

UNIVERSIDADE DO VALE DO RIO DOS SINOS – UNISINOS
CIÊNCIAS EXATAS E TECNOLÓGICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOLOGIA
MEIO AMBIENTE E RECURSOS MINERAIS
GEOLOGIA E PLANEJAMENTO AMBIENTAL

Meriéle Reinke

UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS APLICADAS A
MAPEAMENTOS HIDROGEOLÓGICOS

São Leopoldo – RS

2008

Meriéle Reinke

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS APLICADAS A
MAPEAMENTOS HIDROGEOLÓGICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Geologia da Universidade do Vale do Rio dos Sinos - UNISINOS, como requisito para a obtenção do Título de Mestre em Geologia (Área de Concentração Meio Ambiente e Recursos Minerais).

Orientador: Prof. Dr. Maurício R. Veronez

São Leopoldo - RS

2008

Meriéle Reinke

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS APLICADAS A
MAPEAMENTOS HIDROGEOLÓGICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Geologia da Universidade do Vale do Rio dos Sinos - UNISINOS, como requisito para a obtenção do Título de Mestre em Geologia (Área de Concentração Meio Ambiente e Recursos Minerais).

Aprovado em

BANCA EXAMINADORA

Dr. José Luiz Flores Machado - CPRM - Serviço Geológico do Brasil

Dr. Carlos Augusto Uchoa da Silva - Universidade Federal do Ceará

Dr. Maurício Roberto Veronez - Universidade do Vale do Rio dos Sinos

*Dedico este trabalho:
ao meu marido, Telmo;
à minha amiga e companheira, Mytsa.*

AGRADECIMENTOS

Meus sinceros agradecimentos...

...primeiramente a Deus, por ter iluminado meu caminho e me
fortalecido;

...ao Telmo, pela disposição, auxílio, compreensão e “paciência”;

...aos meus pais, pela compreensão e apoio;

... ao Anderson e a Dati, pela revisão;

...ao Alessandro, pelo socorro na hora “H”;

...ao Vagner, por estar sempre “pronto”;

...ao Dr. José Luiz Flores Machado, pelas sugestões no decorrer do
trabalho;

...ao professor Dr. Maurício Roberto Veronez, pela orientação.

*“Algo só é impossível até que alguém
duvide e prove o contrário!”
(Albert Einstein)*

RESUMO

A gestão dos recursos hídricos exige o uso de ferramentas que representem os processos hidrológicos de forma clara e objetiva para auxiliar na compreensão e utilização dos mesmos. Atendendo a essa necessidade, desenvolveram-se modelos computacionais que sistematizam problemas complexos de modo simples. Entre esses modelos cita-se a técnica de Redes Neurais Artificiais, metodologia inspirada no sistema nervoso humano e que possui a habilidade de aprender e generalizar possibilitando a resolução de problemas complexos. Neste trabalho é estudada a aplicação de Redes Neurais Artificiais do tipo *Perceptron* Multicamadas baseadas no algoritmo de aprendizado *backpropagation* para estimar a espessura da Formação Serra Geral, o nível estático e a capacidade específica, baseado em informações contidas no cadastro de poços do Sistema de Informação de Águas Subterrâneas para a Bacia Hidrográfica do Rio Caí no estado do Rio Grande do Sul. Através do teste de *Student* (teste T), com um nível de significância de 5%, estatisticamente, os modelos propostos para as estimativas da espessura da Formação Serra Geral, do nível estático e da capacidade específica não diferiram dos tomados como verdadeiros. Também, por meio de regressão linear verificou-se através do coeficiente R^2 uma forte correlação entre as variáveis simuladas e as verdadeiras. Os resultados indicaram que as RNAs podem ser utilizadas como um método alternativo em relação à modelagem convencional visando a elaboração de cartas temáticas bem como a otimização de processos para a exploração de água subterrânea.

Palavras-chaves: redes neurais artificiais, modelos hidrogeológicos, mapeamento hidrogeológico.

ABSTRAC

The hydric resources management demands the use of tools that represent the hydrologic processes in a clear and objective way to assist the understanding and using of them. Considering this necessity, computer models that systemize complex problems in a simple way have been developed. Among these models is the Artificial Neural Network technique, a methodology inspired on human nervous system which has the ability to learn and generalize, making possible to solve complex problems. In this work is studied the application of Artificial Neural Networks of Perceptron Multilayer type, based on backpropagation learning algorithmic to estimate the thickness of Serra Geral formation, the static level and specific capacity, based on information extracted from well cadastre of Groundwater Information System for the Hydrographic Basin of Cai River in Rio Grande do Sul state. Through the Student test (test T), with a significance level of 5%, statistically, the models proposed for the estimates of the thickness of Serra Geral Formation, the level static and specific capacity did not differ from taken as true. Also, through linear regression there has been through the coefficient R^2 a strong correlation between variables simulated and the real. The results demonstrate that the developed models through the Artificial Neural Networks present good results on prevision of hydrogeologic parameters, which could be used as a base to elaborate thematic maps. In the same way, they suggest the use of alternative data for conventional modeling aiming at processes optimization for groundwater exploration.

Keywords: artificial neural networks, hydrogeological models, hydrogeological mapping.

LISTA DE FIGURAS

FIGURA 1 - Estrutura geral de um neurônio biológico.....	21
FIGURA 2 - Estrutura de neurônio artificial.....	23
FIGURA 3 - Gráficos das funções de ativação das RNAs.....	25
FIGURA 4 - Fluxograma da estruturação de uma Rede Neural.....	27
FIGURA 5 - Arquitetura de uma rede Perceptron Multicamadas.....	29
FIGURA 6 - Etapa de propagação do algoritmo bacpropagation.....	32
FIGURA 7 - Etapa de retropropagação do algoritmo bacpropagation.....	32
FIGURA 8 - Fluxograma para elaboração do modelo hidrológico.....	36
FIGURA 9 - Fluxograma para aplicação do modelo hidrológico.....	37
FIGURA 10 - Bacia Hidrográfica do Rio Caí.....	44
FIGURA 11 - Distribuição dos poços amostrados da Bacia do Rio Caí.....	47
FIGURA 12 - Fluxograma da metodologia adotada.....	49
FIGURA 13 - Estrutura da RNA1.....	61
FIGURA 14 - Espessura conhecida e simulada pela RNA1.....	63
FIGURA 15 - Regressão linear para a espessura conhecida e simulada pela RNA1.....	64
FIGURA 16 - Cartas de isolinhas para espessura da Formação Serra Geral conhecida	66
FIGURA 17 - Cartas de isolinhas para espessura da Formação Serra Geral simulada	66
FIGURA 18 - Cartas de isolinhas para cota máxima da Formação Botucatu conhecida.....	67
FIGURA 19 - Cartas de isolinhas para cota máxima da Formação Botucatu Simulada	67
FIGURA 20 - Estrutura da RNA2.....	68
FIGURA 21 - Nível estático conhecido e simulado pela RNA2.....	70
FIGURA 22 - Regressão linear para nível estático conhecido e simulado pela RNA2.....	71
FIGURA 23 - Cartas de isolinhas para profundidade do nível estático conhecido.....	73

FIGURA 24 - Cartas de isolinhas para profundidade do nível estático simulado.....	73
FIGURA 25 - Cartas de isolinhas para cota máxima do nível estático conhecido	74
FIGURA 26 - Cartas de isolinhas para cota máxima do nível estático simulado.....	74
FIGURA 27 - Estrutura da RNA3.....	75
FIGURA 28 - Capacidade específica conhecida e simulada pela RNA3.....	77
FIGURA 29 - Regressão linear para capacidade específica conhecida e simulada pela RNA3.....	78
FIGURA 30 - Carta de isolinhas para capacidade específica conhecida e simulada	80
FIGURA 31 - Carta de isolinhas para capacidade específica conhecida e simulada	80

LISTA DE QUADROS

QUADRO 1 - Municípios integrantes da Bacia do Rio Caí.....	45
--	----

LISTA DE TABELAS

TABELA 1 - Sistemas Aqüíferos da Bacia Hidrográfica do Rio Caí.....	47
TABELA 2 - Relação dos poços amostrados da Bacia Hidrográfica do Rio Caí.....	51
TABELA 3 - Estimativas para a espessura da Formação Serra Geral pela RNA1.....	62
TABELA 4 - Resultados do teste de hipótese para RNA1.....	65
TABELA 5 - Estimativa dos níveis estáticos de poços pela RNA2.....	69
TABELA 6 - Resultados do teste de hipótese para RNA2.....	72
TABELA 7 - Estimativas das capacidades específicas de poços pela RNA3.....	76
TABELA 8 - Resultados do teste de hipótese para RNA3.....	79

LISTA DE ABREVIATURAS E SIGLAS

ADALINE - *Adaptative Linear Element*

CORSAN - Companhia Riograndense de Saneamento

CPRM - Companhia de Pesquisa de Recursos Minerais (Serviço Geológico do Brasil)

IBGE - Instituto Brasileiro de Geografia e Estatística

INMET - Instituto Nacional de Meteorologia

MADALE - *Many Adaptative Linear Element*

MLP - Rede *Perceptron* Multicamadas

MSE - *Mean Square Error*

RNA - Redes Neurais Artificiais

SAG - Sistema Aquífero Guarani

SEMA - Secretaria Estadual de Meio Ambiente

SIAGAS - Sistema de Informações de Água Subterrânea

SIG - Sistema de Informação Geográfica

UTM - Universal Transverso de Mercator

SUMÁRIO

1 INTRODUÇÃO	15
1.1 OBJETIVO PRINCIPAL.....	17
1.1.1 Objetivos Específicos.....	18
2 REDES NEURAIS ARTIFICIAIS.....	19
2.1 NOTAS HISTÓRICAS.....	19
2.2 INSPIRAÇÕES BIOLÓGICAS.....	21
2.3 ESTRUTURA DE PROCESSAMENTO.....	22
2.3.1 Unidades de Processamento.....	22
2.3.2 Arquitetura da RNA.....	25
2.3.3 Conjunto de Treinamento.....	27
2.3.4 Perceptron e Perceptron Multicamadas	28
2.3.5 Conexão Entre as Unidades de Processamento.....	30
2.3.6 Processo de Aprendizado.....	30
2.3.7 Algoritmo de Treinamento <i>Backpropagation</i>.....	31
3 REVISÃO BIBLIOGRÁFICA	33
3.1 MAPEAMENTO HIDROGEOLÓGICO DO RIO GRANDE DO SUL	33
3.2 MODELOS HIDROLÓGICOS	34
3.3 APLICAÇÕES DE REDES NEURAIS ARTIFICIAIS	38
4 ÁREA DE ESTUDO E BANCO DE DADOS.....	44
4.1 ÁREA DE ESTUDO.....	44
4.1.1 Bacia Hidrográfica do Rio Caí.....	44
4.2 BANCO DE DADOS – SIAGAS.....	48
5 MATERIAIS E MÉTODO.....	49
5.1 DESCRIÇÃO DO MÉTODO.....	49
5.2 ANÁLISE ESTATÍSTICA.....	56
5.2.1 Teste T para amostras independentes.....	57
6 RESULTADOS	60
6.1 RESULTADOS REFERENTES À ESTIMATIVA DA ESPESSURA DA FORMAÇÃO SERRA GERAL (RNA1).....	61

6.2 RESULTADOS REFERENTES À ESTIMATIVA DO NÍVEL ESTÁTICO (RNA2).....	68
6.3 RESULTADOS REFERENTES À ESTIMATIVA DA CAPACIDADE ESPECÍFICA (RNA3).....	75
7 DISCUSSÃO DOS RESULTADOS.....	81
7.1 CONSTRUÇÃO DAS REDES NEURAIS ARTIFICIAIS.....	81
7.2 RNA1: ESPESSURA DA FORMAÇÃO SERRA GERAL.....	82
7.3 RNA2: REDE PARA NÍVEIS ESTÁTICOS.....	84
7.4 RNA3: REDE PARA CAPACIDADES ESPECÍFICAS.....	85
8 CONCLUSÕES E CONSIDERAÇÕES FINAIS.....	87
9 REFERÊNCIAS.....	90

1 INTRODUÇÃO

A água é um recurso crucial ao desenvolvimento de uma região. Em especial, as águas subterrâneas passam a desempenhar um papel importante nas regiões sem sistema centralizado de abastecimento, com déficit de água superficial, ou ainda, em locais onde o aumento da poluição apresenta níveis intoleráveis (Mirlean *et al*, 2005, Freire *et al*, 1998).

O maior incentivo à adoção da água subterrânea para o abastecimento urbano é a redução do custo de produção em relação às fontes superficiais deterioradas (Rebouças, 2002). Conseqüentemente, sua utilização para fins de abastecimento doméstico e/ou industrial vem crescendo em escala acentuada e desordenada, sendo que, muitas vezes, os estudos prévios à exploração são negligenciados. Como exemplo, cita-se a alocação de poços, onde se deve levar em consideração dados geológicos preexistentes da área ou região, além de um reconhecimento de campo, baseado em uma análise da geologia de superfície e sub-superfície, por métodos geofísicos ou sondagem mecânica (Capucci *et al*, 2001), que visam evitar prejuízos irreversíveis ao aquífero.

Dentro desse contexto, a gestão da água subterrânea apóia-se em bases frágeis, tornando-se necessário o desenvolvimento de estratégias de proteção e monitoramento constante da qualidade e da quantidade da mesma para o seu uso no presente e no futuro. A criação de um planejamento de uso considerando medidas para a minimização dos danos aos recursos subterrâneos deve levar em consideração os processos hidrogeológicos, os critérios econômicos, ambientais e institucionais da região.

A geração de estratégias eficientes exige o conhecimento adequado dos processos hidrológicos característicos de uma região. De modo geral, a compreensão desses processos é possível através do emprego de mapeamentos e modelos hidrogeológicos, determinados pela correlação de diversas variáveis.

Um mapa hidrogeológico mostra-se uma ferramenta fundamental que agrega informações integradas e que facilita a tomada de decisões no planejamento e no uso dos recursos hídricos, podendo responder a diversas questões. Se esse for direcionado à exploração da água subterrânea, os dados dos poços são interessantes a fim de gerar um modelo hidrológico para ser, em correlação com outros dados, indicador das potencialidades dos aquíferos e da situação atual da exploração de água subterrânea por aquífero, por bacia hidrográfica, por município ou qualquer recorte que se queira dar ao espaço geográfico.

De acordo com Tucci (1998), a modelagem busca representar o comportamento dos sistemas hidrológicos em uma linguagem de fácil acesso e uso, com o objetivo de melhor entendê-los e prever condições diferentes das até então observadas. A estimativa, a verificação e a previsão hidrológica limitam-se pela heterogeneidade física e dos processos envolvidos na área, o que tem levado ao desenvolvimento de diversos modelos que se diferenciam por meio dos dados utilizados, das prioridades de representação e dos objetivos a serem alcançados.

Contudo, a quantificação de certas variáveis necessárias aos modelos envolvidos nos mapeamentos hidrogeológicos pode ser de difícil acesso e envolver custos dispendiosos. Por exemplo, a estimativa da transmissividade e do coeficiente de armazenamento de um aquífero exigem a realização de ensaios de bombeamento para a organização de dados não somente do poço bombeado, mas também dos de observação. Essa realidade traduz-se numa das principais dificuldades na criação de ferramentas para o monitoramento dos recursos hídricos subterrâneos, pois não há dados em quantidade e cobertura adequada.

Através do uso de Redes Neurais Artificiais (RNAs) vislumbra-se um método alternativo à metodologia convencional (estudos geofísicos, sondagens mecânicas ou ensaios de bombeamento) para ser utilizado em questões de previsão de informações hidrogeológicas de uma forma rápida e com variáveis de fácil acesso.

