de generalização de uma rede MLP é, em geral, superior à capacidade de generalização de uma rede RBF.

A rede RBF é treinada em dois estágios. O primeiro utiliza técnicas não supervisionadas para determinar os valores para o centro e para o desvio padrão das funções de base radial e o segundo, utiliza técnicas supervisionadas para determinar os pesos na camada de saída, provocando assim uma rápida convergência. E o seu aprendizado se equivale a encontrar uma superfície em um espaço multi-dimensional que se ajuste ao conjunto de padrões treinados, sendo este ajuste calculado de forma estatística (CASTRO, 2001).

De acordo com Barreto (1999), pode-se enumerar os seguintes parâmetros ajustáveis em uma rede RBF:

- **Número de RBFs:** O número de funções de base radial na camada oculta está diretamente ligado à complexidade da função computada pela rede e pode ser interpretada como uma maneira de se controlar o nível de suavidade da aplicação.
- **Posição dos centros:** Os centros das funções de base radial são determinados como parte do processo de aprendizagem, ao invés de estarem restritos às posições dos dados conhecidos. O número e posição dos centros devem compor um conjunto que seja representativo da amostra de pontos dadas.
- **Largura das RBFs:** Os parâmetros também podem ser adaptados, permitindo que a função aproximativa se adeque às peculiaridades do problema, como por exemplo, níveis de suavidade diferentes em regiões distintas.
- **Coefficientes Lineares:** Os coeficientes representam os pesos que compõem a soma ponderada executada pelas unidades de saída e também devem ser determinados.

2.2.14.2 Redes Competitivas – Mapa Auto-Organizável de Kohonen

São utilizadas em projetos industriais para resolver problemas práticos de difícil solução. É adotada como ferramenta analítica de padrão pela estatística, processamento de sinais, análise financeira, teoria de controle e outros campos da ciência (DUARTE, 2007).

O mapa de Kohonen é uma rede de duas camadas, na qual a primeira camada é a de entrada e a segunda é a camada competitiva, também chamada de processamento, é organizada como uma grade unidimensional ou bidimensional. Todas as interconexões vão da primeira camada para a segunda; as duas camadas são completamente interconectadas, pois cada neurônio de entrada é conectado a todos os neurônios da camada competitiva (DUARTE, 2007).

Os três processos essenciais para a formação da Redes Competitivas são:

- **Competição:** Os neurônios da rede devem computar seus respectivos valores através de uma função discriminante, que provê as bases da competição entre os neurônios. O neurônio de maior valor discriminante será o vencedor da competição, de acordo com cada padrão de treinamento.
- **Cooperação:** O neurônio vencedor determinará uma vizinhança topológica de neurônios excitados, provendo a cooperação entre os neurônios vizinhos.
- **Adaptação sináptica:** Permite aos neurônios excitados, aumentar seus valores individuais da função discriminante, realçando a resposta do neurônio vencedor à aplicação de um padrão similar.

2.2.14.3 Redes Recorrentes

Redes neurais recorrentes são estruturas de processamento capazes de representar uma grande variedade de comportamentos dinâmicos. A presença de realimentação de informação permite a criação de representações internas e dispositivos de memória capazes de processar e armazenar informações temporais e sinais sequenciais (VON ZUBEN, 2004).

2.2.14.4 Redes Neurais de Memória Associativa

Todos os neurônios são ligados entre si, mas não a si mesmo. De acordo com Duarte (2007) podem ser definidos como:

- **Auto-Associação:** Um conjunto de padrões de comportamento é armazenado na rede, depois apresenta-se à rede uma versão distorcida dos padrões originais, e a rede deve ser capaz de devolver o padrão original. Utiliza o aprendizado não-supervisionado como método de treinamento.

- **Hetero-Associação:** Neste modelo os padrões de entrada são organizados em pares de entrada e saída e possui o aprendizado supervisionado como métodos de treinamento.

Existem outros tipos de redes, porém as mesmas não serão descritas neste trabalho por fugirem do objetivo.

2.2.15 Aplicações

Através dos estudos em relação a capacidade que as RNAs têm de auxiliar na resolução de problemas complexos, observa-se que trata-se de um método de grande poder e que vêm ganhando espaço nas mais diversas áreas.

Desta forma, neste trabalho, as RNAs serão utilizadas no reconhecimento de padrões do solo, e então, através de treinamento, as características em relação a quantidade dos componentes do solo responsáveis pela retenção de água retida, poderão ser encontradas, determinando assim a quantidade de água no solo.

Nesta aplicação específica, optou-se por utilizar o simulador de Redes Neurais JavaNNS, o qual fornece todos os recursos necessários para a realização do presente trabalho. Com isso, a eficiência do simulador foi comprovada, incentivando assim outros trabalhos com a utilização do mesmo.

2.2.16 Simulador de Rede Neural Artificial JavaNNS

O JavaNNS é um simulador para redes neurais desenvolvido pelo Instituto Wilhelm-Schickard de Ciência da computação, em Tübingen, na Alemanha. Baseado no simulador para rede neural artificial SNNS, porém sua interface gráfica foi desenvolvida em Java, com intuito de auxiliar de forma mais simples e intuitiva seus usuários, sendo multiplataforma o simulador fica disponível para ser executado em vários sistemas como Windows NT, Windows 2000, Windows XP, Solaris 7 e Linux RedHat 6,1 (FISCHER et al., 2007).

Através do simulador JavaNNS, redes predefinidas ou redes criadas pelo próprio usuário, de acordo com a aplicação desejada, podem ser testadas, treinadas e analisadas. O simulador, disponibiliza um ambiente flexível e eficiente com funcionalidades que possibilitam a solução de vários problemas por meio desse software (CERA, 2005).

Para cada plataforma, um arquivo de instalação é definido, arquivo este que disponibiliza, além do simulador, uma pasta contendo vários exemplos e uma pasta com o manual. Como o simulador é baseado no SNNS, dúvidas referentes a ele podem ser solucionadas através do manual do SNNS, por ser mais completo.

Ao inicializar o JavaNNS, sua interface gráfica é aberta contendo somente uma barra de menu. As redes predefinidas com extensão .net podem ser carregadas e então o desenho da rede é disponibilizado na tela. Os padrões de treinamento e validação, encontram-se na extensão .pat. Após a fase de treinamento e validação, os resultados da rede devem ser salvos com extensão .res. A FIG. 11 mostra uma rede modelada no JavaNNS.

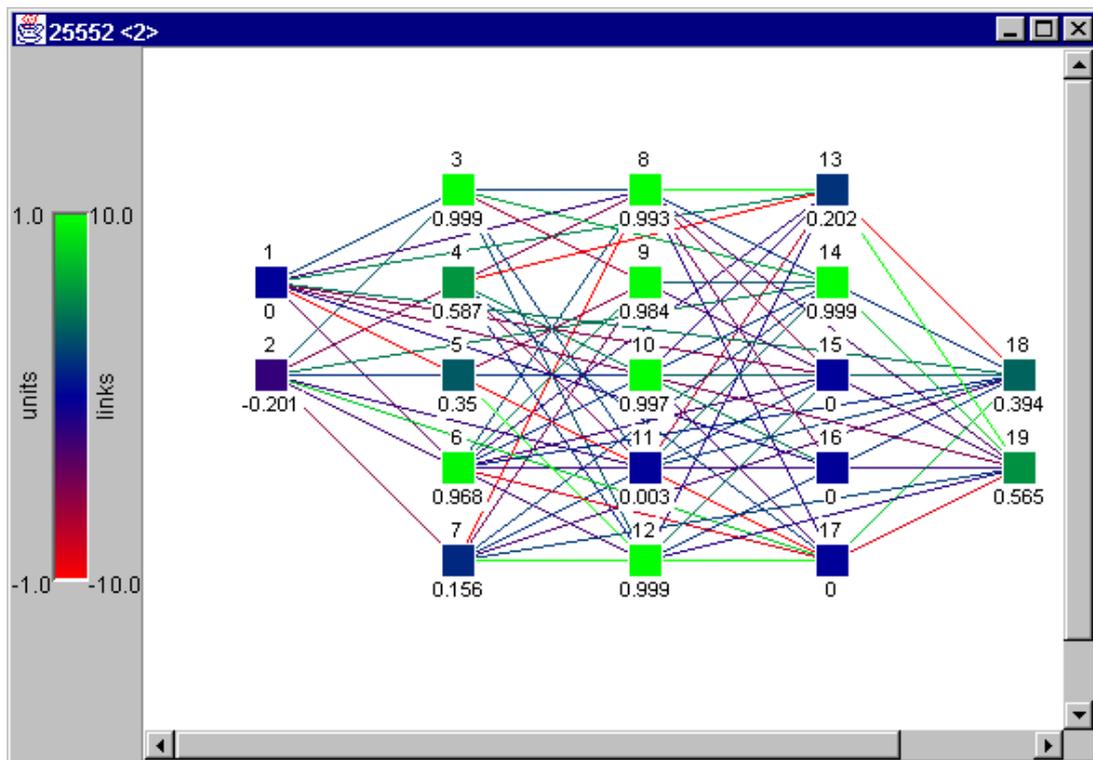


FIGURA 11 - RNA modelada no simulador JavaNNS (FISCHER *et al.*, 2007)

Os arquivos de treinamento e validação possuem um cabeçalho próprio,

definindo assim um arquivo de padrão, a versão do simulador, o dia da semana, a data, o mês, hora e ano em que o mesmo foi criado, sem esse cabeçalho, o simulador não reconhece as entradas, porém não precisa estar necessariamente atualizado.