As RNAs são sistemas compostos por unidades de processamento simples interconectadas que calculam determinadas funções matemáticas

(Braga *et al*, 1998), além disso, possuem capacidade de generalização, classificação, interpolação, extrapolação, tolerância a erros e ruídos e também pelo fato de não haver a necessidade prévia de parametrização explícita na modelagem (Haykin, 2001). Esta técnica que teve seu estudo iniciado ainda na década de 40, passou por certo esquecimento durante a década de 70 e ressurgiu no final dos anos 80 como uma alternativa à computação tradicional. Nos dias atuais são comuns os trabalhos que apresentam a utilização de RNAs, principalmente em previsão de dados, algoritmos de aprendizado, otimização de sistemas, reconhecimento de padrões, entre outros, nas mais diversas áreas do conhecimento (Haykin, 2001).

Esses sistemas têm sido utilizados para modelar fenômenos físicos nos quais (Müller & Fill, 2003):

- Não há necessidade do conhecimento da teoria intrínseca do problema;
- Para analisar problemas onde a relação entre variáveis não é totalmente conhecida;
- Em questões de difícil modelagem;

1.1. OBJETIVO PRINCIPAL

O objetivo principal desse trabalho foi desenvolver um método para estimar os seguintes parâmetros relacionados à água subterrânea: espessura da Formação Serra Geral, profundidade do nível estático e a capacidade específica de poços através da utilização de um modelo de rede neural, usando algoritmos de aprendizado supervisionado, baseado em informações disponibilizadas pelo SIAGAS (Sistema de Informações de Águas Subterrâneas) para a Bacia Hidrográfica do Rio Caí, estado do Rio Grande do Sul.

1.1.1 Objetivos Específicos

Destacam-se como objetivos específicos deste trabalho:

- Comparar e discutir os resultados obtidos a partir do modelo proposto com os existentes no SIAGAS;
- Aplicar o modelo proposto com o intuito de elaborar cartas de isolinhas das variáveis estimadas.

2 REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNAs) são agrupamentos de unidades de processamento (neurônios ou nós), estruturadas e interconectadas, cujo funcionamento é análogo a uma estrutura neural de organismos inteligentes (Müller & Fill, 2003). As RNAs extraem seu poder computacional da sua distribuição de estrutura maciçamente paralela e da sua habilidade de aprender/generalizar, tornando possível a resolução de problemas complexos nas mais diferentes áreas do conhecimento (Haykin, 2001).

2.1 NOTAS HISTÓRICAS

O maior entendimento da neurociência tem permitido uma melhor compreensão do funcionamento do cérebro humano, por exemplo, como se dá o fluxo e o processamento de informações no interior deste. Baseadas neste entendimento, os diferentes ramos de inteligência artificial, dentre os quais estão as RNAs, também progredem de maneira animadora, buscando desenvolver paradigmas ou algoritmos computacionais que tornem possível o modelamento matemático desse comportamento para a reprodução de tarefas cognitivas, mesmo que de forma simples e primitiva. O breve histórico apresentado a seguir é baseado em Haikyn (2001).

A era moderna das RNAs começou com o trabalho pioneiro de 1943, “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, do psiquiatra e neuroanatomista Warren McCulloch e do matemático Walter Pitts. Neste trabalho é descrito o cálculo lógico das RNAs que unifica os estudos de neurofisiologia e da lógica matemática. McCulloch e Pitts mostraram que uma rede com um número suficiente de unidades simples, com conexões sinápticas ajustadas apropriadamente e operando de forma sincrônica, realizaria, em princípio, a computação de qualquer função.

Em 1949, ocorreu o próximo passo relevante do desenvolvimento das RNAs, com a publicação do livro de Donald Hebb (*"The Organization of Behavior"*), no qual uma teoria baseada no processo de aprendizagem que ocorre no cérebro humano serviu de base para a criação de modelos computacionais de sistemas adaptativos e de aprendizagem. Nos anos subsequentes, novos estudos na área aprimoraram o desenvolvimento das RNAs. Entre eles, a criação da idéia de um filtro adaptativo não-linear e o desenvolvimento do conceito de memória associativa que introduziu a matriz de aprendizagem.

Em 1958, Frank Rosenblatt criou a rede *Perceptron*, com uma estrutura muito simples contendo apenas duas camadas de neurônios; mas usada com sucesso para o reconhecimento de caracteres. Com esta rede, Rosenblatt introduziu um método inovador de aprendizagem supervisionada ao problema de reconhecimento de padrões. Paralelamente, em 1960, Bernard Widrow e Marcian Hoff criaram o algoritmo dos Mínimos Quadrados médio (Least Mean-Square), e a primeira rede capaz de imitar o cérebro humano utilizando processadores paralelos, chamada de rede ADALINE (*Adaptative Linear Element*). Mais tarde, o aprimoramento originou a rede MADALINE (*Many ADALINE*).

Os anos áureos da rede *Perceptron* de Rosenblatt transcorreram durante toda a década de 60. Entretanto, em 1969, sua credibilidade foi abalada devido a severas críticas feitas por Mavin Minsky e Seymour Papert, com a publicação "*Perceptron*", baseada em argumentos de que as RNAs apresentavam limitações em suas aplicações, não possuíam capacidade de aprendizado para resolver problemas simples, nem adequada sustentação matemática. Então, as RNAs passaram por um período de descrédito e abandono durante toda a década de 70. Apesar disso, alguns pioneiros mantiveram-se firmes em suas convicções, fazendo surgir trabalhos significativos.

As pesquisas com as RNAs só voltaram a recuperar sua credibilidade com o trabalho do físico e biólogo John Hopfield, em 1982, que contestou Minsky e Papert com sucesso, fomentando um novo interesse pelas redes. A partir de então, os trabalhos desenvolvidos, mas não divulgados por

incógnitos pesquisadores nos anos de incredulidade, criaram uma avalanche de publicações.

A retomada das pesquisas sobre o tema fez surgir e desenvolver novas teorias, projetos e aplicações, como, por exemplo, a introdução do algoritmo *backpropagation* em 1986.

2.2 INSPIRAÇÕES BIOLÓGICAS

O perfeito funcionamento e integração entre os diversos setores de um organismo, que inspiraram os idealizadores das RNAs, são garantidos pelo rápido recebimento, processamento e condução dos impulsos nervosos, por meio de células altamente especializadas na captura e transmissão dos impulsos nervosos, chamados neurônios. Os neurônios biológicos são formados por três porções distintas: o corpo celular, diversos dendritos e um axônio (FIGURA 1).




FIGURA 1 - Estrutura geral de um neurônio biológico.

O corpo celular de um neurônio é a parte central da célula onde estão contidos o núcleo, o citoplasma e as organelas celulares. Projetando-se a partir do corpo celular estão os dendritos (especializados em receber estímulos) e um axônio (especializado em transmitir impulsos nervosos). A extremidade do axônio pode se ramificar em diversas terminações, aumentando a superfície de contato da célula.

O tecido nervoso de um organismo biológico pode abranger mais de um trilhão de neurônios com múltiplas interconexões entre suas extremidades, formando um complexo sistema de comunicação. Esta comunicação é realizada através de impulsos. Quando um impulso é recebido, o neurônio o processa, e passado um limite de ação, dispara um segundo impulso, produzindo um neurotransmissor que flui do corpo celular para o axônio conectado a um dendrito de outra célula. O neurônio que transmite o pulso pode controlar a frequência do mesmo aumentando ou diminuindo a polaridade na membrana pós-sináptica. Os impulsos são transferidos a centros superiores para processamento e interpretação de sensações ou para início de respostas motoras (Gartner & Hiatt, 1997).

Esta estrutura, que possui alta capacidade de aprendizado e adaptação, inspirou a criação de um sistema artificial capaz de simular o aprendizado e a generalização de uma rede neural biológica, podendo assim, realizar tarefas que programas convencionais não conseguiriam.

2.3 ESTRUTURA DE PROCESSAMENTO

2.3.1 Unidades de Processamento

Um neurônio é uma unidade de processamento de informação fundamental para a operação de uma rede (Haikyn, 2001). Todas as RNAs são compostas por várias unidades de processamento, em geral conectadas por canais de comunicação (sinapses) que estão associadas a determinado

peso, sendo que o aprendizado da RNA ocorrerá através dos pesos sinápticos (Tafner *et al*, 1996).

Cada neurônio é constituído, basicamente, pelos elementos (FIGURA 2):

- *Sinapses* ou pesos sinápticos formam o conjunto de elos de conexão, caracterizada por um peso ou força própria. Especificamente, a função do peso é ponderar o sinal na entrada da sinapse conectada ao neurônio. As RNAs podem apresentar também pesos adicionais, denominados “bias”, que tem a função de evitar a geração de erros quando todos os dados de entrada são nulos: assim, a matriz de pesos não sofre modificações no treinamento.
- *Somatório* (?) agrega os dados das entradas ponderados pelos respectivos pesos.
- *Função de ativação* é uma função de ordem interna, sendo uma decisão tomada pelo próprio neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas.
- *Função de transferência* é uma função de saída ou limiar lógico. Ela controla a intensidade de ativação para se obter o desempenho desejado na rede.




FIGURA 2 - Estrutura de um neurônio artificial (disponível em: <http://www.lncc.br/~labinfo/tutorialRN> e acessado em 23 novembro 2006).

A operação de uma unidade de processamento segue as seguintes etapas:

- Os sinais são apresentados à entrada (X_1, X_2, \dots, X_m);
- Cada sinal é multiplicado por um peso ($W_{k1}, W_{k2}, \dots, W_{km}$);
- É realizado o somatório dos sinais, que produz um nível de atividade ($W_{k1}X_1, W_{k2}X_2 \dots W_{km}X_m$);
- Se o nível de atividade exceder o limiar definido, a unidade de processamento produz uma determinada resposta de saída (y) em função do nível de atividade ($f(\cdot)$), ao próximo neurônio.

Em uma RNA, cada unidade de processamento está associada a um estado de ativação que é determinado pela função de ativação, contínua ou discreta, que se quer representar com o modelo. A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados. Em geral, as funções mais utilizadas são a linear, a rampa, a degrau (*threshold*) e a sigmoideal, descritas a seguir conforme Silva *et al* 2004 (FIGURA 3):

- *Função linear* é a função que não limita a saída da RNA e é usada para armazenar entrada e saída de dados. Os neurônios que possuem esta função atuam como aproximadores lineares;
- *Função rampa* é a função de aproximação não-linear, entretanto, é simplificada;
- *Função degrau* é a função utilizada para neurônios que tomam decisões binárias, limitando a saída do neurônio somente a dois valores, sendo assim, classificadora;
- *Função sigmoideal logística* é uma função limitada que assume valores entre um limite superior e um inferior (0 e 1), sem jamais atingi-los.
- *Função sigmoideal tangente hiperbólica* é a função limitada, definida no intervalo de -1 e +1.

As funções tangente hiperbólica e sigmoideal são as mais utilizadas em RNAs, pois apresentam diversas características favoráveis, como o fato de serem funções semi-lineares, contínuas, simétricas, deriváveis em toda sua extensão, monotonicamente crescentes e limitadas por assíntonas horizontais.

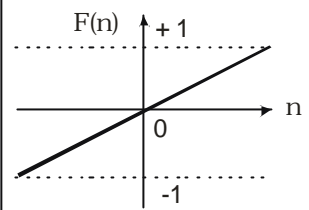
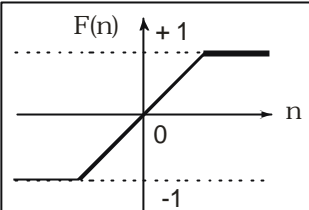
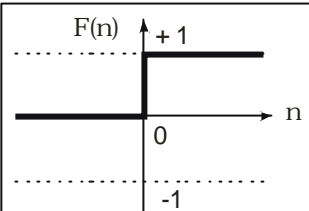
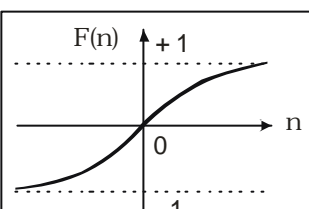
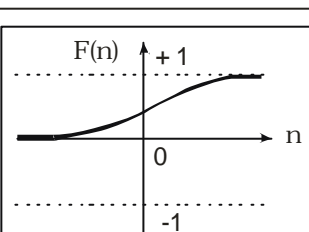
Função	Representação Gráfica
Linear	
Rampa	
Degrau	
Tangente Hiperbólica	
Sigmóide	

FIGURA 3 - Gráficos das funções de ativação das RNAs.

2.3.2 Arquitetura da RNA

A arquitetura refere-se à maneira como os neurônios da rede estão organizados. Existem várias estruturas que diferem umas das outras em função do número de camadas e pela forma como seus neurônios interagem.

A literatura traz sugestões oriundas de experiências realizadas que podem servir como orientação; mas a definição de parâmetros, como o algoritmo de treinamento, o tipo de conexão, o número de camadas e de neurônios por camada, não possui uma regra exata. Dessa forma, a estrutura da rede neural deve ser determinada pela análise do problema e pela experimentação.

Em geral, o número de camadas e o número de neurônios em cada camada são definidos inicialmente em função de uma análise dos dados e da complexidade do problema, não havendo números pré-estabelecidos. Já a topologia final é determinada por sucessivos refinamentos durante o processamento empírico do modelo. Entretanto, para esse caso, é imprescindível que os números determinados sejam ótimos, não havendo neurônios demais e nem de menos, pois o excesso ou a falta podem causar perda de sensibilidade ou memorização de dados (ponto em que a rede deixa de aprender), fatos que prejudicariam a generalização dos dados.

Segundo Silva *et al* (2004), entre os fatores que influenciam estes ajustes estão: número de exemplos de treinamento, quantidade de ruído, complexidade da função a ser aprendida e distribuição estatística dos dados. Sendo assim, o projeto de construção de uma RNA deve ser definido seguindo as questões norteadoras do estudo e a experimentação empírica de modo a se alcançar a estrutura ótima para a resolução do problema. Ainda assim, o projeto pode ser guiado por passos básicos, conforme apresentado no fluxograma da FIGURA 4.

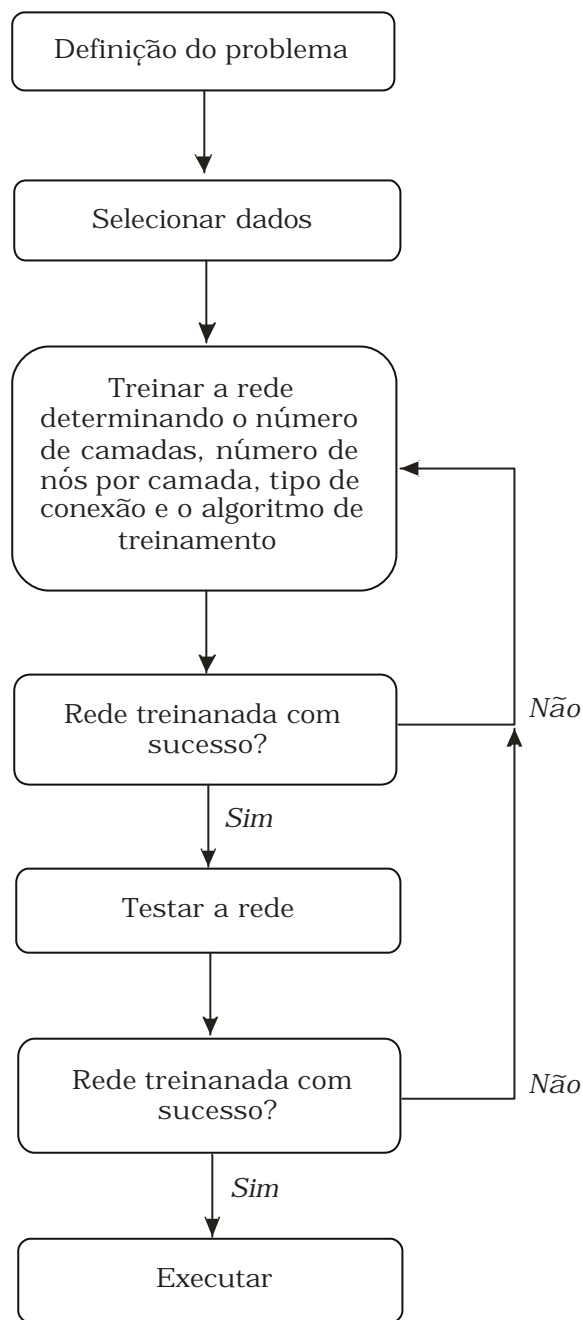


FIGURA 4 - Fluxograma de estruturação de uma RNA.

2.3.3 Conjunto de Treinamento

O conjunto de treinamento é de extrema importância, pois corresponde aos dados que serão apresentados como entrada e utilizados para o aprendizado da RNA. Essas informações são a fonte do conhecimento

da rede e todas as generalizações que ela for capaz de realizar dependem do seu aprendizado (Tafner *et al*, 1996).

Tendo em vista que a rede não é capaz de entender o mundo tal como ele é, o conjunto de treinamento deve passar por processo de tratamento antes de ser apresentado à mesma. O tratamento corresponde à adequação dos dados a uma linguagem compreensível à rede, melhorando a representação do problema, além da eliminação de dados redundantes, não relevantes ou duvidosos.

A seleção dos dados de entrada deve ser estudada cautelosamente, de modo que contenha dados com qualidade e em quantidade apropriada. Em relação à qualidade, cabe salientar que se deve dar preferência a dados reais e que possuam credibilidade; dados simulados só devem ser aplicados em situações especiais que os exijam. Além disso, a seleção das variáveis utilizadas exige atenção redobrada, pois em muitos casos a inclusão de uma variável pode não fazer diferença ou piorar o desempenho da rede. Já no que diz respeito à quantidade, deve se manter o conjunto de treinamento o mais completo e abrangente possível, visto que uma limitação apresentada pelas RNAs consta de que elas melhor generalizam resultados que estejam dentro da escala de treinamento. Assim, quanto mais dados reais tiverem sido apresentados durante a etapa de treinamento, tanto melhores serão as respostas fornecidas pela rede (Rohn e Mine, 2003; Adeloje e Munari, 2005).

2.3.4 Perceptron e Perceptron Multicamadas

O *Perceptron* é o modelo mais simples de RNA. Sua estrutura básica consiste em um nível de entrada e um nível de saída de unidades de processamento, com pesos e *bias* ajustáveis. Essas RNAs são usadas para a classificação de padrões ou para a representação de funções booleanas, com padrões de treinamento originados em duas classes linearmente separáveis. Assim, o algoritmo converge e posiciona a superfície de decisão na forma de um hiperplano entre as duas classes (Haikyn, 2001).

A Rede *Perceptron* limita-se a classificar padrões com apenas duas classes, havendo a possibilidade de aumentar esse número para três, se houver a inclusão de mais um neurônio. Entretanto, as variáveis devem ser separáveis linearmente. Por este motivo, seu sucesso foi interrompido frente às duras críticas de Minsky e Papert.

Com a retomada das pesquisas com as RNAs, a partir do trabalho de Hopfield, novas técnicas foram desenvolvidas, entre elas, as redes *Perceptron* Multicamadas (MLP). Atualmente as MLP são as mais utilizadas, devido a sua facilidade de implementação e simplicidade.

As redes MLP possuem um poder de processamento muito superior ao *Perceptron* original, devido ao fato de sua estrutura apresentar camadas intermediárias de neurônios, passando a conter pelo menos três camadas de unidades de processamento, conforme a FIGURA 5.




FIGURA 5 - Arquitetura de uma rede Perceptron Multicamadas (MLP).

A estrutura de uma rede MLP pode ser assim explicada:

- Camada de entrada: onde os sinais são introduzidos à rede, com a função de armazenar a informação e transmiti-la às camadas seguintes;
- Camadas intermediárias escondidas ou ocultas localizam-se entre a entrada e a saída, não tendo contado com o mundo externo. É nestas camadas que ocorre a maior parte do processamento, através de conexões ponderadas, que funcionam como extratoras de características apresentadas nos padrões de entrada e permitem que a

Rede crie sua própria representação, mais rica e complexa do problema;

- Camadas de saída: onde o resultado é finalizado e apresentado.

2.3.5 Conexão Entre as Unidades de Processamento

Existem várias formas de interação entre os neurônios constituintes de uma RNA. As mais comuns, porém, são a unidirecional e a recorrente. As redes unidirecionais ou *feedforward* são aquelas em que o sinal se propaga somente em uma direção, não havendo realimentação de sinais propagados de uma camada posterior para a anterior ou para neurônios adjacentes à sua própria camada. Enquanto isso, que nas redes recorrentes ou *feedback* ocorre a realimentação de sinais já propagados na rede.

2.3.6 Processos de Aprendizado

A propriedade que é de primordial importância para uma RNA é a sua habilidade de aprender a partir de seu ambiente e de melhorar seu desempenho através da aprendizagem (Haykin, 2001). Para isso, foram desenvolvidos diversos algoritmos de aprendizagem, ou seja, conjuntos de regras definidas para que uma RNA aprenda uma determinada função, por meio de processos interativos que se ajustam aos parâmetros propostos (Silva *et al*, 2004).

As metodologias de treinamento de RNAs que foram criadas podem ser agrupadas em dois paradigmas principais, conforme Silva *et al* (2004) e Tafner *et al* (1996):

Aprendizagem supervisionada: O treinamento da RNA acontece com auxílio de um “professor”. Para isso, a RNA deve ter um conjunto de entradas e um conjunto de saídas desejadas. Toda vez que for apresentada à

RNA uma entrada, deverá ser verificado se a saída obtida confere com a saída desejada. Sendo diferente, a RNA deverá ajustar os pesos de forma que armazene o conhecimento desejado. Esta interatividade deverá ser repetida com todo o conjunto de treinamento, até que a taxa de acertos seja satisfatória.

Aprendizagem não-supervisionada: Este treinamento não requer saídas desejadas. Para o treinamento, a rede usa somente valores de entradas. A rede trabalha essas entradas e se organiza de modo que acabem classificando-as, usando, para isso, seus próprios critérios. A auto-organização demonstrada em RNAs de aprendizados não-supervisionados envolve a competição e a cooperação entre as unidades de processamento.

2.3.7 Algoritmo de Treinamento *Backpropagation*

O algoritmo *backpropagation* (ou retropropagação) é o principal algoritmo de treinamento de rede e é, freqüentemente, utilizado como algoritmo de treinamento em redes MLP devido a sua eficiência.

O princípio deste algoritmo baseia-se no aprendizado por correção de erro. Quando um padrão é apresentado à rede pela primeira vez, esta produz uma saída aleatória. A diferença entre esta saída e a desejada constitui o erro, que é calculado pelo próprio algoritmo (FIGURA 6). O algoritmo *backpropagation* faz com que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das restantes camadas, corrigindo-os de trás para frente, com o objetivo de reduzir o erro (Silva *et al*, 2004) (FIGURA 7). Este processo é repetido durante o aprendizado até que o erro se torne aceitável.

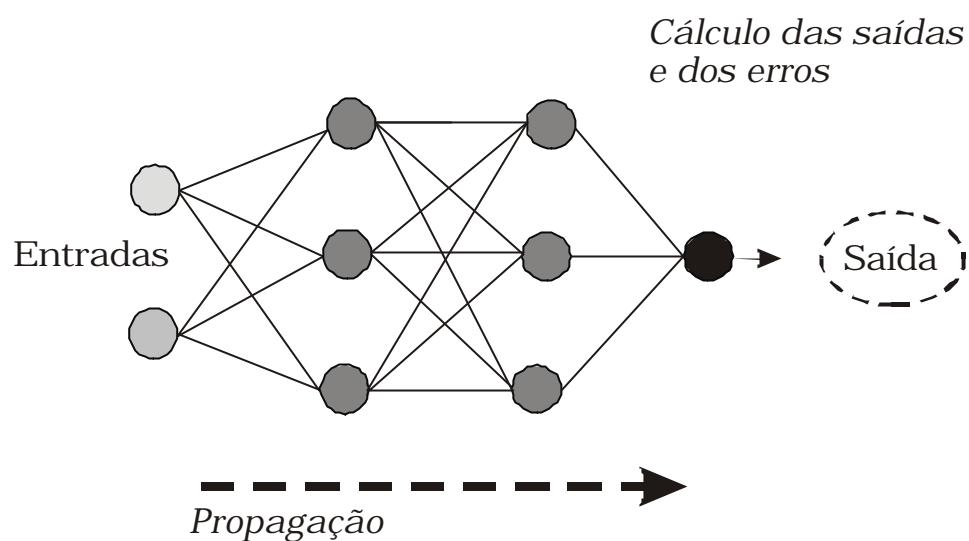


FIGURA 6 - Etapa de propagação do algoritmo backpropagation.

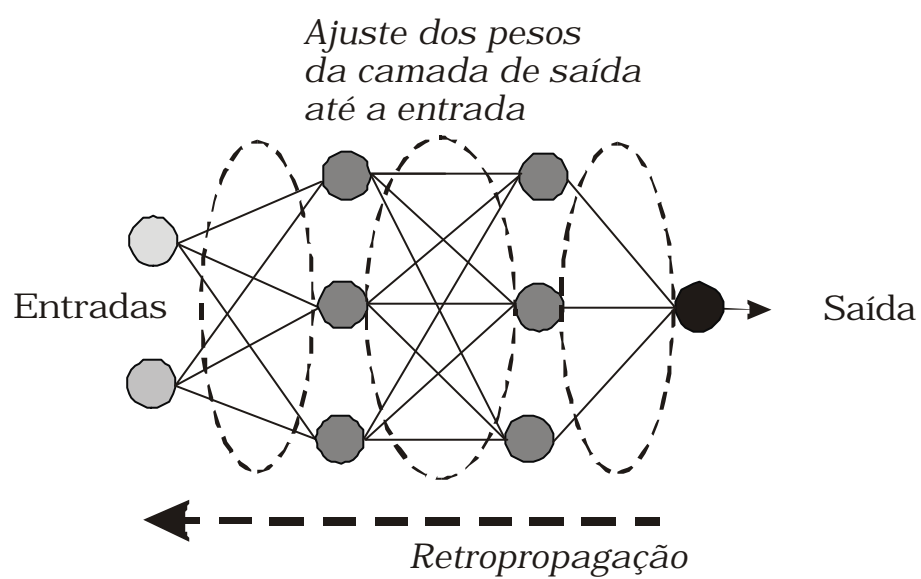


FIGURA 7 - Etapa de retropropagação do algoritmo *backpropagation*.

3 REVISÃO BIBLIOGRÁFICA

3.1 MAPEAMENTO HIDROGEOLÓGICO DO RIO GRANDE DO SUL

O aumento do uso das águas subterrâneas para abastecimento público exige o conhecimento aprofundado da hidrogeologia da região a fim de avaliar as potencialidades e as condições dos aquíferos. Desse modo, o Serviço Geológico do Brasil e o Governo do Estado do Rio Grande do Sul, por meio da Diretoria de Recursos Hídricos da Secretaria Estadual de Meio Ambiente (SEMA), elaboraram o Mapa Hidrogeológico do Rio Grande do Sul, para que o mesmo componha uma base de dados com as informações necessárias ao planejamento do uso e exploração das águas subterrâneas de maneira sustentável. As informações contidas nos mesmos apresentam-se descritas abaixo, conforme Machado e Freitas (2005).

O Mapa Hidrogeológico inclui o cadastramento dos pontos de captação de água subterrânea (poços tubulares) e o estudo dos sistemas aquíferos contemplando aspectos estruturais, climatológicos e físico-químicos.

O processo de cadastramento iniciou com o levantamento de informações junto a cadastros de instituições públicas e privadas, mas esta etapa do projeto esbarrou no desconhecimento e na desorganização das prefeituras, da mesma maneira que na falta de cooperação das instituições privadas para o fornecimento de dados. Posteriormente, houve a verificação das informações através do trabalho de campo. Devido a limitações financeiras as áreas escolhidas para o trabalho de varredura concentraram-se nas regiões aflorantes do Sistema Aquífero Guarani (SAG) ou aquelas que estão mais próximas da superfície do terreno e a região litorânea.

O inventário atingiu 7.692 poços tubulares com diâmetro superior a 4 polegadas que, em sua maioria, se apresentaram distribuídos em aquíferos porosos triássicos e eo-cretáceos. Localizados na fronteira oeste do Estado, captam água do aquífero Serra Geral ou de aquíferos porosos eo-cretáceos confinados.

O cadastramento de poços serviu de base para a construção do SIAGAS e para a elaboração do Mapa Hidrogeológico do Estado. Em especial, o SIAGAS proporciona uma excelente base de dados para o estabelecimento de uma rede de monitoramento quali-quantitativo das águas subterrâneas em sistemas aquíferos importantes.

O cadastro e a interpretação dos dados de poços, análise da geologia, dos dados climatológicos e físico-químicos culminaram na classificação das principais unidades hidroestratigráficas e sistemas aquíferos no Mapa Hidrogeológico. Gerado em uma escala de 1:750.000, permite a análise regional, mas que ressalta somente as unidades hidroestratigráficas e sistemas aquíferos mais importantes; entre eles, o SAG.

O Mapa Hidrogeológico do Rio Grande do Sul teve seus dados divulgados por meio impresso e digital; o cadastro dos poços está disponível para consultas no site da CPRM, cujo endereço eletrônico consta de <http://siagas.cprm.gov.br>. Essas ferramentas podem constituir bases para diversos estudos, assim como para subsidiar o desenvolvimento de políticas públicas de controle e otimização do uso dos recursos hídricos subterrâneos.

3.2 MODELOS HIDROLÓGICOS

Segundo Tucci (1998), a representação de processos hidrológicos de forma clara e sucinta é de extrema necessidade para o gerenciamento dos recursos hídricos. Para tanto, é necessário cruzar informações de diferentes áreas e selecionar metodologias adequadas à quantificação destes processos para que sejam tomadas as decisões que melhor atendam aos interesses da sociedade. Atendendo a essa necessidade, a hidrologia deixou de ser uma ciência descritiva e qualitativa, passando a explorar de forma mais eficiente, por meio da matemática e da estatística, os métodos quantitativos, havendo melhoras tanto nos resultados como na exploração das informações existentes. Com isso, surgiram os modelos matemáticos que passaram a ser imprescindíveis nas simulações de situações reais da hidrologia.

Os modelos são representações simplificadas de situações reais, através de equações matemáticas. Como qualquer metodologia apresenta limitações, as informações resultantes serão tanto mais precisas quanto mais detalhados forem os dados que alimentam o modelo matemático.

Com o avanço tecnológico surgiram os modelos computacionais que hoje permitem análises mais complexas em estudos de caso - como os de aquíferos. Tais modelos sistematizam as informações de campo, facilitam a compreensão dos recursos hídricos subterrâneos e auxiliam na avaliação, projeto e planejamento do uso da água subterrânea.

De acordo com Cabral e Demétrio (1997), para a elaboração de um modelo computacional é importante sempre ter em mente os objetivos almejados. Se o objetivo é prever a resposta do aquífero a determinadas ações, utiliza-se um modelo de previsão. Já se o desejado é entender o funcionamento do aquífero e sistematizar as informações, utiliza-se um modelo de interpretação. Sendo assim, a modelagem hidrogeológica envolve diversas etapas em que a simulação computacional é apenas um dos passos existentes entre a definição dos objetivos até a apresentação dos resultados. Para melhorar estes resultados, a elaboração de um modelo deve seguir algumas etapas, como apresentadas no fluxograma da FIGURA 8.