As ferramentas disponibilizadas pelo simulador para criação e manipulação de RNAs se encontram na barra de ferramentas, onde podem ser acessadas para a criação e manipulação das redes. A criação das redes com seus neurônios e conexões são realizadas através do menu "Tools". Neste mesmo menu encontra-se uma das janelas mais importantes do simulador, responsável pelas modificações e manipulações da rede (FIG. 12).

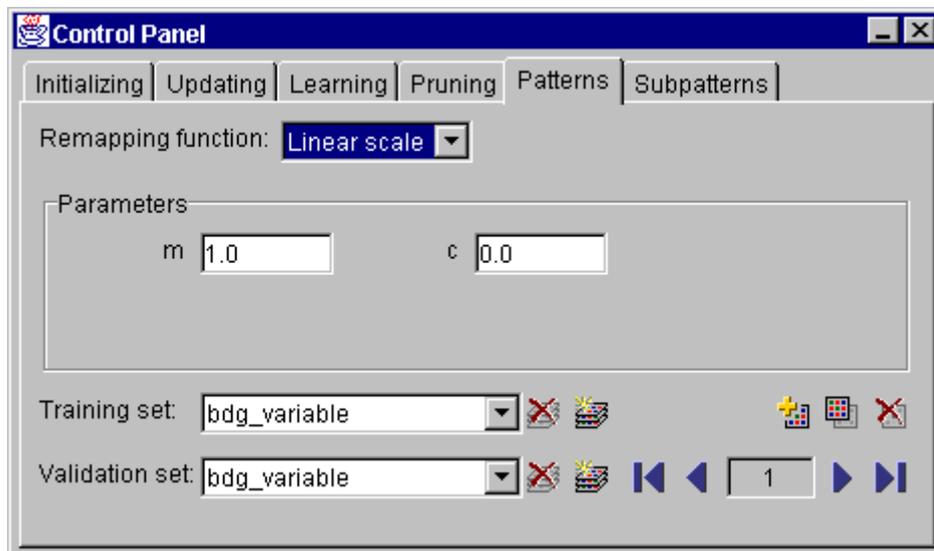


FIGURA 12 - Painel de Controle (FISCHER *et al.*, 2007)

Através deste painel a inicialização da rede poderá ser feita juntamente com a manipulação de padrões que são introduzidos à rede para o treinamento e validação.

O erro gráfico pode ser visualizado através da ferramenta Error Graph (FIG. 13), permitindo assim a verificação da variação da rede durante o treinamento.

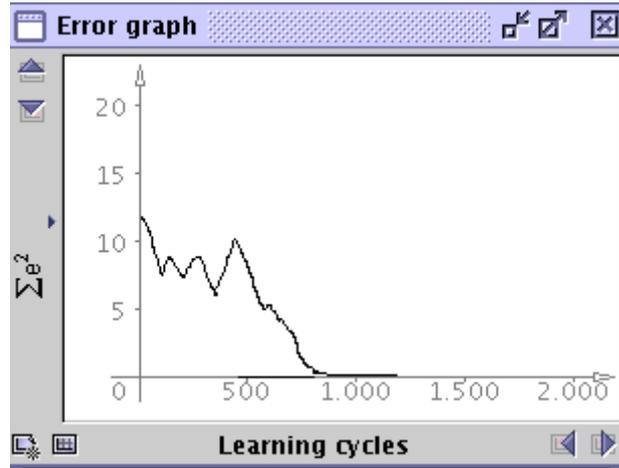


FIGURA 13 - Exemplo de gráfico de erro (FISCHER *et al.*, 2007)

As facilidades encontradas em manipular o simulador o torna uma ferramenta de grande importância na resolução de problemas envolvendo RNAs. Com isto as redes utilizadas neste trabalho foram implementadas através deste simulador, o qual teve como entrada variáveis do solo de acordo com a quantidade encontrada através das análises disponibilizadas pelo PROJIR, permitindo que o treinamento e os testes fossem feitos afim de verificar a sua eficiência ao predizer a quantidade de água encontrada no solo.

3 METODOLOGIA

3.1 REDES NEURAIS ARTIFICIAIS RBF APLICADAS NA PREDIÇÃO DE QUANTIDADE DE ÁGUA NO SOLO

Neste capítulo, serão abordadas as etapas do processo feito para aplicar RNA na predição de água no solo.

3.1.1 Coleta e Separação dos Dados

As amostras do solo foram disponibilizadas pelo PROJIR, que é um projeto que corresponde ao estudo de reconhecimento geral em nível de semidetalhe de hidrologia, geotecnia, sócio-economia, agronomia e topografia e anteprojetos de irrigação. Os estudos visam a elaboração de projetos de irrigação e drenagem da cana-de-açúcar, além de contemplar as culturas do milho, soja, feijão, arroz, hortaliças e de algumas fruteiras tais como abacaxi, melancia, citrus, etc (SOARES, 2010).

O PROJIR dispõe dos seguintes estudos: Levantamento aerofotogramétrico de toda a área do projeto, cartografia básica, estudos de pedologia, estudos geológicos e estudos hidrogeológicos (SOARES, 2010).

Na FIG. 14 é apresentado um mapa da região Norte Fluminense juntamente com a área do PROJIR.

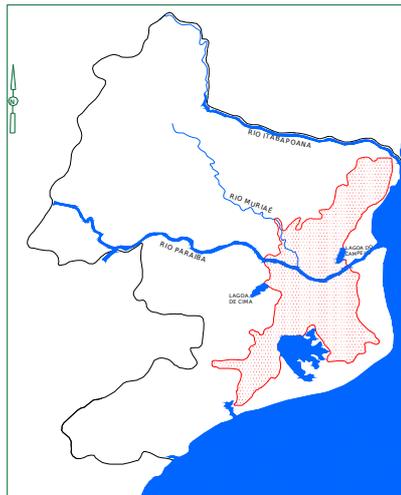


FIGURA 14 - Região Norte Fluminense e área do PROJIR (rachurada)

As amostras disponibilizados pelo PROJIR foram analisadas em laboratórios específicos de física do solo, juntamente com a quantidade de água encontrada em cada perfil. Através de estudos, estas amostras foram analisadas e separadas de acordo com a influência que exerciam na retenção de água no solo para serem disponibilizadas como variáveis de entrada para a RNA.

Cada amostra do solo, foi dividida em perfis, determinando assim as camadas do solo juntamente com suas variáveis, tais como, areia, argila, silte, densidade do solo, material orgânico e porosidade.

Como exemplo, foi destacada uma parte do banco de dados utilizado, FIG. 15, onde as amostras do solo foram separadas em perfis, cada perfil está dividido em camadas do solo e cada camada contém as seguintes informações:

- **Horizontes:** Tipo de horizonte encontrado;
- **Areia:** Quantidade de areia em g/Kg;
- **Silte:** Quantidade de silte em g/Kg;
- **Argila:** Quantidade de argila em g/Kg;
- **Ds:** Densidade do solo em kg/dm³;
- **C org:** Material Orgânico em g/Kg;
- **Porosidade:** Porosidade em cm³/100cm³;

- **0.010 Mpa:** Porcentagem de capacidade de retenção de água com pressão e tensão em 0.010Mpa;
- **0.033Mpa:** Porcentagem da capacidade de retenção de água com pressão e tensão em 0.033Mpa;
- **1.5 Mpa:** Porcentagem da capacidade de retenção de água com pressão e tensão em 1.5Mpa.
- **Água disp.:** Porcentagem da capacidade de água disponível.