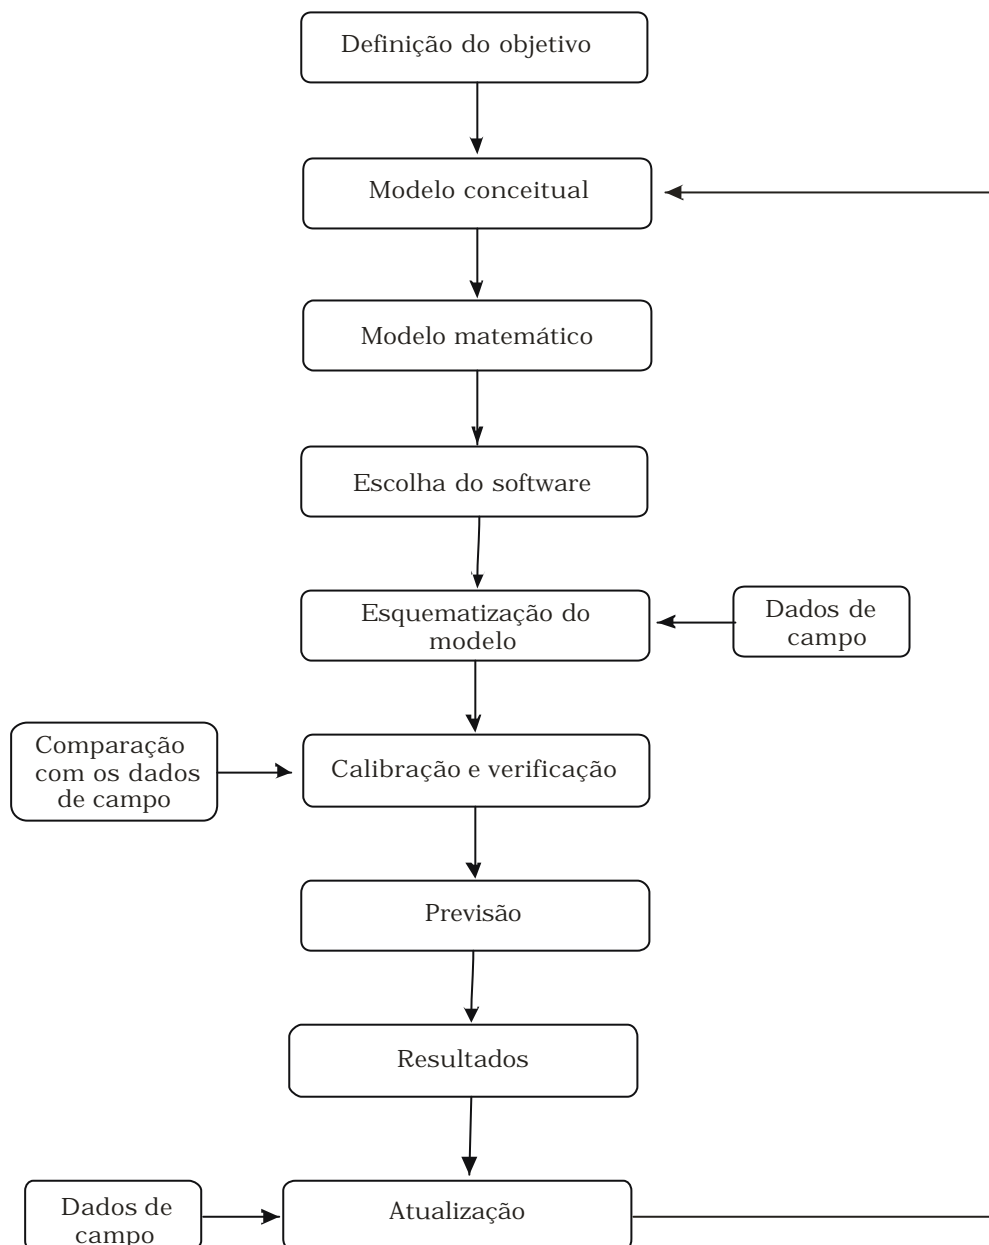


FIGURA 8 - Fluxograma para elaboração de um modelo hidrológico (adaptado de Cabral e Demétrio ([1997])).

A elaboração de um modelo inicia-se pela definição dos objetivos que servem de guia para a elaboração do modelo conceitual, no qual se identificam as características que influenciam o sistema. Parte-se, então, para a formulação matemática do problema e a escolha do *software* a ser utilizado na modelagem. Posteriormente, faz-se a esquematização do modelo que inclui a seleção dos parâmetros a serem utilizados. A calibração e a verificação referem-se ao ajuste dos parâmetros para reproduzir as situações

reais. Para estas duas etapas a amostra de dados pode ser dividida, para que uma parte seja usada na calibração e outra na verificação. Por fim, a previsão fornece os resultados necessários para entender o funcionamento do sistema em análise. A obtenção de resultados não finaliza a elaboração do modelo, pois o mesmo deve ser constantemente atualizado por meio do monitoramento e aperfeiçoamento a partir de novos dados de campo e simulações ao longo do tempo.

Em qualquer estudo de caso existem elementos que precisam ser entendidos, tanto na elaboração quanto na utilização de um modelo matemático. Por exemplo, as características do sistema em análise, a disponibilidade e a qualidade dos dados e a familiaridade do usuário com o modelo. Dessa forma as fases da aplicação podem ser seguidas como sugere Tucci (1998) na FIGURA 9.

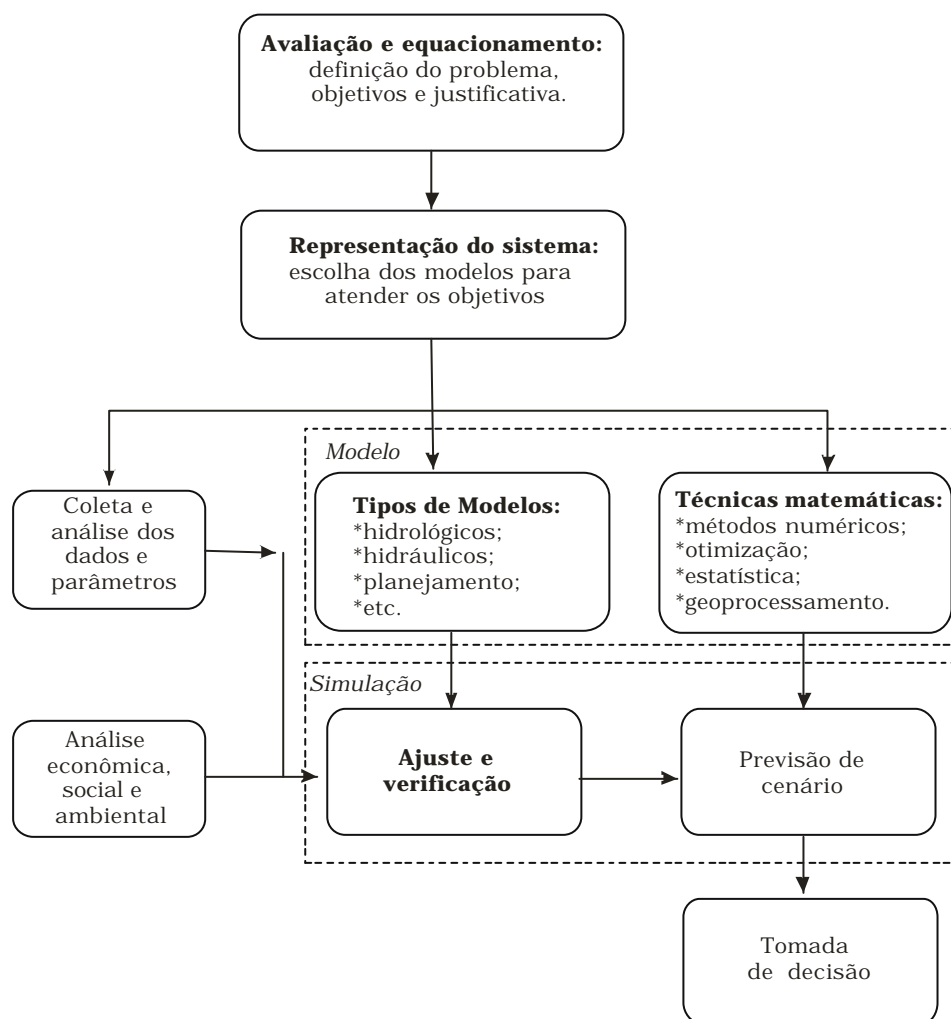


FIGURA 9 – Fluxograma para aplicação de um modelo hidrológico, conforme Tucci (1998).

3.3 APLICAÇÕES DE REDES NEURAIS ARTIFICIAIS

De seus dias iniciais até a atualidade, as RNAs trilharam um longo caminho, se estabelecendo e aprimorando através de raízes profundas em neurociências, psicologia, matemática, ciências físicas e engenharia. Por estar fundamentada na interdisciplinaridade, suas aplicações estão direcionadas às mais diversas áreas do conhecimento.

Na área das Geociências, as RNAs têm sido aplicadas em processamento de imagens de satélite e geração de Sistemas de Informação Geográfica (Galo, 2000; Wandresen *et al*, 2003; Andrade & Centeno, 2003; Nóbrega & Souza, 2003; Espinhosa, 2004), na estimativa de observáveis GPS (Silva, 2003), na análise de erros na propagação de sinais GPS (Hernández-Pajares *et al*, 1997; Leandro, 2004), na modelagem numérica de terrenos (Baca, 2001), na classificação e uso do solo (Ribeiro & Centeno, 2001), análise de parâmetros químicos de solo (Sena *et al*, 2000), na estimativa de temperatura de superfície do solo (Veronez, 2006a), na modelagem geoidal (Maia, 2003; Veronez, 2006b), no controle de teores de minérios em lavras (Cintra, 2003), como auxiliar na identificação e localização espacial de corpos geológicos com hidrocarbonetos minerais (Fleck *et al*, 2003), na classificação de tipologias minerais (Valim, 1998) e em mapeamentos geofísicos (Ferreira & Porsani, 1997; Correia, 2005).

Especificamente no contexto da hidrologia e hidrogeologia, há muitos trabalhos desenvolvidos, principalmente na modelagem e determinação de parâmetros de sistemas superficiais, conforme alguns exemplos apresentados a seguir.

Müller e Fill (2003) verificaram o comportamento de um modelo de RNA na propagação de vazões de rios. O caso de estudo foi um trecho do rio Iguaçu. A rede criada foi uma rede *Perceptron* Multicamadas, com topologia [2-8-8-8-1], onde, na primeira camada, tinha-se como entrada a vazão no início do trecho e o incremento de vazão, na camada de saída apresentava-se a vazão no final do trecho. Os autores concluíram que o método era

promissor, pois mesmo tratando-se de uma técnica puramente matemática, não levou-se em consideração a teoria intrínseca ao problema.

Sahoo e Ray (2006) testaram o uso da rede multicamadas do tipo *feedforward* com o algoritmo *backpropagation*, além da rede com função de base radial, para verificar a exatidão das mesmas em prever o fluxo de alguns córregos no Havaí quando comparadas ao método convencional (curvas de avaliação). Além disso, procuraram examinar a importância de variáveis descritivas de fluxo e mensurar a capacidade das RNAs em traçar curvas de avaliação. A RNA que utilizou a função de base radial exigiu menor tempo de experimentação na determinação de sua melhor arquitetura em relação à rede *feedforward* com algoritmo *backpropagation*; mas a segunda, apesar de exigir mais testes, teve melhores resultados em relação à primeira. Ao comparar a rede *feedforward* com o método tradicional, o desempenho foi eficiente, mesmo com um número inferior de parâmetros descritivos.

Rohn e Mine (2003) aplicaram as técnicas de RNAs na previsão de precipitação de curtíssimo prazo. A proposta era de um modelo de rede com seis neurônios de entrada, referentes às seis estações pluviométricas adjacentes à área de interesse. As informações provenientes das estações adjacentes alimentavam a rede por meio de dados de precipitação com uma defasagem de tempo de 15 minutos. A rede era informada sobre as condições presentes de chuva existentes nas seis estações adjacentes para, então, ter condições de prever a precipitação depois de 15 minutos na estação de interesse. O trabalho não obteve resultados satisfatórios, pois as previsões giraram em torno de um valor médio sendo incapaz de simular os picos dos eventos. As autoras justificaram a deficiência do modelo à variabilidade das precipitações, que impediu que a rede reconhecesse as características relevantes nos eventos observados, e afirmaram que os dados não possuíam um padrão bem identificado para que a RNA estabelecesse relações e aprendesse adequadamente.

Chen e Adams (2006) baseados nas vantagens de um modelo conceitual em representar as características de um sistema hidrológico e na capacidade das RNAs em reconhecer e traçar padrões não-lineares, propuseram a integração das duas metodologias com o objetivo de gerar um

modelo de chuva-vazão. As RNAs foram combinadas a três diferentes modelos conceituais (modelo de Xinanjiang/China, Modelo de determinação de umidade do solo e roteamento/Irlanda e modelo de Tank/Japão). Os modelos integrados apresentaram grande potencial, realizando aproximações que não seriam alcançadas pelas metodologias isoladas.

Adeloye e Munari (2005), utilizando dados mensais de chuva de 18 reservatórios internacionais distribuídos em 4 continentes, procuraram desenvolver uma rede baseada na generalização do modelo *Store-Yield-Reliability* para reservatórios, determinando simultaneamente as capacidades de dentro do ano e sobre o ano. Primeiramente foram detectadas as relações *Store-Yield-Reliability*, a fim de modificar o algoritmo seqüencial *Peak* para normalizar os dados de saída para o treinamento e testes da RNA. Em seguida, vários modelos de redes foram projetados e comparados para achar a melhor solução para o problema. E, por fim, o melhor modelo foi comparado com o recentemente desenvolvido da regressão de Adeloye *et al* (2003). Após o término dos testes e comparações, as RNAs obtiveram resultados satisfatórios em suas previsões durante as fases de treinamento e validação. Além disso, baseados em diversas considerações, alguns modelos foram testados e conseguiram identificar a relação entre características de rios e a capacidade de armazenamento. Entretanto, salientam a importância de um amplo conjunto de treinamento, pois os resultados da rede tendem a decair ao se extrapolar a escala de dados do treinamento.

Galvão e Meneses (2005) aplicaram uma RNA com função de base radial, *feedforward* e constituída de três camadas, para selecionar em um Sistema de Informação Geográfica (SIG) as áreas potenciais à alocação de estações fluviométricas na bacia hidrográfica do rio São Francisco. Essa classificação se deu a partir de variáveis geoambientais (como hidrografia, sedes municipais, rodovias, geologia, solos, etc.). A rede em questão mostrou-se uma eficaz ferramenta na realização da complexa classificação de padrões dispostos não linearmente em um espaço de grande dimensão.

Jia e Culver (2006), baseados em outros trabalhos, investigaram o uso de uma RNA para gerar uma série sintética de fluxo de rios. Os resultados

do estudo mostraram que as RNAs têm grande potencial para expandir jogos de dados limitados. Além disso, os autores sugerem que para essa metodologia se tornar mais eficaz, seu uso seja combinado a outros modelos.

Os estudos para modelamento de sistemas de água subterrânea são menos comuns em relação aos de águas superficiais, mesmo assim, há estudos relevantes:

Balkair (2002) desenvolveu uma RNA do tipo *Perceptron* Multicamadas, com três camadas, sendo que na entrada o número de neurônios foi igual ao número de pontos existentes de dados para o tempo, rebaixamento e diâmetro dos poços, enquanto que na camada de saída os dois neurônios apresentaram a transmissividade e o escoamento. A RNA teve bons resultados, sendo considerada uma ferramenta útil no campo da hidráulica. Além disso, os autores ressaltaram que o conhecimento prévio de parâmetros do aquífero e a sistemática de treinamento em macro e microescala foram úteis no desenvolvimento da pesquisa.