Horizontes	Areia (g/kg)	Silte (g/kg)	Argila (g/kg)	Ds (kg/dm ³)	C org (g/kg)	Porosidade (cm ³ / 100 cm ³)	Umid 0,010Mpa (%)	Umid 0,033Mpa	Umid 1,5Mpa (%)	Água disp (%)
Ap	710	130	160	1,36	1,10	48	21,7		8,5	13,200
C1	770	70	160	1,44	0,38	45	16,1		6,5	9,600
C2	740	140	120	1,16	1,70	55	33,6		10,3	23,300
C3	750	90	160	1,31	0,51	50	19,9		7,8	12,100
Trad1	200	180	620	1,16		55		38,4	26,2	12,200
Trad2	290	340	370	1,13		57		35,3	20,0	15,300
Horizontes	Areia (g/kg)	Silte (g/kg)	Argila (g/kg)	Ds (kg/dm ³)	C org (g/kg)	Porosidade (cm ³ / 100 cm ³)	Umid 0,010Mpa (%)	Umid 0,033Mpa	Umid 1,5Mpa (%)	Água disp (%)
Ap	160	340	500	1,08	1,32	58		41,3	34,8	6,500
C1	220	320	460	1,08	1,01	58		38,7	33,0	5,700
C2	90	360	550	1,00	0,86	61		44,9	37,8	7,100
C3	70	360	570	1,01	0,76	61		47,9	39,9	8,000
Horizontes	Areia (g/kg)	Silte (g/kg)	Argila (g/kg)	Ds (kg/dm ³)	C org (g/kg)	Porosidade (cm ³ / 100 cm ³)	Umid 0,010Mpa (%)	Umid 0,033Mpa	Umid 1,5Mpa (%)	Água disp (%)
Ap	60	240	700	1,09	1,89	56		43,9	31,2	12,700
C1	20	240	740	1,04	0,70	62		52,3	37,5	14,800
C2	470	220	310	1,13	0,21	57		30,9	18,9	12,000
C3	730	130	140	1,19	2,62	54	28,2		11,2	17,000
C4	550	210	240	1,16		55		28,2	17,7	10,500
C5	980	0	20	1,51		43	2,6		1,3	1,300
Horizontes	Areia (g/kg)	Silte (g/kg)	Argila (g/kg)	Ds (kg/dm ³)	C org (g/kg)	Porosidade (cm ³ / 100 cm ³)	Umid 0,010Mpa (%)	Umid 0,033Mpa	Umid 1,5Mpa (%)	Água disp (%)
Ap	140	240	620	1,18	2,34	53	0,0	37,9	29,5	8,400
C1	70	190	740	1,15	0,85	56	0,0	41,7	31,3	10,400
C3	980	0	20	1,48	0,02	44	3,7	0,0	1,4	2,300
C4	980	0	20	1,37	0,05	49	4,9	0,0	2,0	2,900

FIGURA 15 - Exemplo de parte do Banco de Dados utilizado

3.1.2 Aplicação de Redes Neurais

Através do simulador JavaNNs, foi criada e testada a arquitetura da RNA para aplicar ao problema, todos os parâmetros incluindo números de neurônios, número de camadas e tipo de conexões foram definidos através de análises e

testes.

Uma Rede RBF, geralmente tem uma arquitetura simples, consistindo de duas camadas de peso: a primeira delas contém os parâmetros das funções de base radial e a segunda camada forma combinações lineares das ativações de base radial para gerar uma saída (CASTRO, 2001).

Com os estudos realizados sobre as variáveis que iriam compor a camada de entrada, com os parâmetros das funções de base radial, definiu-se que a mesma teria 6 neurônios, sendo estes compostos pelas variáveis: Silte, Areia, Matéria Orgânica, Densidade do Solo, Argila e Porosidade, os valores dessas variáveis foram organizados no intervalo de 0 a 1. Essas variáveis foram escolhidas pela influência que as mesmas exercem na retenção de água no solo. De acordo com Reinert e Reichert (2006) as influências exercidas pelas variáveis são:

- **Silte:** O silte confere ao solo uma maior microporosidade, aumentando assim a força de retenção de água pela capilaridade;
- **Porosidade:** É responsável por um conjunto de fenômenos e desenvolve uma série de mecanismos de importância na física de solos, tal como retenção e fluxo de água e ar no solo;
- **Areia:** A areia retém pouca água, porque seu grande espaço poroso permite a drenagem livre da água dos solos;
- **Argila:** A argila absorve relativamente, grande quantidade de água e seu menor espaço poroso a retém contra as forças de gravidade;
- **Matéria Orgânica:** A matéria orgânica tem capacidade de absorver uma quantidade de água cerca de seis vezes superior ao seu peso. Os solos que contêm matéria orgânica têm uma melhor estrutura, que aumenta a infiltração da água e reduz a vulnerabilidade do solo à compactação, à erosão, à desertificação e aos escorregamentos.
- **Densidade do solo (Ds):** O uso principal da densidade do solo é como indicador da compactação, assim como medir alterações da estrutura e porosidade do solo.

Na camada intermediária, que forma combinações lineares das ativações de base radial para gerar a saída, a quantidade de unidades da camada oculta não é

fácil de determinar, a forma mais utilizada é tentativa e erro. Após verificar que os pesos representavam de forma satisfatória a relação entre as entradas e saídas definiu-se que a mesma seria composta por 15 neurônios.

Como saída, foram definidos 2 neurônios, sendo estes representados pela CC e o PMP do solo.

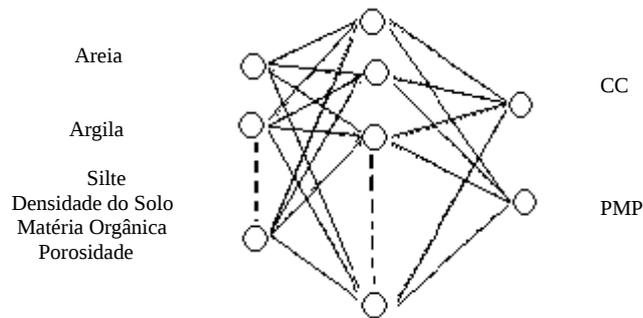


FIGURA 16 - Arquitetura da RNA RBF

Para obter melhores resultados, as entradas da rede foram alternadas, de forma que cada perfil fosse treinado contendo todas as entradas e posteriormente contendo apenas 5 entradas, onde retirou-se uma variável para verificar se a mesma interferia de forma significativa na predição. As saídas também foram alternadas, para que pudessem prever a CC e o PMP simultaneamente e logo após individualmente. Como mostra a Tabela 1:

TABELA 1 - Modelo de entrada e saída da RNA

Padrão de treinamento	Entradas	CC	PMP
1	1,2,3,4,5,6	X	X
2	2,3,4,5,6	X	X
3	1,3,4,5,6	X	X
4	1,2,4,5,6	X	X
5	1,2,3,5,6	X	X
6	1,2,3,4,6	X	X
7	1,2,3,4,5	X	X

8	1,2,3,4,5,6	X	
9	2,3,4,5,6	X	
10	1,3,4,5,6	X	
11	1,2,4,5,6	X	
12	1,2,3,5,6	X	
13	1,2,3,4,6	X	
14	1,2,3,4,5	X	
15	1,2,3,4,5,6		X
16	2,3,4,5,6		X
17	1,3,4,5,6		X
18	1,2,4,5,6		X
19	1,2,3,5,6		X
20	1,2,3,4,6		X
21	1,2,3,4,5		X

1- Silte; 2- Areia; 3- Matéria Orgânica; 4- Densidade do Solo; 5- Argila; 6- Porosidade

3.1.2.1 Padrões de Entrada

Como exigência do simulador JavaNNS, os arquivos de treinamento e de teste são organizados em padrões, num arquivo de extensão *.pat*, com a quantidade de padrões utilizados, quantidade de neurônios de entrada e de saída. De forma parecida, os arquivos de validação são construídos, porém sem os arquivos de saída.

Depois de construídos todos os arquivos necessários para o funcionamento da Rede Neural, a mesma foi submetida ao processo de treinamento.

3.1.2.2 Treinamento

O treinamento foi feito utilizando a Rede Neural Artificial RBF, e através de sua arquitetura puderam ser analisados o comportamento mediante o treinamento e validação. A arquitetura composta por uma camada intermediária, contendo 15 neurônios, os quais são conectados com os 6 neurônios da camada de entrada e com os 2 neurônios da camada de saída é mostrada na FIG. 17:

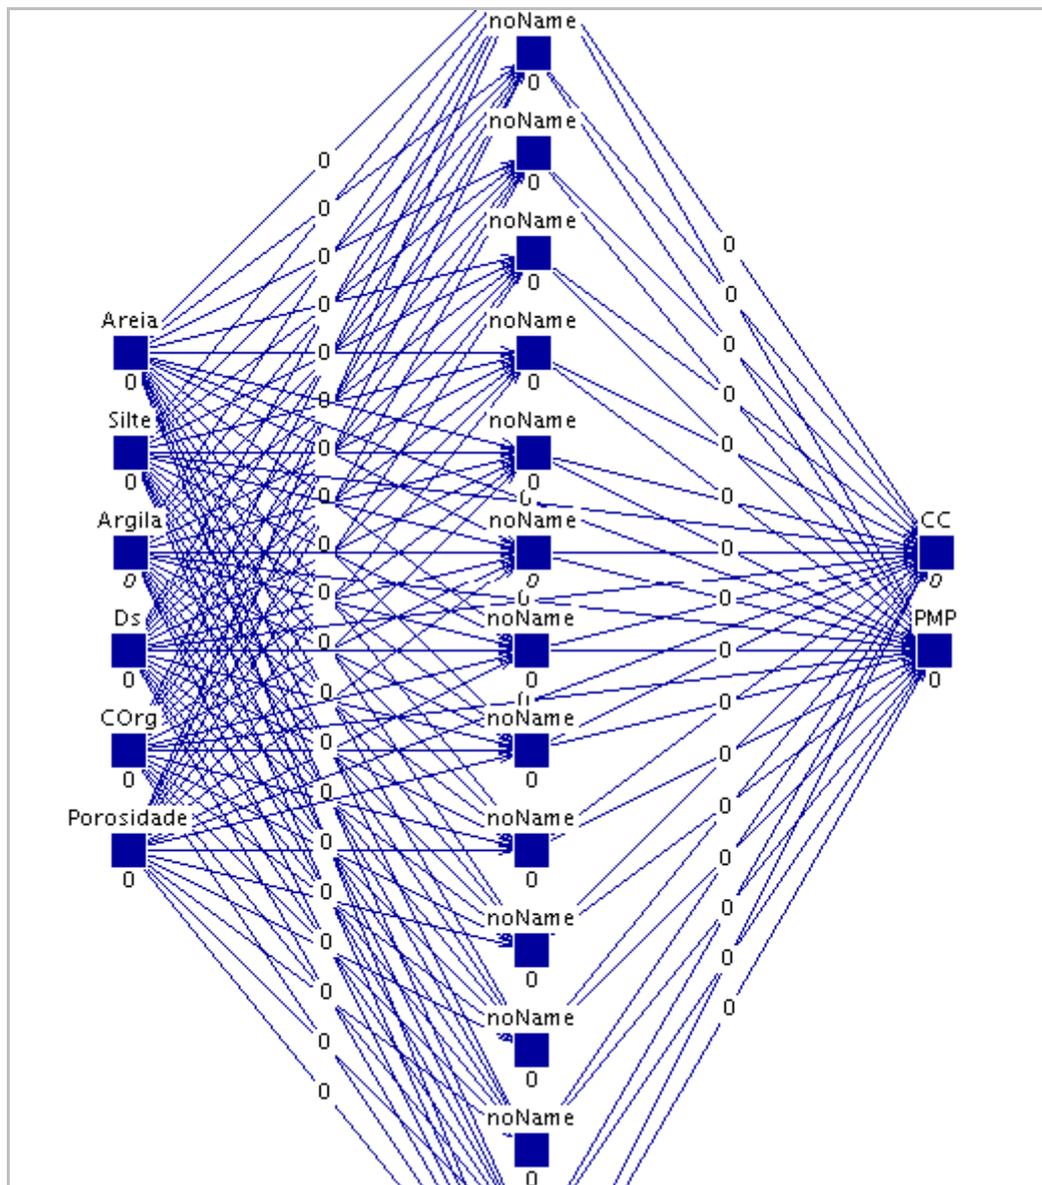


FIGURA 17 - Demonstração de parte da Arquitetura

Os arquivos de entrada foram criados de acordo com os padrões utilizados no JavaNNS. A FIG. 18 mostra um exemplo de arquivo de treinamento, de acordo com

esses padrões.

```

NNNS pattern definition file V3.2
generated at Mon Apr 25 17:54:03 1994

No. of patterns : 5
No. of input units : 6
No. of output units : 2

# Input pattern 1:
0.295918 0.209677 0.623656 0.691358 0.284734 0.6875
# Output pattern 1:
0.355 0.252

# Input pattern 2:
0.979592 0 0.043011 0.814815 0.007290 0.625
# Output pattern 2:
0.061 0.026

# Input pattern 3:
0.591837 0.290322 0.258064 0.666667 0.016295 0.7375
# Output pattern 3:
0.296 0.171

# Input pattern 4:
0.989796 0.016129 0.021505 0.870370 0.002144 0.5875
# Output pattern 4:
0.043 0.018

# Input pattern 5:
0.897959 0.161290 0.021505 0.697531 0.009434 0.7125
# Output pattern 5:
0.258 0.115

```

FIGURA 18 - Exemplo de um padrão de treinamento

O cabeçalho é constituído por informações sobre o arquivo que não precisam estar necessariamente atualizadas, porém são indispensáveis para sua utilização, em seguida tem-se a quantidade de padrões a serem utilizados, quantidade de neurônios da camada de entrada e da camada de saída, e logo abaixo encontra-se cada padrão de entrada a ser utilizado e cada padrão de saída.

Para o treinamento da rede, foram realizados os seguintes ajustes no painel de controle do simulador:

- **Learning function:** O algoritmo de treinamento utilizado foi o *Radial Basis Learning*;

- **η_1** : O valor do parâmetro para a taxa de aprendizado para a modificação do centro dos vetores foi 0.01. Segundo Silva (2010), a taxa de aprendizagem é um parâmetro de grande importância no treinamento da rede, pois controla a alteração dos pesos. Uma taxa baixa deixa o aprendizado muito lento, já uma taxa alta, acelera o aprendizado mas pode causar muitas oscilações no treino e pode dificultar o processo de generalização da rede;

- **η_2** : Não foram estabelecidos valores de *bias* para aumentar ou diminuir a influência dos valores de entrada;

- ***weights***: Para influenciar a formação dos pesos foi utilizado o valor 0.01. Segundo Silva (2010), os pesos sinápticos são de grande importância para uma rede neural, pois determinam toda a manipulação de valores da rede;

- ***dmax***: O erro máximo permitido foi estabelecido com o valor 0.1;

- **μ** : Termo Momentum, especifica a quantidade de mudanças de pesos anteriores que é adicionada a mudança atual. Os valores típicos utilizados estão entre 0 e 1.0, neste caso utilizou-se o valor 0.8.

- ***Steps***: Especifica o número de etapas de atualização da rede. Neste caso foram realizadas 7 etapas para o treinamento;

- ***Cycles***: Especifica o número de ciclos de treinamento, neste caso, cada etapa teve 100 ciclos de treinamento.

Essa configuração pode ser visualizada através do painel de controle do simulador, demonstrado na FIG. 19:

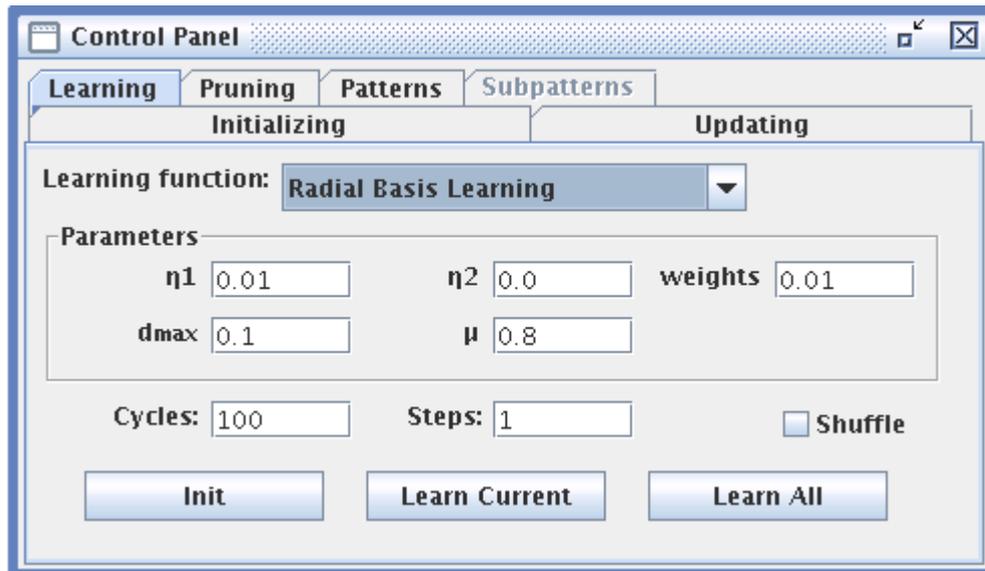


FIGURA 19 - Painel de Controle

Para indicar que o aprendizado já havia sido alcançado, a rede foi treinada até que sua função de erro permanecesse com erro mínimo estável. Como mostra a FIG. 20 através do gráfico de erro gerado durante o treinamento da rede.