Daliakopoulos *et al* (2005) testaram diferentes RNAs e algoritmos de treinamento com a finalidade de avaliar qual combinação entre ambos apresentaria melhor aproximação na previsão futura do nível de água subterrânea. Os dados utilizados para a entrada foram precipitação, temperatura, fluxo de um córrego da região e o nível da água subterrânea. Já a saída consistiu em previsão do nível da água na etapa $t+1$. Dentre as técnicas testadas, a mais promissora foi a RNA do tipo *feedforward* com o algoritmo *Levenverg-Marquardt* e topologia 20-3-1. Porém salientam que com o aumento do tempo de predição há um decréscimo na exatidão da previsão.

Lin e Chen (2005) realizam um comparativo entre uma RNA baseada no algoritmo de treinamento *backpropagation* e outra rede baseada em uma função de base radial para determinar parâmetros do aquífero (transmissividade e coeficiente de armazenamento). Após a realização de testes, os autores concluíram que as redes de função de base radial têm muitas vantagens, entre elas o menor tempo de treinamento, a exclusão do problema de seleção de uma escala apropriada para o treinamento e a aproximação com maior precisão para os valores dos parâmetros do aquífero.

Lin e Chen (2006) propuseram uma nova aproximação alternativa à determinação de parâmetros do aquífero (transmissividade e coeficiente de armazenamento) por RNAs. A nova proposta possui algumas vantagens como, por exemplo, evita problemas de escala para o treinamento, determina valores de parâmetros com maior exatidão, possui estrutura mais simples e necessita menor tempo de treinamento em relação a rede tradicional.

Seguindo a recomendação dos autores do artigo acima citado, Samani *et al* (2007) substituíram o algoritmo de treinamento gradiente descendente pelo algoritmo de *Levenberg-Maquart* aplicado a análise do componente principal. A análise do componente principal detecta a estrutura nos relacionamentos entre variáveis de entrada na série de dados de treinamento, explicando a correlação entre testes padrões de treinamento nos termos de um número menor de fatores subjacentes, eliminando dados redundantes. Em consequência, essa nova combinação melhora não somente o desempenho da previsão, como também aumenta a velocidade de treinamento e reduz o número de neurônios, simplificando a topologia da rede.

Nayak *et al* (2006) usaram RNAs para prever os níveis de água subterrânea em um aquífero raso do sistema central do Delta de Godavari, na Índia, a partir de dados pluviométricos, nível de canais e o nível de água em poços. As previsões mensais obtidas apresentaram bons resultados tanto na calibração como na validação.

Rao e Jamieson (1997) demonstraram a aplicabilidade de uma RNA e um algoritmo genético para aperfeiçoar o projeto de um sistema de remediação do tipo “*pump-and-treat*” para água subterrânea. Uma vez que os locais para poços da remediação foram identificados, uma RNA associou o fluxo de água subterrânea e o transporte do contaminador, simulando no modelo o conhecimento para predizer a eficácia de diferentes combinações de locais de extração/injeção. Depois disso, usou-se um algoritmo genético para identificar o regime de bombeamento ótimo, buscando determinar a solução com melhor custo-benefício para conseguir o nível residual de poluente dentro de qualquer escala de tempo especificada.

Lallahem *et al* (2005) geraram uma RNA treinada com algoritmo *backpropagation* para simular o nível da água em um aquífero calcário fraturado. O modelo desenvolvido simulou saídas com elevado grau de exatidão, em que as estruturas mais simples produziram os melhores resultados. Além disso, o processo de modelamento iterativo revelou que existe um limite ótimo de informações e parâmetros específicos que devem ser utilizados para geração do modelo; entretanto, realizar essa seleção é também a maior dificuldade.

Garcia e Shigidi (2006) treinaram com sucesso uma rede capaz de aproximar a relação entre a transmissividade e os principais dados hidráulicos sob condições de estado estacionário para um estudo de caso bidimensional. O estudo demonstrou que a metodologia é capaz de identificar um jogo de soluções inversas, que há uma estabilidade em relação a erros aleatórios na medição dos valores hidráulicos e que a rede treinada também possui a habilidade de filtrar pequenos ruídos aleatórios.

4 ÁREA DE ESTUDO E BANCO DE DADOS

4.1 ÁREA DE ESTUDO

4.1.1 Bacia Hidrográfica do Rio Caí

A área de estudo selecionada foi a Bacia Hidrográfica do Rio Caí (FIGURA 10) pelo fato de possuir um conjunto satisfatório de informações íntegras referentes à sua rede de poços no SIAGAS e também, por ter sua geologia conhecida.

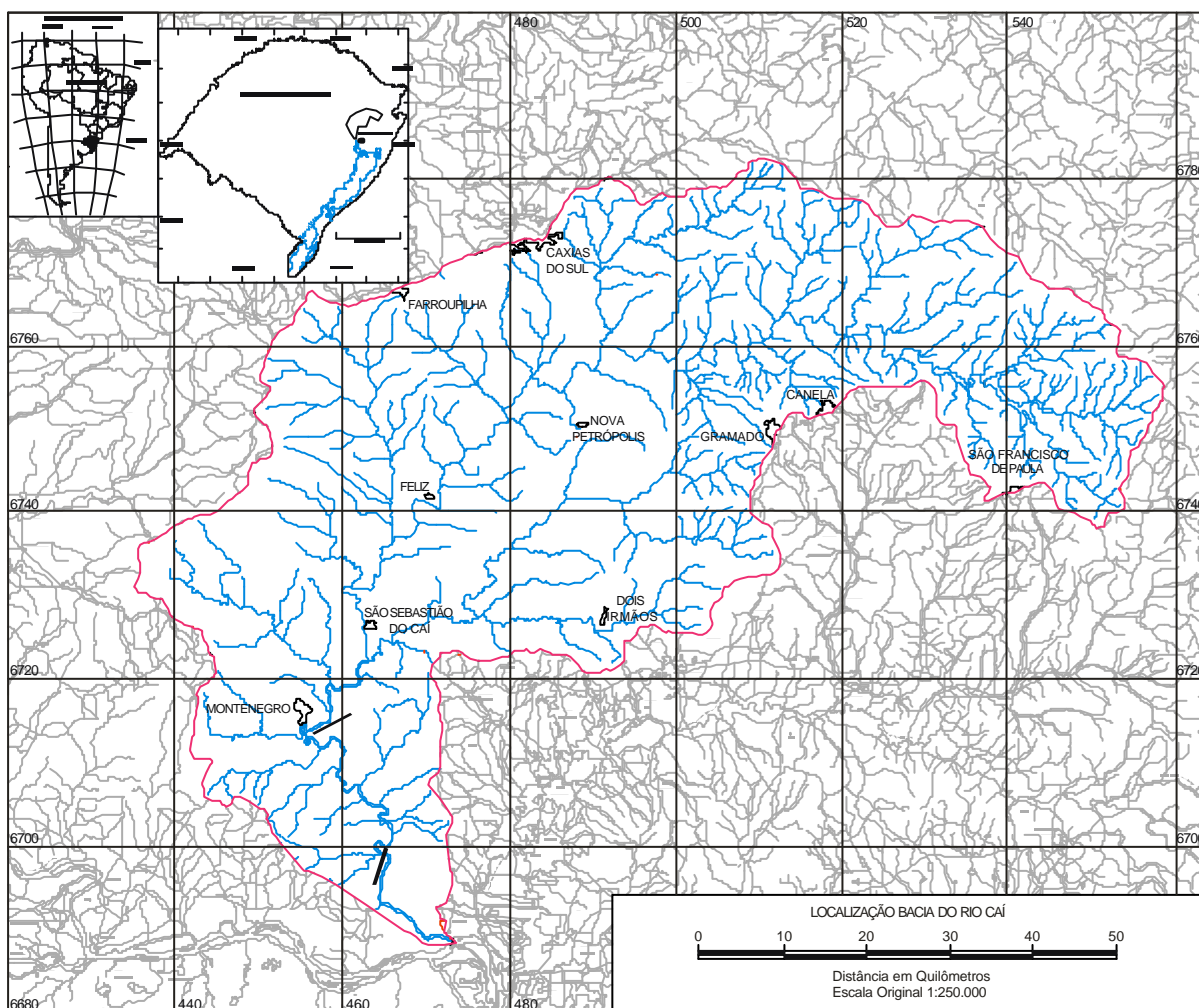


FIGURA 10 - Bacia Hidrográfica do Rio Caí. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

A RNA foi estruturada e treinada com base no banco de dados SIAGAS para a Bacia Hidrográfica do Rio Caí, localizada na região leste do Estado do Rio Grande do Sul. Integrando a Região Hidrográfica do Guaíba, tem seus limites distribuídos em 41 municípios relacionados no QUADRO 1, totalizando uma área de 4.957,74 km². A vazão média anual é de 29,52 m³/s e a população corresponde a cerca de 498.259 habitantes, de acordo com SEMA (2007).

QUADRO 1 – Municípios integrantes da Bacia Hidrográfica do Rio Caí.

Municípios	
Alto Feliz	Nova Hartz
Barão	Nova Petrópolis
Bom Princípio	Nova Santa Rita
Brochier	Pareci Novo
Canela	Picada Café
Capela de Santana	Portão
Carlos Barbosa	Presidente Lucena
Caxias do Sul	Salvador do Sul
Dois Irmãos	Santa Maria do Herval
Estância Velha	São Francisco de Paula
Farroupilha	São José do Hortêncio
Feliz	São José do Sul
Gramado	São Pedro da Serra
Harmonia	São Sebastião do Caí
Igrejinha	São Vendelino
Ivoti	Sapiranga
Lindolfo Collor	Três Coroas
Linha Nova	Triunfo
Maratá	Tupandi
Montenegro	Vale Real
Morro Reuter	

A Bacia está localizada na transição entre as regiões fisiogeográficas da Depressão Central e Serra Geral com altitude variada, podendo ultrapassar 800 m em suas nascentes. O clima é subtropical com delimitação entre as quatro estações do ano e a precipitação anual média é variável, podendo atingir 1400 mm nas nascentes e 900 mm a jusante de São Sebastião do Caí até a foz (FEPAM, 2007).

O contexto geológico do município está inserido na Bacia do Paraná constituído de rochas areníticas das Formações Pirambóia e Botucatu e rochas basálticas da Formação Serra Geral.

A Formação Pirambóia é um sistema deposicional resultante da associação de extensivos depósitos de dunas eólicas (fácies de arenitos com estratificações cruzadas acanaladas ou tangenciais e mais raramente planares) e interdunas (fácies de arenitos tabulares e fácies de pelitos lenticulares maciços ou laminados) com evidências de exposição do nível freático, representados por arenitos bioturbados, laminações contorcidas por fluidização e pela presença de fácies pelíticas, eventualmente recortadas por canais “*wadis*” que caracterizam esse intervalo como um sistema eólico úmido (Faccini *et al*, 2003).

Já a Formação Botucatu é uma associação de fácies de um sistema deposicional eólico seco, constituída basicamente de arenitos bimodais, quartzosos, de granulação de fina a grossa na região de dunas e fina a média nas regiões de interdunas. Além disso, ocorrem as características estratificações cruzadas de grande porte (Faccini *et al*, 2003).

E, por fim, a Formação Serra Geral é composta por derrames basálticos continentais que se constituem por seqüências toleíticas bimodais, onde predominam basaltos a basaltos andesitos, superpostos por riolitos e riodacitos (Bizzi *et al*, 2003).

A Bacia do Caí apresenta como curso de água principal o Rio Caí e seus afluentes de maior porte são os arroios Piaí, Forromeco, Pinhal, Cadeia e Maratá. As disponibilidades de águas subterrâneas provêm dos sistemas aquíferos relacionados na TABELA 1, juntamente com o percentual de ocorrência (SEMA, 2007). A capacidade específica média da Bacia é considerada em geral muito baixa, mesmo para o Sistema Aquífero Botucatu confinado (SEMA, 2007).

TABELA 1 - Sistemas Aquíferos da Bacia Hidrográfica do Rio Caí (SEMA, 2007).

Sistemas Aquíferos	% de ocorrência na Bacia
Botucatu/Pirambóia	17.74
Aquitardos Permeanos	3.92
Botucatu	0.90
Quaternário Costeiro	0.36
Serra Geral II	77.09

O uso da água subterrânea se dá por meio de uma rede de poços, pertencentes à Companhia Riograndense de Saneamento (CORSAN), às Prefeituras Municipais e particulares, dentre os quais foram retirados os poços para o presente trabalho (FIGURA 11).

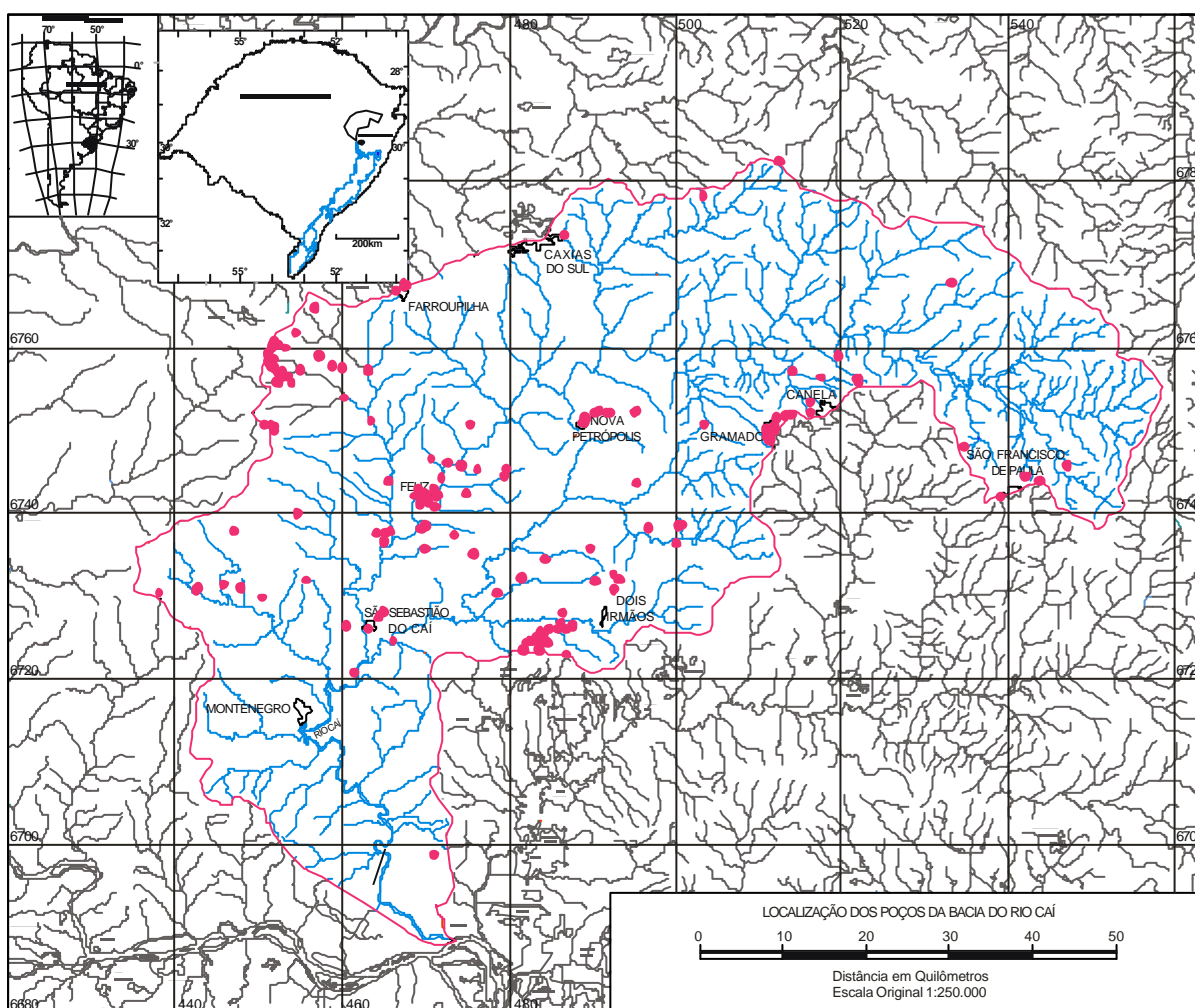


FIGURA 11 - Distribuição dos poços amostrados da Bacia do Rio Caí. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

4.2 BANCO DE DADOS - SIAGAS

O Sistema de Informação de Águas Subterrâneas (SIAGAS) é um cadastro de poços gerado através do trabalho do Serviço Geológico do Brasil (CPRM) e reúne informações de cerca de 100.000 pontos de captação de água em todo o território nacional, dos quais 7.692 estão localizados no Rio Grande do Sul.