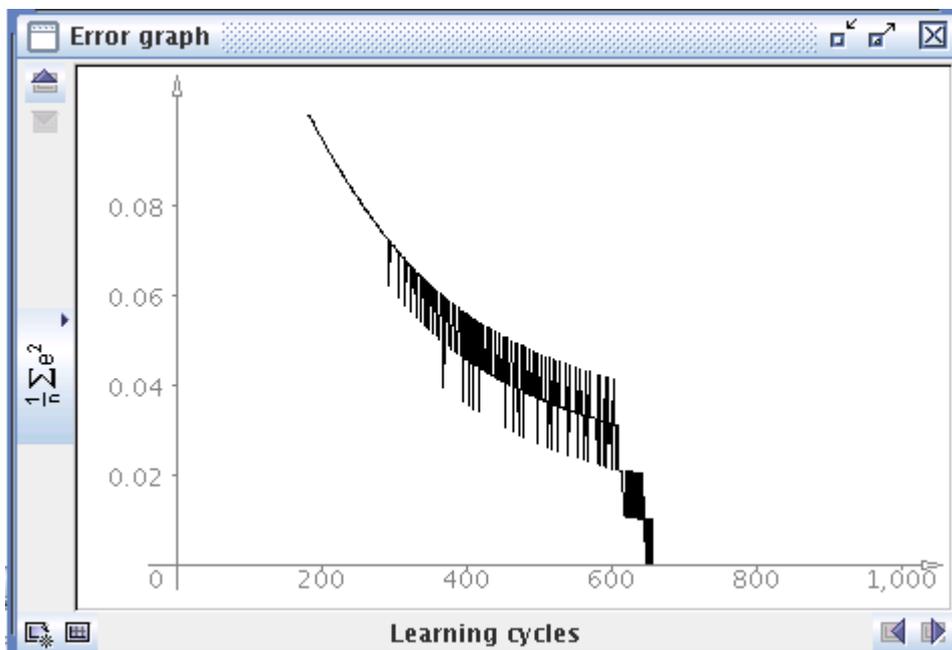


FIGURA 20 - Erro gráfico

Através do Log do sistema apresentado na FIG. 21, pode ser verificado de forma mais nítida o aprendizado, quando o valor do SSE paralisou em 0, não houve

mudança nos pesos da rede. Se novos ciclos de treinamento sobre a rede fossem realizados, nada iria acontecer, visto que o “aprendizado” já havia sido alcançado.

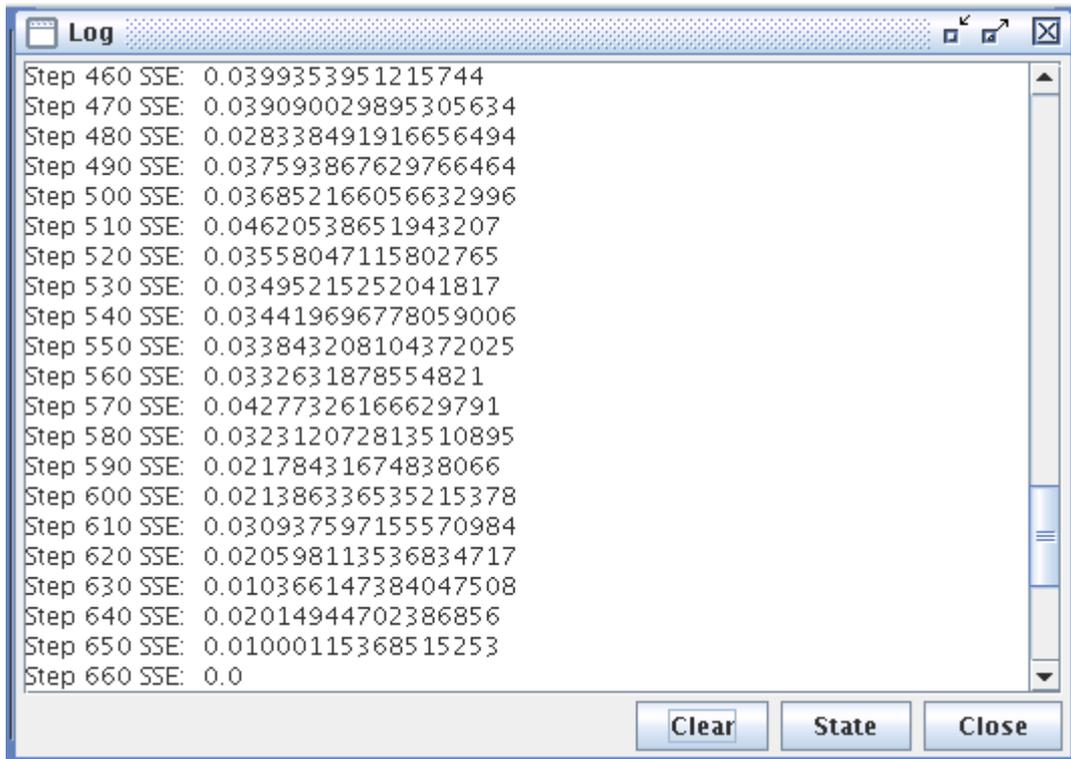


FIGURA 21 - Arquivo de registro gerado durante o treinamento da rede

Depois de realizado o treinamento, observou-se que a rede alcançou a convergência, uma vez que conseguiu aprender os padrões do conjunto de treinamento. Na FIG. 22 é mostrado parte da rede após o treinamento.

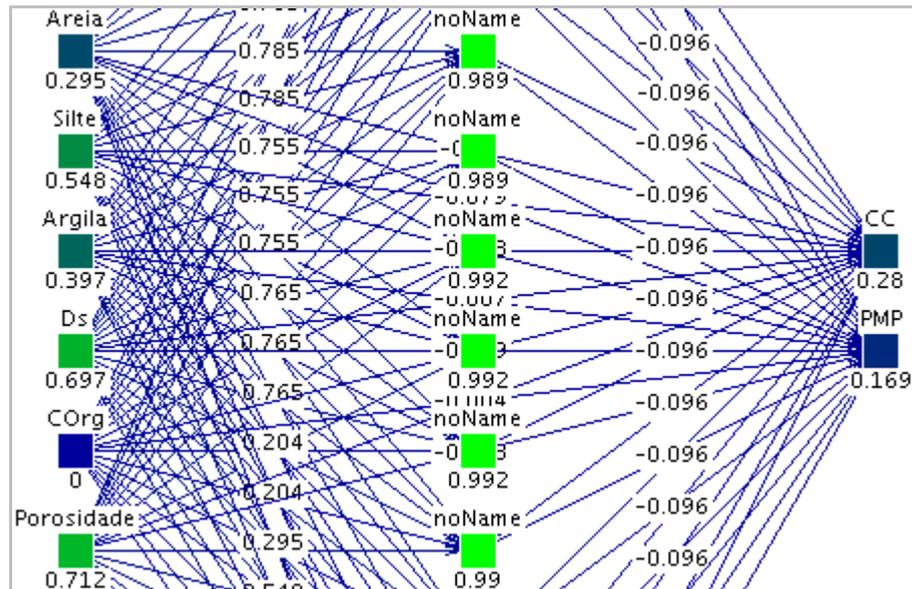


FIGURA 22 - RNA após o treinamento

A precisão da predição utilizando a RNA RBF foi qualificada pela RMSE (Raiz Quadrada do Erro Médio) entre o valor real e o valor predito e através do R², (Coeficiente Múltiplo de Determinação):

$$RMSE = \sqrt{\frac{1}{N} \sum_{N=1}^N (atual - predito)^2}$$

$$R^2 = 1 - \frac{SSE}{SS_y}$$

Onde $SSE = \sum (y - \hat{y})^2$ e $SS_y = \sum (y - \bar{y})^2$, y é o valor atual, \hat{y} é o valor predito, e \bar{y} é a média dos valores de y .

Através do RMSE pode-se estimar o erro em relação a comparação entre os valores reais e preditos. Um resultado de RMSE que obtiver o valor 0, pode ser considerado como um método que obteve perfeita exatidão. Quanto mais o resultado se afastar de 0, mais distante será a precisão.

O coeficiente múltiplo de determinação R², compara a eficiência dos dados em relação ao erro encontrado. Um resultado de R² que obtiver o valor 1 indica que o modelo utilizado se encaixa perfeitamente no problema, quanto mais se aproximar de 0, menos eficiência será o método.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Após o treinamento da rede, a mesma deve ser capaz de acertar as saídas de novos padrões que não foram apresentados durante o treinamento. Dessa forma, arquivos de teste *.pat* foram definidos, com padrões que correspondem a horizontes do solo reservados para validação. Nestes arquivos, além de alternar os dados de entrada, fez-se um revezamento entre as saídas para verificar qual das alternativas obteria melhores resultados.