O banco de dados SIAGAS foi criado como instrumento de gestão a partir da Política Nacional de Recursos Hídricos, instituída através da Lei nº 9.433 de 08 de janeiro de 1997. O objetivo deste é compilar, padronizar e divulgar dados sobre poços para que os mesmos possam ser aplicados como ferramenta em estudos hidrogeológicos que visam o conhecimento, exploração ou proteção dos recursos hídricos subterrâneos (Peixinho e Oliveira, 2007)

Os dados disponíveis para cada poço cadastrado no banco de dados SIAGAS são:

- Dados gerais (identificação, localização, propriedade, hidrografia, etc.);
- Dados construtivos (profundidade, diâmetro, perfuração, etc.);
- Dados geológicos (litologia e estratigrafia);
- Dados hidrológicos (aqüíferos e perfilagem do poço);
- Dados do teste de bombeamento (nível estático, nível dinâmico, vazão, vazão específica, etc.);
- Dados químicos (condutividade elétrica, qualidade da água, temperatura, etc.).

De modo a facilitar o acesso à informação e agilizar os processos de planejamento e decisão, o SIAGAS é um banco de dados de domínio público, que está disponível no site da CPRM.

5 MATERIAIS E MÉTODO

5.1 DESCRIÇÃO DO MÉTODO

Nesse trabalho, as RNAs do tipo *Perceptron* Multicamadas foram utilizadas para gerar um modelo capaz de determinar alguns parâmetros hidrogeológicos (a espessura da camada da Formação Serra Geral, a profundidade do nível estático e a capacidade específica) para que os mesmos fossem utilizados como base para a criação de cartas de isolinhas. Para tanto, o método foi dividido em etapas de acordo com o fluxograma da FIGURA 12, estando o detalhamento das etapas descrito ao que se segue.

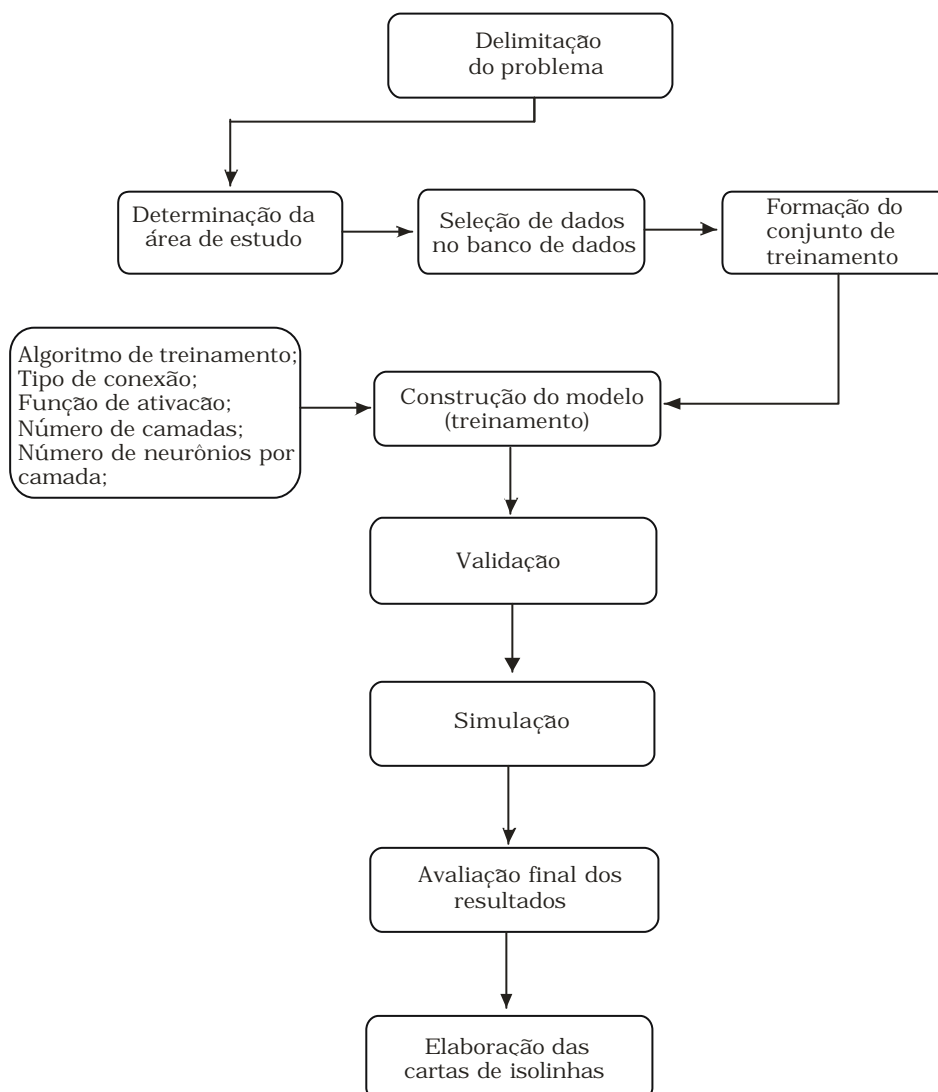


FIGURA 12 - Fluxograma da metodologia adotada.

Delimitação do problema: A pesquisa em questão teve sua estrutura determinada no sentido de buscar a forma mais eficiente de responder às seguintes questões norteadoras:

- É possível extrapolar informações hidrogeológicas, como nível estático, capacidade específica e a espessura da Formação Serra Geral da Bacia Hidrográfica do Rio Caí a partir de informações disponibilizados no banco de dados SIAGAS sem a utilização da modelagem convencional?
- As RNAs são ferramentas adequadas para o desenvolvimento desses modelos alternativos? Caso sejam, qual modelo neural é o mais adequado? Que topologia, que funções e parâmetros de treinamento são mais indicados?
- Quais os parâmetros existentes no banco de dados SIAGAS relevantes e adequados para o desenvolvimento do modelo alternativo?

Seleção da área de estudo e dados: As informações necessárias ao treinamento da RNA foram baseadas no SIAGAS da Bacia Hidrográfica do Rio Caí. A escolha desta Bacia para a modelagem já foi abordada anteriormente.

Formação do conjunto de treinamento: De acordo com Cabral e Demétrio (1997), as informações a serem utilizadas na alimentação do modelo podem ser do tipo físico, correspondendo à geometria do aquífero que incluem dados como extensão, espessura, contornos estruturais, perfis geológicos e geofísicos. E também do tipo hidrogeológico, que se referem a informações sobre porosidade, condutividade hidráulica, cargas hidráulicas, fluxos e coeficiente de armazenamento. Baseando-se nisso, os dados existentes no SIAGAS foram avaliados e pré-selecionados conforme sua disponibilidade. Posteriormente, foram selecionados de modo empírico os parâmetros que se melhor enquadravam em cada RNA.

Os dados retirados do banco de dados para compor o conjunto de treinamento utilizado no processo de construção da RNA passaram por uma análise preliminar para a exclusão de informações duvidosas ou

incompletas. Posteriormente, tais dados foram adequados, para que se tornassem compreensíveis à rede. Isso incluiu a normalização dos dados em um intervalo entre 0 e 1. Este procedimento é necessário em casos de variáveis com unidades diferentes ou dispersões muito heterogêneas. Seu objetivo é homogeneizar as variáveis de uma base de dados, criando um intervalo de amplitude similar para todas as variáveis. Cabe ressaltar que se manteve a abrangência de todas as situações possíveis a serem aprendidas, de modo a ampliar ao máximo a escala de treinamento. Os poços selecionados para os conjuntos de treinamento e validação são apresentados na TABELA 2.

TABELA 2 - Relação de poços amostrados da Bacia Hidrográfica do Rio Caí. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

Poços	Localização		Município
	UTM N (m)	UTM E (m)	
4300000871	6742800	471150	Feliz
4300001710	6750425	451975	Barão
4300001711	6749950	452050	Barão
4300001713	6750625	450850	Barão
4300001744	6737750	465950	Bom Princípio
4300001745	6737550	464360	Bom Princípio
4300001746	6736625	465225	Bom Princípio
4300002876	6757020	514275	Canela
4300002877	6759187	451308	Carlos Barbosa
4300002881	6759815	451725	Carlos Barbosa
4300002884	6760603	452076	Carlos Barbosa
4300002886	6757500	452075	Carlos Barbosa
4300002916	6742065	468800	Feliz
4300002917	6742250	470575	Feliz
4300002918	6742250	470070	Feliz
4300002919	6742100	470275	Feliz
4300002920	6738150	469800	Feliz
4300002921	6742030	471500	Feliz
4300002922	6741300	470550	Feliz
4300002933	6749855	512240	Gramado
4300002935	6751350	512365	Gramado
4300002936	6750050	511220	Gramado
4300002943	6752016	492310	Nova Petrópolis

continua

continuação

Poços	Localização		Município
	UTM N (m)	UTM E (m)	
4300006198	6737710	465458	Bom Princípio
4300006225	6730835	442632	Brochier
4300006226	6730982	442925	Brochier
4300006231	6730445	438223	Brochier
4300006519	6758411	451229	Carlos Barbosa
4300006520	6758095	451233	Carlos Barbosa
4300006521	6757764	451440	Carlos Barbosa
4300006527	6759845	453357	Carlos Barbosa
4300006688	6750872	489258	Nova Petrópolis
4300006689	6751523	489284	Nova Petrópolis
4300006690	6751401	489352	Nova Petrópolis
4300006691	6752244	491037	Nova Petrópolis
4300006693	6750836	489226	Nova Petrópolis
4300006731	6752243	495609	Nova Petrópolis
4300006732	6750831	489276	Nova Petrópolis
4300006734	6750732	503662	Nova Petrópolis
4300006739	6752167	495279	Nova Petrópolis
4300006758	6743566	495619	Nova Petrópolis
4300006766	6752112	491995	Nova Petrópolis
4300006768	6752058	490578	Nova Petrópolis
4300006853	6755682	522285	Canela
4300006854	6756125	521929	Canela
4300006855	6756126	522307	Canela
4300006863	6758884	519746	Canela
4300006865	6757108	514285	Canela
4300006866	6756337	517782	Canela
4300006875	6752158	516403	Canela
4300006881	6753353	516379	Canela
4300006973	6745304	479898	Linha nova
4300006974	6744484	479612	Linha nova
4300006985	6743912	544020	São Francisco de Paula
4300006991	6767699	533461	São Francisco de Paula
4300006997	6741998	539280	São Francisco de Paula
4300007001	6745774	547296	São Francisco de Paula
4300007002	6744509	542271	São Francisco de Paula
4300007004	6748021	534929	São Francisco de Paula
4300007011	6742295	475146	Feliz
4300007015	6737350	473659	Feliz
4300007025	6746568	470880	Feliz
4300007026	6746025	472920	Feliz
4300007028	6745713	474528	Feliz
4300007029	6735696	470075	Feliz

continuação

Poços	Localização		Município
	UTM N (m)	UTM E (m)	
4300007035	6745207	476447	Feliz
4300007036	6741543	470642	Feliz
4300007041	6742106	471718	Feliz
4300007042	6744239	472112	Feliz
4300007048	6742851	469390	Feliz
4300007049	6741159	469600	Feliz
4300007100	6731033	448043	Maratá
4300007103	6731498	445957	Maratá
4300007104	6729884	450626	Maratá
4300007118	6725995	480003	Lindolfo Collor
4300007140	6751627	513446	Gramado
4300007142	6749128	511349	Gramado
4300007144	6748791	511537	Gramado
4300007153	6750507	512162	Gramado
4300007156	6751943	514182	Gramado
4300007161	6731974	493473	Morro Reuter
4300007170	6730834	492810	Morro Reuter
4300007171	6732709	492806	Morro Reuter
4300007173	6732199	481815	Morro Reuter
4300007176	6730904	492847	Morro Reuter
4300007178	6731806	490590	Morro Reuter
4300007298	6739978	454783	Morro Reuter
4300007305	6737857	447202	Salvador do Sul
4300007366	6720851	461603	Salvador do Sul
4300007403	6735116	476030	Parei Novo
4300007418	6724693	466327	São José do Hortêncio
4300007419	6728116	465113	São Sebastião do Caí
4300007420	6726146	463269	São Sebastião do Caí
4300007421	6727389	464491	São Sebastião do Caí
4300007422	6727813	464675	São Sebastião do Caí
4300007449	6738557	500986	São Sebastião do Caí
4300007453	6738495	500563	Santa Maria do Herval
4300007454	6736351	500376	Santa Maria do Herval
4300007463	6738220	496979	Santa Maria do Herval
4300007476	6751070	463657	Santa Maria do Herval
4300007640	6742084	469765	São Vendelino
4300007641	6742246	470534	Vale Real
4300007642	6742350	470010	Feliz
4300007643	6738410	470153	Feliz
4300007644	6740736	471317	Feliz
4300007645	6749900	512229	Feliz
4300007646	6751430	512369	Feliz

continuação

Poços	Localização		Município
	UTM N (m)	UTM E (m)	
4300007647	6750031	511090	Gramado
4300009368	6776728	467754	Gramado
4300009370	6767285	467898	Gramado
4300009371	6767304	467902	Farroupilha
4300009372	6767202	467723	Farroupilha
4300009436	6773407	486899	Farroupilha
4300010387	6756442	453201	Farroupilha
4300010388	6755647	454132	Caxias do Sul
4300010390	6756467	453699	Carlos Barbosa
4300010393	6757220	455173	Carlos Barbosa
4300010424	6725763	483991	Lindolfo Collor
4300010425	6725143	483970	Lindolfo Collor
4300010426	6724473	482240	Ivoti
4300010427	6724541	482699	Ivoti
4300010428	6724539	482698	Ivoti
4300010429	6725047	483489	Ivoti
4300010430	6724543	483217	Ivoti
4300010431	6724118	483581	Ivoti
4300010432	6723806	483466	Ivoti
4300010433	6723617	483758	Ivoti
4300010435	6725547	484454	Ivoti
4300010437	6726163	485065	Ivoti
4300010438	6724861	484733	Ivoti
4300010439	6724390	484884	Ivoti
4300010453	6728015	486737	Ivoti
4300010455	6726838	486568	Ivoti
4300010456	6726059	487082	Ivoti
4300010458	6726470	487901	Ivoti
4300010459	6724505	484684	Ivoti
4300010460	6724546	484727	Ivoti
4300010461	6724256	484090	Ivoti
4300010462	6724338	483895	Ivoti
4300010465	6723047	487170	Ivoti
4300010467	6723481	484118	Ivoti
4300010468	6723562	481943	Ivoti
4300010473	6726160	486151	Ivoti
4300010678	6760274	452403	Carlos Barbosa
4300010679	6760270	452396	Carlos Barbosa
4300010683	6760133	451689	Carlos Barbosa
4300010684	6760009	451680	Carlos Barbosa
4300010685	6758983	451277	Carlos Barbosa
4300010686	6761690	454578	Carlos Barbosa

Poços	Localização		
	UTM N (m)	UTM E (m)	Município
4300010687	6758444	451942	Carlos Barbosa
4300010689	6758545	451875	Carlos Barbosa
4300010693	6756915	452488	Carlos Barbosa
4300010694	6756908	452540	Carlos Barbosa
4300010695	6757010	453046	Carlos Barbosa
4300010697	6759201	451378	Carlos Barbosa
4300010698	6755878	452705	Carlos Barbosa
4300010752	6753840	460423	Carlos Barbosa
4300010754	6757324	463250	Carlos Barbosa
4300010758	6757017	463306	Carlos Barbosa
4300010767	6757402	460166	Carlos Barbosa
4300010768	6757617	459056	Carlos Barbosa
4300010769	6758859	457491	Carlos Barbosa
4300010771	6758975	457306	Carlos Barbosa
4300010774	6755797	452409	Carlos Barbosa
4300010811	6764652	456945	Carlos Barbosa
4300016721	6778107	503558	Carlos Barbosa
4300016764	6726461	460702	Farroupilha
4300016902	6743762	465785	Caxias do Sul
4300017410	6734427	484718	Pareci Novo
4300017411	6734453	484545	Bom Princípio
4300017524	6766831	466658	Nova Santa Rita

Construção do modelo de RNA: Este processo consistiu na calibração, ou seja, no ajuste dos parâmetros do modelo. Para responder às questões norteadoras da pesquisa, os processos de estruturação e treinamento foram executados com o uso do programa MATLAB, através do módulo *Neural Network Toolbox*.