Estes arquivos foram apresentados a rede e após o processo de validação, os resultados obtidos foram analisados em relação ao erro encontrado RMSE e ao coeficiente de determinação R2. A tabela 2 mostra seus respectivos valores, onde a coluna de padrão de validação exibe o número de cada padrão apresentado para a rede, a coluna de entradas especifica quais componentes do solo foram utilizados na entrada, a coluna CC e PMP exibe quais saídas foram utilizadas e nas colunas de RMSE e R2 são exibidos seus respectivos valores para a CC e PMP.

TABELA 2 - Resultados do RMSE e R2 obtidos

Padrão de Validação	Entradas	CC	RMSE	R2	PMP	RMSE	R2
1	1,2,3,4,5,6	X	0,031187	0,942790	X	0,021649	0,919755
2	2,3,4,5,6	X	0,032117	0,942786	X	0,020741	0,923120
3	1,3,4,5,6	X	0,054669	0,902609	X	0,014464	0,946385
4	1,2,4,5,6	X	0,018513	0,967020	X	0,028507	0,894333
5	1,2,3,5,6	X	0,029984	0,946584	X	0,020844	0,922737
6	1,2,3,4,6	X	0,032367	0,942341	X	0,021962	0,918593
7	1,2,3,4,5	X	0,030775	0,945176	X	0,021132	0,921673
8	1,2,3,4,5,6	X	0,031140	0,944530			
9	2,3,4,5,6	X	0,018250	0,967480			
10	1,3,4,5,6	X	0,031350	0,940000			
11	1,2,4,5,6	X	0,028740	0,950000			

12	1,2,3,5,6	X	0,019840	0,946710			
13	1,2,3,4,6	X	0,053580	0,904550			
14	1,2,3,4,5	X	0,031190	0,944440			
15	1,2,3,4,5,6				X	0,021460	0,920440
16	2,3,4,5,6				X	0,029140	0,891990
17	1,3,4,5,6				X	0,022980	0,914820
18	1,2,4,5,6				X	0,021920	0,918730
19	1,2,3,5,6				X	0,022090	0,918120
20	1,2,3,4,6				X	0,015150	0,943840
21	1,2,3,4,5				X	0,022670	0,915980

1- Silte; 2- Areia; 3- Matéria Orgânica; 4- Densidade do Solo; 5- Argila; 6- Porosidade

Analisando as informações da tabela 2, é possível observar que a rede obteve valores significativos considerando o resultado do R2 e do RMSE. Visto que os valores de R2 aproximaram-se do valor 1 indicando que o modelo utilizado se encaixa no problema e os valores do RMSE se aproximaram do valor 0 indicando que o método utilizado obteve uma boa precisão. Através dos gráficos a seguir, é possível visualizar melhor os resultados.

No primeiro gráfico estão os valores do RMSE para a Capacidade de Campo, e em seguida, para o Ponto de Murcha Permanente. Estes valores se referem aos resultados encontrados ao validar a rede com as duas saídas simultaneamente. A representação pode ser observada no GRAF. 7, onde os valores se encontram no intervalo de 0 a 0,06.

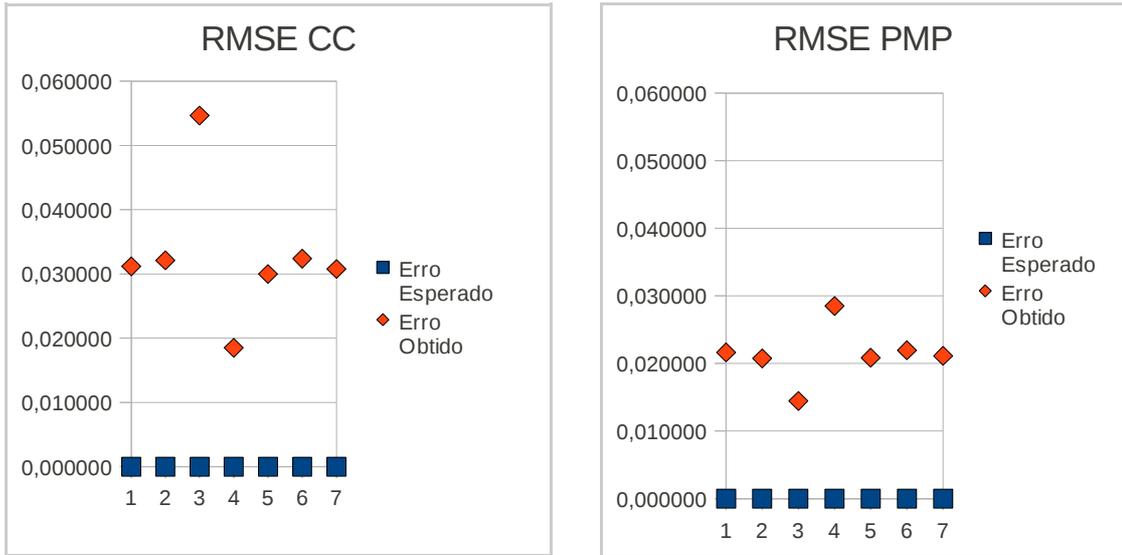


GRÁFICO 7- Valor de RMSE para CC e PMP preditos simultaneamente

Os dados, tanto para a CC quanto para o PMP obtiveram valores satisfatórios, analisando que os valores se aproximaram de forma significativa de zero, sendo este o objetivo. Observa-se ainda que o PMP obteve valores ainda mais aproximados de zero.

No GRAF. 8, estão os valores do R2 para a Capacidade de Campo, e em seguida, para o Ponto de Murcha Permanente. Estes valores também se referem aos resultados encontrados ao validar a rede com as duas saídas simultaneamente e se encontram representados no intervalo de 0,84 a 1,02.

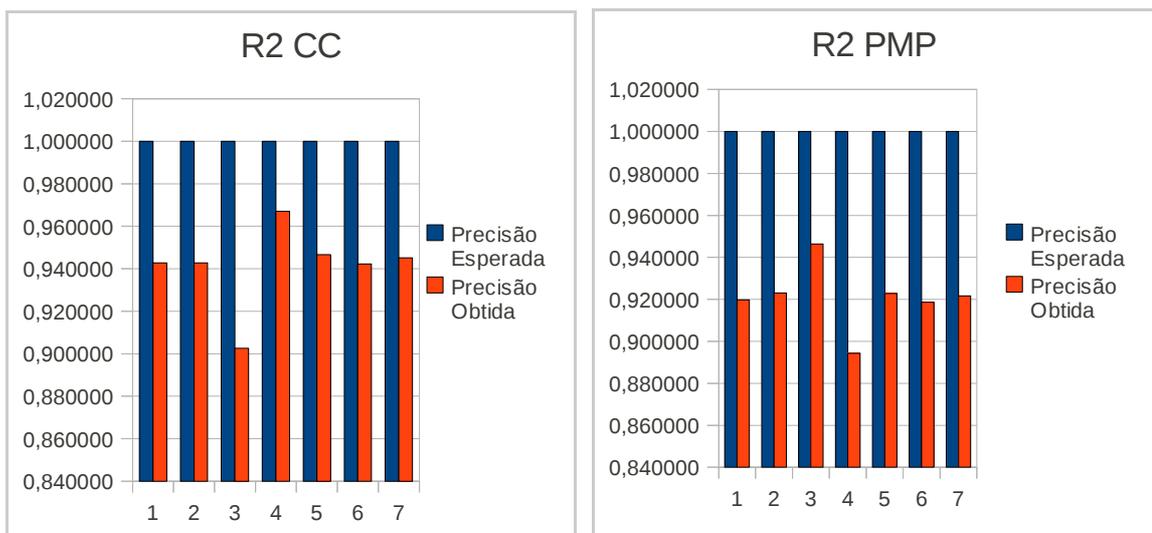


GRÁFICO 8 - Valor de R2 para CC e PMP preditos simultaneamente

Através da análise dos gráficos verifica-se que os valores de R2 também são satisfatórios, pois aproximam-se de forma significativa do valor 1, sendo este o objetivo. Observa-se também que os valores mais precisos foram encontrados para a CC, portanto apesar dos valores encontrados pelo RMSE no gráfico anterior terem sido melhores para o PMP, conclui-se que esses valores não foram obtidos da forma mais precisa que os valores encontrados para a CC.

No GRAF. 9, estão os valores do RMSE para a Capacidade de Campo, e em seguida, para o Ponto de Murcha Permanente encontrados ao validar a rede com as saídas individualmente, os valores se encontram no intervalo de 0 a 0,06.