A estruturação da rede foi determinada pela experimentação e erro durante o processo de treinamento, de modo a definir o tipo de rede, o número de camadas (entrada, saída e escondidas), o número de neurônios em cada camada, as funções de ativação, o algoritmo e o conjunto de dados para o treinamento.

A partir da formação do conjunto de treinamento, os testes para o aprendizado da RNA ocorreram pela metodologia de aprendizado supervisionado com o uso do algoritmo *backpropagation*.

Validação: A validação objetiva comprovar se os parâmetros ajustados na fase de aprendizado condizem com a realidade física.

Nesta etapa, o método empregado foi o clássico, no qual se divide a amostra em duas partes fixas: uma para a calibração do modelo (conjunto de treinamento) e outra para a validação (conjunto de teste).

Simulação e avaliação final da qualidade do modelo: compreende a utilização do modelo propriamente dito e consiste na aplicação do mesmo aos dados da área de estudo reservados para essa finalidade (conjunto de teste). Os resultados produzidos pela simulação são avaliados quanto à qualidade por meio da comparação com os resultados determinados pela metodologia convencional, obtidos no banco de dados SIAGAS.

Após a obtenção dos resultados, foi possível avaliar a capacidade de todas as RNAs e as incertezas geradas pelas mesmas através de ferramentas estatísticas descritas no tópico seguinte.

Elaboração das cartas de isolinhas: Finalmente, os resultados obtidos pelas RNAs foram utilizados na geração de cartas de isolinhas, apresentando o comportamento dos parâmetros da Bacia Hidrográfica do Rio Caí. Para a elaboração dessas cartas fez-se uso do programa Surfer 8 baseado na metodologia de krigagem que consiste em um conjunto de técnicas de regressão linear generalizadas para minimizar uma variância de estimação a partir de um modelo de covariância definido a priori, Deutsch e Journel (1998). O processo de krigagem estima um valor de um atributo, em uma posição não amostrada, a partir de um conjunto de amostras vizinhas.

5.2 ANÁLISE ESTATÍSTICA

A análise estatística utilizada na apresentação dos resultados da pesquisa baseou-se na comparação entre os valores das variáveis modeladas através de RNAs e os tomados como verdadeiros.

Os indicadores estatísticos de desempenho foram: o erro médio absoluto (ou seja, diferença entre o valor real e o valor calculado pelo modelo), a regressão linear (explica a variação de um parâmetro y em função de uma variável x) e também o teste estatístico de *Student* (teste t) apresentado a seguir.

5.2.1 Teste T Para Amostras Independentes

Seja x a medida de um certo atributo dos elementos de uma população A;

Seja y a medida do mesmo atributo dos elementos de uma população B;

Sejam x e y normalmente distribuídos com variâncias desconhecidas;

Seja a hipótese: $\mu_x = \mu_y$ em que μ_x = média de x e μ_y = média de y .

Para testar a hipótese da igualdade das médias de duas populações utiliza-se o teste t . Para isso é necessário testar inicialmente se as duas populações apresentam variâncias iguais utilizando-se o teste F de Fisher:

$$F = \frac{SQD_x}{SQD_y} \quad (1)$$

$$s_x^2 = \frac{SQD_x}{(n_x - 1)} \quad (2)$$

$$s_y^2 = \frac{SQD_y}{(n_y - 1)} \quad (3)$$

$$F_{\text{calculado}} = \frac{s_x^2}{s_y^2} \quad (4)$$

onde:

- SQD_x e SQD_y corresponde, respectivamente, às somas dos quadrados dos desvios de x e y ;
- s_x^2 e s_y^2 correspondem, respectivamente, às variâncias amostrais de x e y ;

- n_x e n_y correspondem, respectivamente, número de variáveis de x e y .

A hipótese a ser testada (H_0) é que a variância populacional de x é igual à variância populacional de y . Se $\text{Prob} > F$ for menor que 5% aceita-se H_0 . Se $\text{Prob} > F$ for maior que 5% rejeita-se H_0 . Se as variâncias populacionais foram estatisticamente iguais, calcula-se uma variância comum (s_c^2):

$$s_c^2 = \frac{(\text{SQD}_x + \text{SQD}_y)}{[(n_x - 1) + (n_y - 1)]} \quad (5)$$

$$s_c^2 = \frac{[(s_x^2 \cdot (n_x - 1)) + (s_y^2 \cdot (n_y - 1))]}{[(n_x - 1) + (n_y - 1)]} \quad (6)$$

A seguir testa-se H_0 para a igualdade das médias populacionais utilizando-se a variável aleatória t , definida por:

$$t = \frac{\mu_x - \mu_y}{\sqrt{v \cdot (\mu_x - \mu_y)}} \quad (7)$$

Sendo:

$$v \cdot (\mu_x - \mu_y) = v(\mu_x) + v(\mu_y) = \frac{s_x^2}{n_x} + \frac{s_y^2}{n_y} \quad (8)$$

Onde:

- v corresponde à variância da média.

Admitindo $s_x^2 = s_y^2 = s_c^2$ tem-se:

$$v \cdot (\mu_x - \mu_y) = \frac{s_c^2}{n_x} + \frac{s_c^2}{n_y} = s_c^2 \cdot \left(\frac{1}{n_x} + \frac{1}{n_y} \right) \quad (9)$$

$$t = \frac{\mu_x - \mu_y}{\sqrt{s_c^2 \cdot \left(\frac{1}{n_x} + \frac{1}{n_y} \right)}} \quad (10)$$

$$\text{graus de liberdade (n)} = (n_x + n_y - 2) \quad (11)$$

No caso de variâncias diferentes tem-se:

$$t = \frac{\mu_x - \mu_y}{\sqrt{\frac{s_x^2}{n_x} + \frac{s_y^2}{n_y}}} \quad (12)$$

Sendo o grau de liberdade calculado com a seguinte equação:

$$n = \frac{\left(\frac{s_x^2}{n_x} + \frac{s_y^2}{n_y}\right)^2}{\frac{\left(\frac{s_x^2}{n_x}\right)^2}{n_x - 1} + \frac{\left(\frac{s_y^2}{n_y}\right)^2}{n_y - 1}} \quad (13)$$

Em ambos os casos (variâncias iguais ou variâncias diferentes) rejeita-se $H_0 = \text{média populacional de } x = \text{média populacional de } y$ se $\text{Prob} > t$ for maior que o nível de significância adotado.

6 RESULTADOS

Nesse estudo foram realizados treinamentos e simulações testando o uso de diferentes topologias e parâmetros disponíveis para avaliar a capacidade de generalização das RNAs aplicadas ao modelamento de recursos hídricos subterrâneos para a Bacia Hidrográfica do Rio Caí.

A análise da disponibilidade e da relevância do estudo resultou na escolha dos seguintes parâmetros hidrogeológicos para compor as entradas e saídas das RNAs: dados de localização (coordenadas UTM Este e Norte), altitude do terreno, espessura e/ou penetração nas camadas litológicas, nível estático, capacidade específica (no mesmo, citado como vazão específica). Conseqüentemente, a partir da escolha dos parâmetros acima descritos, formou-se a amostra de dados para o estudo. Assim, foram utilizadas informações referentes a 171 poços distribuídos na Bacia Hidrográfica do Rio Caí para todas as RNAs desenvolvidas, sendo os mesmos divididos em dois conjuntos de dados: o conjunto de aprendizado, contendo 103 poços (correspondendo a cerca de 60% dos dados amostrais) e o conjunto de simulação/validação, contendo 68 poços (correspondendo a cerca de 40% dos dados amostrais).

Dos cenários testados são apresentados os seguintes resultados:

- Espessura da Formação Serra Geral (RNA1);
- Nível Estático dos poços (RNA2);
- Capacidade específica dos poços (RNA3).

Subsequentemente aos resultados de cada rede são apresentadas as respectivas cartas de isolinhas com os padrões da região.

6.1 RESULTADOS REFERENTES À ESTIMATIVA DA ESPESSURA DA FORMAÇÃO SERRA GERAL (RNA1)

O melhor desempenho para esse problema foi alcançado pela rede de topologia [3-2-2-1], baseada na seguinte estrutura: na camada de entrada os dados de localização do poço (coordenadas UTM Este e Norte e altitude do terreno), duas camadas intermediárias (cada uma com dois neurônios) e a camada de saída com a espessura da Formação Serra Geral (FIGURA 13).

A função de ativação aplicada em todas as camadas constou da sigmoideal tangente hiperbólica; a função de erro foi a MSE (*Mean Square Error*), o algoritmo *backpropagation* foi o *Levenberg-Marquardt* e o número de ciclos de treinamento correspondeu a 600.




FIGURA 13 - Estrutura da RNA1.

A validação dos resultados de simulação obtidos pela RNA1 foi realizada através da comparação entre os valores simulados e os conhecidos para a Bacia Hidrográfica do Rio Caí (TABELA 3). A partir dessa análise comparativa, verificou-se que o erro médio absoluto foi da ordem de 11,89 m com desvio padrão de 10,8 m. Do mesmo modo, os resultados da simulação da RNA1 estão comparados graficamente aos reais na FIGURA 14.

TABELA 3 - Estimativas para a espessura pela RNA1.

Poços	Espessura Serra Geral Conhecidas (m)	Espessura Serra Geral Simuladas (m)	Erro (m)
4300007422	0	4.55	4.55
4300007028	0	3.56	3.56
4300016764	0	-0.77	0.77
4300000871	0	-2.07	2.07
4300007641	0	-7.21	7.21
4300007042	0	-0.31	0.31
4300010431	7	8.23	1.23
4300007476	20	10.29	9.71
4300002918	23.5	25.76	2.26
4300007418	34	26.81	7.19
4300006863	35	27.85	7.15
4300007104	36	34.58	1.42
4300006865	37	41.86	4.86
4300007643	54	49.12	4.88
4300010467	54	49.19	4.81
4300010694	57	49.79	7.21
4300010771	60	53.96	6.04
4300001746	61	54.65	6.35
4300002916	63	61.10	1.90
4300010462	64	61.94	2.06
4300010393	65	65.53	0.53
4300002933	69	67.62	1.38
4300017411	70	68.43	1.57
4300002881	71.5	69.30	2.20
4300007100	75	69.62	5.38
4300006732	78	70.37	7.63
4300002922	80	81.23	1.23
4300006231	80	75.86	4.14
4300006875	80	71.73	8.27
4300010424	81	82.97	1.97
4300002884	86	82.90	3.10
4300006226	87	86.92	0.08
4300006974	91	90.81	0.19
4300010427	98	90.66	7.34
4300006866	98	90.91	7.09
4300006198	100	91.16	8.84
4300006855	100	90.52	9.48
4300007041	102	92.47	9.53
4300010695	108	95.84	12.16
4300006689	105	94.70	10.30
4300010438	114	95.33	18.67
4300007103	116	95.61	20.39

continua

			conclusão
4300010460	118	97.25	20.75
4300010388	120	99.19	20.81
4300007011	123	102.90	20.10
4300009371	125	103.67	21.33
4300010439	126	108.02	17.98
4300009370	126	105.05	20.95
4300010678	133	111.82	21.18
4300007171	137	115.20	21.80
4300010679	139	116.73	22.27
4300001713	144	118.61	25.39
4300002936	144	117.81	26.19
4300007035	150	120.23	29.77
4300001711	150	119.67	30.33
4300006527	150	119.12	30.88
4300010686	150	118.79	31.21
4300002943	156	124.30	31.70
4300007176	160	129.03	30.97
4300016721	170	134.34	35.66
4300010685	180	151.53	28.47
4300002935	180	145.38	34.62
4300007305	186	155.26	30.74
4300009368	198	185.64	12.36
4300007001	200	194.18	5.82
4300006881	205	202.82	2.18
4300007144	206	212.53	6.53
4300007463	216	214.72	1.28

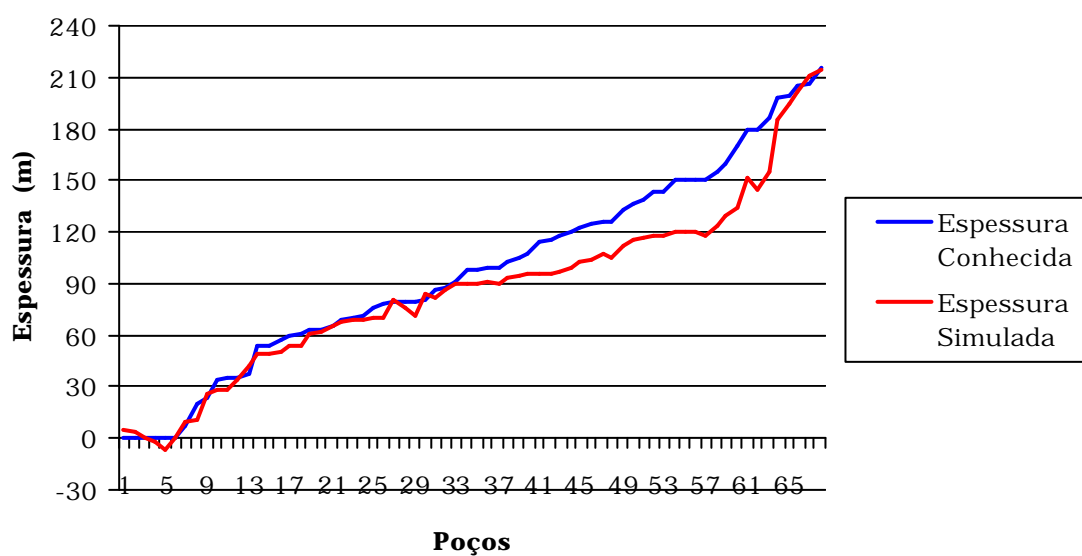


FIGURA 14 - Espessura conhecida e simulada pela RNA1.

Através de uma regressão linear, observou-se uma correlação muito forte ($R^2 = 0,9682$) entre os valores simulados e os tomados como verdadeiros (FIGURA 15).

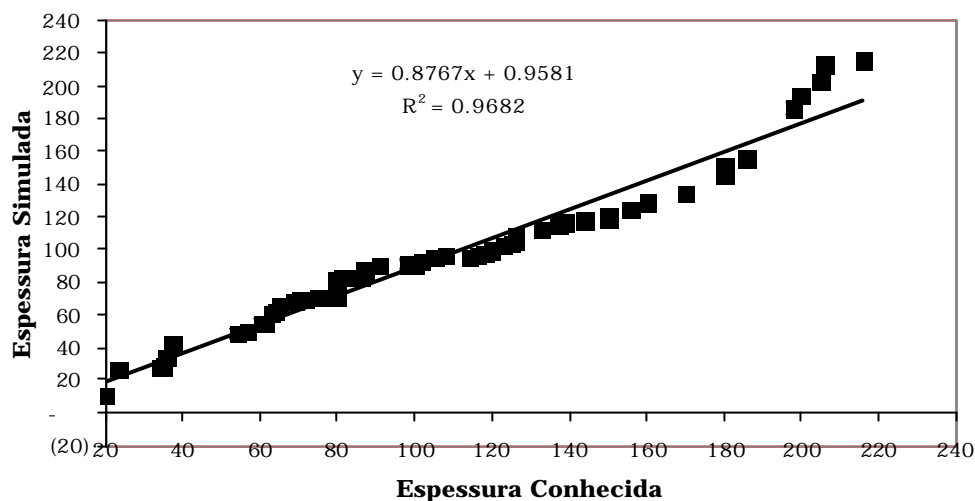


FIGURA 15 – Regressão linear para espessura conhecida e simulada pela RNA1.