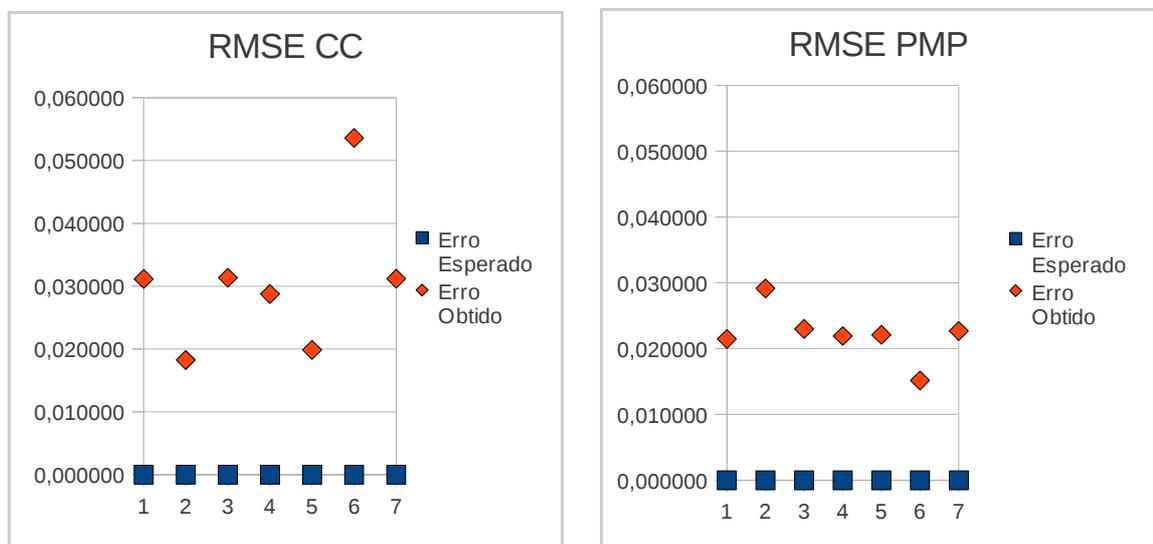


GRÁFICO 9 - Valor de RMSE para CC e PMP preditos individualmente

Após análise comparando os resultados obtidos com as duas saídas juntas, foram analisados os dados encontrados diante da alternância das saídas. De acordo com o GRAF. 9, o RMSE para a Capacidade de Campo e para o Ponto de Murcha Permanente, também obteve valores satisfatórios. Não sendo encontrados valores que tornam a predição com as alterações das saídas melhores ou piores que os resultados encontrados ao analisar as duas saídas juntas. Novamente observa-se que os valores encontrados para o RMSE do PMP obtiveram valores mais aproximados de zero.

No GRAF. 10, estão os valores do R2 para a Capacidade de Campo, e em seguida, para o Ponto de Murcha Permanente encontrados ao validar a rede com as saídas individualmente e se encontram representados no intervalo de 0,84 a 1,02.

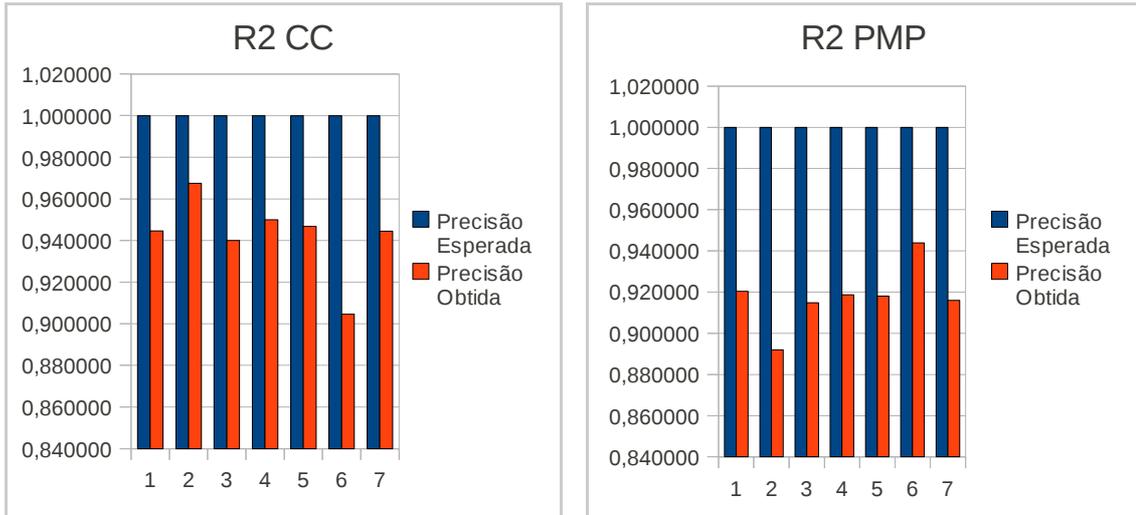


GRÁFICO 10 - Valor de R2 para CC e PMP preditos individualmente

De acordo com o esperado pelo RMSE obtido ao alternar os dados de saída, os valores de R2 também são significativos. Porém apesar de encontrar valores melhores para o RMSE do PMP, ao analisar o R2 observa-se que esses valores não foram obtidos da forma mais precisa que os valores encontrados para a CC.

Através dos gráficos conclui-se que os resultados encontrados para a CC foram melhores. Lembrando que quanto mais próximo de 1 se encontra o R2, mais preciso é o método utilizado.

Este comportamento é provavelmente uma consequência da diferença entre os mecanismos de retenção de água pela CC e PMP. No PMP a água é retida por absorção, que é relativamente homogênea e controlada pela superfície específica da amostra. Na CC, a capilaridade é o mais importante mecanismo, que é controlada pela porosidade.

Apesar de existir um alto coeficiente de correlação entre as variáveis argila e areia, no desenvolvimento do trabalho utilizando RNA RBF foi verificado que tanto a variável argila quanto a variável areia podem ser utilizadas no mesmo grupo de variáveis de entrada ou em grupos separados, conforme é indicado pelos bons coeficientes de determinação. Assim, o método apresenta uma vantagem em relação a outros métodos de predição que necessitam de uma avaliação rigorosa das variáveis de entrada evitando variáveis redundantes, ou seja, onde o aumento de uma reflete a diminuição da outra e vice-versa, interferindo de forma negativa nos resultados.

Os resultados obtidos neste trabalho foram comparados com os resultados obtidos por Brandão *et. al.* (2006). Foi encontrada uma melhoria relevante ao utilizar uma rede diferente da utilizada por ele, que pode ser observada na tabela 3, onde encontra-se os resultados mais significativos obtidos por Brandão *et. al.* (2006) ao prever a CC e o PMP simultaneamente.

TABELA 3 - Principais resultados encontrados por Brandão *et. al.* (2006) ao prever CC e PMP simultaneamente.

Padrão de Validação	CC	RMSE	R2	PMP	RMSE	R2
1	X	0,049	0,720	X	0,710	0,790
2	X	0,053	0,620	X	0,075	0,750
3	X	0,083	0,520	X	0,100	0,620

Através dos dados da tabela, observa-se que os valores de R2 e RMSE são inferiores aos valores encontrados neste trabalho. Portanto, o objetivo de melhorar os resultados de predição para áreas com grandes desníveis de textura, utilizando uma rede que suprisse a carência em relação a aproximação da rede MultiPerceptron (MLP) utilizada por Brandão *et. al.* (2006) para este tipo de problema, foi encontrado ao utilizar a RNA RBF.

5 CONCLUSÃO

A utilização de Redes Neurais Artificiais do tipo RBF (*Radial Base Function*) mostra-se bastante eficaz quando aplicada tanto no intuito de obter valores para CC (Capacidade de Campo) como para PMP (Ponto de Murcha Permanente), ambos de suma importância para a determinação da CAD (Capacidade de Água Disponível).

Neste trabalho, ao desenvolver uma RNA através do simulador JavaNNS para predição dos valores da CC e do PMP, utilizou-se como entrada variáveis que influenciavam na retenção de água no solo, tais como areia, argila, silte, matéria orgânica e porosidade.

A rede foi treinada utilizando tanto grupos de variáveis com alto coeficiente de correlação, quanto grupos onde uma variável não exercia influência direta sobre a outra. A validação da rede foi qualificada através do RMSE que estimou o erro em relação a comparação entre os valores reais e preditos e através do coeficiente múltiplo de determinação R^2 que comparou a eficiência dos dados em relação ao erro encontrado.

Verificou-se que a predição para grupo de variáveis com alto coeficiente de correlação, como areia e argila, podem ser utilizadas no mesmo grupo de variáveis de entrada, não interferindo de forma negativa nos resultados.

Por fim, esses resultados foram comparados com os resultados encontrados nas referências e percebe-se uma melhora significativa indicada pelos bons coeficientes de determinação, principalmente em grupos com variáveis de alto coeficiente de correlação.

Os modelos MLP e RBF são aproximadores universais, ou seja, sempre existirá uma RBF capaz de realizar a mesma função de uma MLP e vice-versa, entretanto as redes MLP constroem aproximadores globais, que são capazes de generalizar para regiões onde não existem dados de treinamento, classificando nós completamente diferentes dos nós de treinamento como existentes, já a RBF constrói aproximadores locais, com uma aprendizagem mais rápida e oferecendo respostas as regiões do espaços que apresentam dados de treinamento. Com isso, verificamos que para a predição de solos com grandes desníveis de textura, a rede RBF mostra-se mais eficaz do que a rede MLP.

Como sugestão de trabalhos futuros pode ser realizado a melhoria dos dados de entrada utilizando métodos auxiliares como por exemplo, Lógica Fuzzy;

Outra opção seria avaliar outros tipos de RNA e aplicar ao problema com o intuito de melhorar ainda mais os resultados;

Obter mais dados digitalizados, possibilitando assim novos estudos com diferentes amostras de solo;

Aplicar diferentes técnicas de mineração de dados, podendo ser citados algoritmos estatísticos, lógica nebulosa, clusterização, algoritmos Genéticos, entre outras;

Desenvolvimento de um sistema automático que permita que essas análises sejam feitas de forma automática;

Desenvolvimento de um sistema web que permita a utilização por diferentes pesquisadores do Brasil que atuam na área de solo;

Uso de tecnologia móvel que permita o uso do sistema em plantações, que os dados sejam enviados para um banco de dados de um servidor.

6 REFERÊNCIAS

ALMEIDA, M. A. F. **Introdução ao Estudos de Redes Neurais Artificiais**. Florianópolis, SC: Universidade Federal de Santa Catarina, 2000.

ANA. **Agenda Nacional de Conservação da Água e Uso Racional**. Disponível em <www.ana.gov.br>. Acesso em maio de 2007.

ASSIS, S. V. **Umidade do solo**. Pelotas, RS: Universidade Federal de Pelotas, 2007.

BARRETO, A. M. S. **Algoritmo Genético dos Mínimos Quadrados Ortogonal para o Treinamento de Redes RBF**. 2003.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2007.

BRANDÃO, D. N.; CEDDIA, M. B.; NASCIMENTO G. B.; OLIVEIRA, R. F e LEAL, V. F. **Neural Network applied to predict soil Field Capacity and Permanent Wilting Point**. II Global Workshop on digital mapping soil, 2006.

BROOMHEAD, D. S. e LOWE D. **Multi-variable functional interpolation and adaptive networks**. Complex Systems, Vol. 2, pp. 321-355.

CARDOSO, S. H. **Comunicação entre as células nervosas**. São Paulo, 2000.

CASTRO, F. C. C. e CASTRO, M. C. F. **Redes Neurais Artificiais**. Rio Grande do Sul, 2001.

CERA, M. C. **Redes Neurais no Reconhecimento de Padrões: Estudo de Caso**. Trabalho da disciplina CMP135 – Arquiteturas Especiais de Computadores, 2005.

DBO. **O uso da água e o cenário atual no Brasil**. Disponível em <www.PortalDBO.com.br>. Acesso em junho de 2007. nº 261, julho 2002.

DESOUZART, O. **Peço Água**. Disponível em <<http://pt.engormix.com/MA-avicultura/administracao/artigos/agua-na-agricultura-t353/124-p0.htm>>. Acesso em novembro de 2010.

DUARTE, A. M. **Verificação da autenticidade de uma assinatura digitalizada por meio de Redes Neurais Artificiais**. Caratinga, MG: Faculdades Integradas de Caratinga, 2007.

EBERHART, R. e DOBBINS, R. **Neural Networks PC Tools: A Practical Guide**. Academic Press, San Diego, 1990.

FELÍCIO, P. E. **Perspectivas para a tipificação de carcaça bovina**. I Simpósio Internacional sobre Tendências e Perspectivas da Cadeia Produtiva da Carne Bovina (Simprocarne). Anais. São Paulo SP, junho de 1999.

FISCHER, I.; HENNECKE, F.; BANNES, C. e ZELL, A. **JavaNNS: Java Neural Network Simulator**. Department of Computer Architecture, University of Tübingen, Wilhelm-Schickard-Institute for Computer Science. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/software/JavaNNS/manual/JavaNNS-manual.html>>. Acesso em: setembro de 2007.

GOEDEL, A.; SILVA, I. N.; SERNI, P. J. A. **Uma abordagem neural para estimação de conjugado em motores de indução**. Revista Brasileira Ciência do Solo: Sba Controle & Automação vol. 17 n3, Campinas Julho/Setembro 2006.

HAYKIN, S. **Redes Neurais: Princípios e prática**. Porto Alegre: Editora Bookman, 2001.

HEBB, D. O. **The organization of behavior**. New York: John Wiley, 1949.

HOPFIELD, J. J. **Neural Networks and Physical Systems with emergent collective computational abilities**. Proc. of the National Academy of Science, nº 79, p. 2554-2558, 1987.

KOEKKOEK, E. J. W. e BOOLTINK H. **Neural Network model to preict soil water retention**. European Journal of Soil Science, September 1999,50,489-495.

LOESCH, C. e SARI, S. T. **Redes neurais artificiais: fundamentos e modelos**. Blumenau: Editora da FURB, 1996.

LOYOLA, J. M. T. e PREVEDELLO, C.L. **Modelos analíticos para predição do processo da redistribuição da água no solo**. Viçosa, Revista Brasileira de Ciência do Solo, Vol. 27. 2003.

MELLO, F. C. Q. **Modelos preditivos para diagnósticos da tuberculose pulmonar paucibacilar**. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2001.

MENDES, D. Q.; OLIVEIRA, M. F. S. **Tutorial em Redes Neurais: Aplicações em Bioinformática**. Disponível em <<http://www.lncc.br/~labinfo/tutorialRN>>. Acesso em agosto de 2008.

MINSKY M. e PAPERT S. **Perceptrons**, 1969.

NASCIMENTO G. B.; ANJOS, L. H. C.; SANTOS, H. G.; ZUCHELLO F.; MEIRELES P. G.; PLIESKI G. L. A; PEREIRA M. G. **Funções de pedotransferência para predizer conteúdo de água em Latossolos Amarelos e Argissolos Amarelos no Brasil**. Rio de Janeiro, RJ: Universidade Federal Rural do Rio de Janeiro, 2005.

PAIXÃO, F. J. R.; ALENCAR, S. B.; COSTA, T. L.; MARQUES, L. F. e TRINDADE, J. L. **Capacidade de campo de um neossolo flúvico determinada por métodos diretos e indiretos**. Paraíba, Revista de biologia e ciências da terra ciências da terra, Volume 4- Número 2 - 2º Semestre 2004.

PIRES, L. F. **Tomografia computadorizada, atenuação de raios gama e análise micromorfológica na avaliação de alterações na estrutura e retenção de água pelo solo.** São Paulo, 2006.

PRADO, H. **Manual de classificação de solos do Brasil.** 2ª ed. Jaboticabal: FUNEP, 1995.

REICHARDT, K. **A água em sistemas agrícolas.** São Paulo: Editora Manoele Ltda, 1990.

REINERT, D. J. e REICHERT, J.M. **Propriedades Físicas do Solo.** Santa Maria, RS : Universidade Federal de Santa Maria, 2006.

RNP. **Utilizando redes neurais para predição de falhas em links de redes ópticas.** Boletim bimestral, Vol. 7, 2003.

ROSSATO, L. **Estimativa da capacidade de armazenamento de água no solo do Brasil.** São José dos Campos, 2001.

SILVA, S. S. **SARCO – Sistema Automático de Reconhecimento e Contagem de Ovos de Dengue.** Recife: Universidade Federal de Pernambuco, 2010.

SOARES, E. H. R. **PROJIR:** Projeto de Irrigação e Drenagem da Cana-de-açúcar na Região Norte Fluminense. Disponível em <<http://www.campuslm.ufrj.br/Produtos.asp?Grupo=5&Fundo>>. Acesso em outubro de 2010.

VENZELA, L. S. e ANDRADE, M. C. N. **Manejo da Irrigação Via Solo.** Disponível em: <<http://www.agr.feis.unesp.br/manejoirrigacao.html>>. Acesso em: março de 2007.

VON ZUBEN, F. J. **Processamento Dinâmico em Redes Neurais Artificiais: Redes Neurais Recorrentes.** São Paulo, 2004.