Além da análise de regressão, efetuou-se um teste de hipótese para verificar se o modelo proposto é estatisticamente igual ao modelo tomado como real. Para um nível de significância de 5%, o teste t avaliou a igualdade das duas médias (M_1 e M_2). A hipótese testada foi $M_1 = M_2$. Se $\text{Prob} > t$ fosse menor que 0.05 rejeitar-se-ia a hipótese e então M_1 seria diferente de M_2 . A TABELA 4 mostra os resultados do teste estatístico realizado.

TABELA 4 - Resultados do teste de hipótese para RNA1 (M_1 = valores reais e M_2 = valores simulados).

M	N	Média	Desvio Padrão	Variância	t	Grau de liberdade	Prob>(t)
1	68	97.82352941	57.93632407	Desiguais	1.1524	131.9	0.2512
2	68	87.02764706	51.09921991	Iguais	1.1524	134.0	0.2512

Para H_0 : variâncias são iguais, $F' = 1.29$
 Prob> $F' = 0.3064$
 Nível de significância = 5%

Os padrões da espessura da Formação Serra Geral verificados através de isolinhas foram gerados a partir dos valores conhecidos (FIGURA 16) e da simulação da RNA1 (FIGURA 17). Fazendo uso dos mesmos resultados foi possível elaborar outras cartas de isolinhas com as cotas máximas reais (FIGURA 18) e simuladas da Formação Botucatu (FIGURA 19), elaboradas por meio da determinação da diferença entre a altitude do terreno e a espessura da Formação Serra Geral.

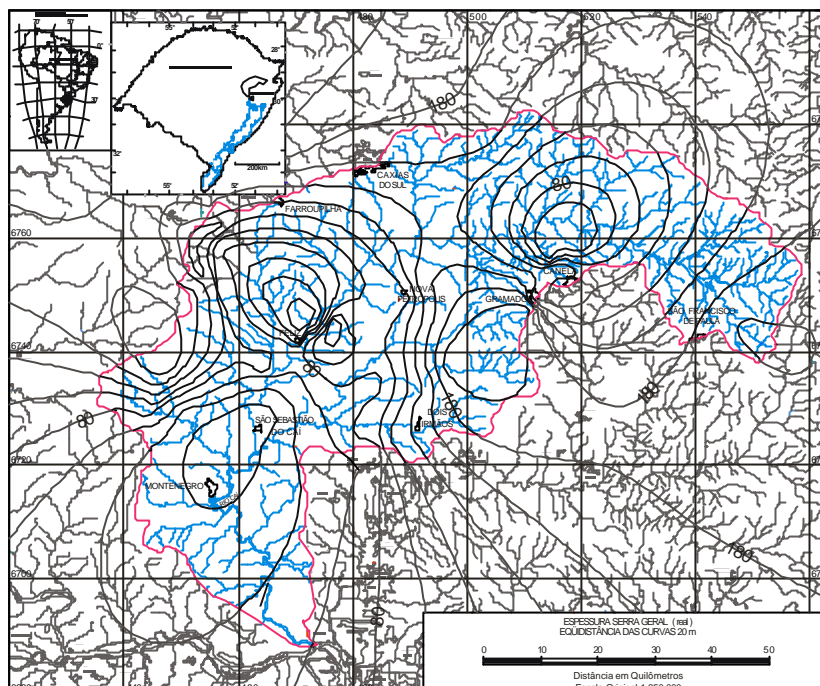


FIGURA 16 – Isolinhas para espessura da Formação Serra Geral conhecida.
Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.




FIGURA 17 – Isolinhas para espessura da Formação Serra Geral simulada.
Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

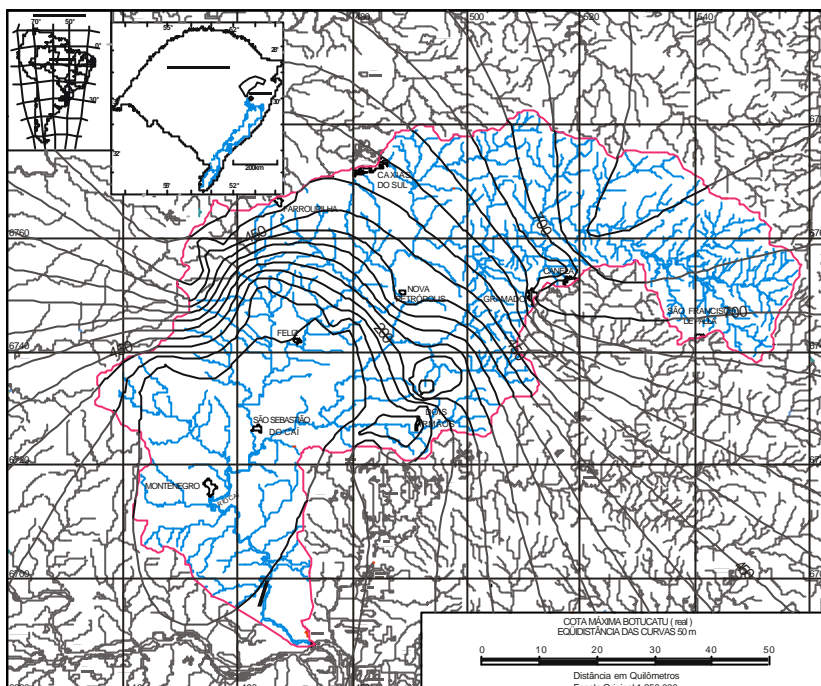


FIGURA 18 – Isolinhas para cota máxima da Formação Botucatu conhecida.
 Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano
 Central 51°W.

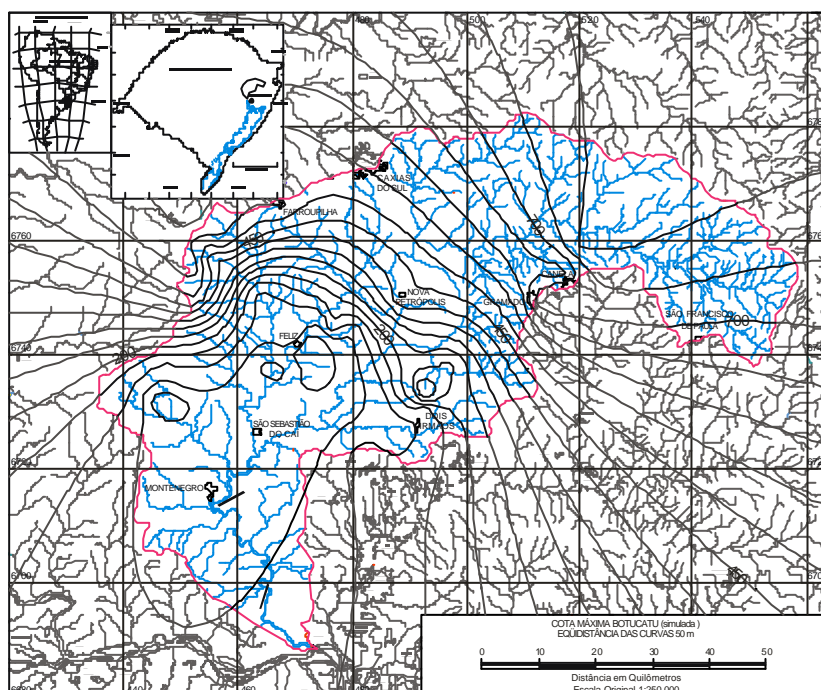


FIGURA 19 – Isolinhas para cota máxima da Formação Botucatu simulada.
 Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano
 Central 51°W.

6.2 RESULTADOS REFERENTES À ESTIMATIVA DO NÍVEL ESTÁTICO (RNA2)

Entre os testes realizados, a rede que proporcionou os melhores resultados foi a de topologia [5-4-2-1]. Na camada de entrada informaram-se dados de localização do poço (coordenadas UTM Este e Norte e altitude do terreno) e de litologia (espessura da camada da Formação Serra Geral e penetração na Formação Botucatu), duas camadas intermediárias (com quatro e dois neurônios, respectivamente) e a camada de saída com os níveis estáticos dos poços (FIGURA 20).

As funções de ativação aplicadas foram a sigmoide tangente hiperbólica nas camadas intermediárias e a função linear na camada de saída, a função de erro foi a MSE (*Mean Square Error*), o algoritmo *backpropagation* foi o *Levenberg-Marquardt* e o aprendizado ocorreu em 200 ciclos de treinamento.




FIGURA 20 - Estrutura da rede RNA2.

Para validar as estimativas propostas os resultados da simulação são comparados com os valores tomados como reais, e dessa forma verificou-se que o erro médio absoluto foi da ordem de 3,87 m com desvio padrão de 6,2 m (TABELA 5). Do mesmo modo, os resultados simulados pela RNA2 estão comparados graficamente com os valores reais na FIGURA 21.

TABELA 5 - Estimativa dos níveis estáticos dos poços pela RNA2.

Poços	Nível Estático Conhecido (m)	Nível Estático Simulado (m)	Erro (m)
4300006732	0	0.11	0.11
4300007048	0.35	0.21	0.14
4300006853	0.66	0.96	0.30
4300006693	1	1.04	0.04
4300002916	1.5	1.04	0.46
4300010694	1.5	0.72	0.78
4300001710	1.67	1.99	0.32
4300010695	2	1.85	0.15
4300007004	2.53	1.94	0.59
4300006739	3	2.03	0.97
4300010774	3.3	2.09	1.21
4300007142	4	2.40	1.60
4300007641	4.36	3.13	1.23
4300010684	4.56	3.88	0.68
4300010393	5	4.50	0.50
4300010767	5	4.28	0.72
4300010693	6	5.15	0.85
4300007403	6.61	5.96	0.65
4300010752	7	7.48	0.48
4300010769	7	7.37	0.37
4300006854	8	8.46	0.46
4300007171	8.25	9.06	0.81
4300007042	9.72	10.54	0.82
4300002920	9.93	10.70	0.77
4300006689	10.74	11.20	0.46
4300006225	11.3	12.04	0.74
4300007418	12	12.19	0.19
4300007644	12.07	16.86	4.79
4300002935	12.32	15.64	3.32
4300007453	12.47	15.58	3.11
4300007118	13	15.57	2.57
4300010435	14.74	16.58	1.84
4300010754	15	18.19	3.19
4300006758	16	20.18	4.18
4300002876	17.38	20.80	3.42
4300010689	19	21.66	2.66
4300007642	21.51	22.59	1.08
4300007103	22	27.06	5.06
4300007029	22	27.13	5.13
4300006855	23	22.02	0.98
4300002921	25.17	24.82	0.35
4300007001	28.5	25.19	3.31

continua

conclusão

Poços	Nível Estático Conhecido (m)	Nível Estático Simulado (m)	Erro (m)
4300007026	30	26.32	3.68
4300006688	30	26.52	3.48
4300006734	30.4	24.73	5.67
4300007645	32.27	26.58	5.69
4300006231	35	28.59	6.41
4300007647	39.93	30.27	9.66
4300010687	42	31.69	10.31
4300007298	44.5	32.19	12.31
4300006198	46.01	35.60	10.41
4300010685	51.95	40.29	11.66
4300001746	55.83	43.94	11.89
4300001711	58	47.86	10.14
4300009370	58.9	55.50	3.40
4300017410	60	57.83	2.17
4300007156	63	60.76	2.24
4300009372	65.8	64.85	0.95
4300010425	67.58	66.03	1.55
4300010758	69	68.10	0.90
4300010437	75.38	69.99	5.39
4300010438	76.15	71.23	4.92
4300010427	85.59	79.91	5.68
4300007140	89.6	84.60	5.00
4300010468	90	86.19	3.81
4300010465	93.2	114.35	21.15
4300010433	97.86	141.30	43.44
4300010459	122.58	122.63	0.05




FIGURA 21 – Níveis estáticos conhecido e simulado pela RNA2.

Através da regressão linear realizada observou-se também uma correlação muito forte ($R^2 = 0,9455$) entre os valores simulados e os tomados como verdadeiros (FIGURA 22).

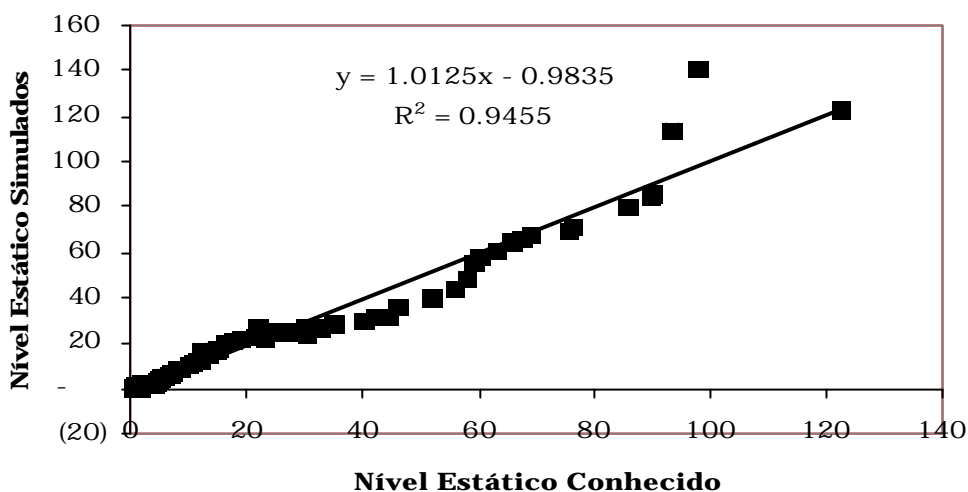


FIGURA 22 – Regressão linear para níveis estáticos conhecidos e simulados pela RNA2.

Da mesma forma que no tratamento estatístico realizado para a estimativa da espessura da camada da Formação Serra Geral, efetuou-se o teste de hipótese para verificar se o modelo proposto é estatisticamente igual ao modelo tomado como real. Assim, para um nível de significância de 5%, o teste t avaliou a igualdade das duas médias (M_1 e M_2). A hipótese testada foi $M_1 = M_2$. Se $\text{Prob} > t$ fosse menor que 0.05, rejeitar-se-ia a hipótese e então M_1 seria diferente de M_2 . A TABELA 6 mostra os resultados do teste estatístico realizado.

TABELA 6 – Resultados do teste de hipótese para RNA2 (M1= valores reais e M2= valores simulados).

M	N	Média	Desvio Padrão	Variância	t	Grau de liberdade	Prob>(t)
1	68	29.73044118	30.13989063	Desigual	0.1160	133.8	0.9078
2	68	29.11823529	31.38441413	Igual	0.1160	134.0	0.9078

Para H_0 : as variâncias são iguais, $F' = 1.08$
 Prob> $F' = 0.7415$
 Nível de significância = 5%

Nas FIGURAS 23 e 24 estão as isolinhas geradas com os valores conhecidos e simulados pela RNA2 para a profundidade do nível estático, respectivamente. Nas FIGURAS 25 e 26 estão as cotas máximas dos níveis estáticos conhecido e simulado, respectivamente, determinados a partir da diferença entre a altitude do terreno e o nível estático.




FIGURA 23 – Cartas de isolinhas para profundidade do nível estático conhecido. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.




FIGURA 24 – Cartas de isolinhas para profundidade do nível estático simulado. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

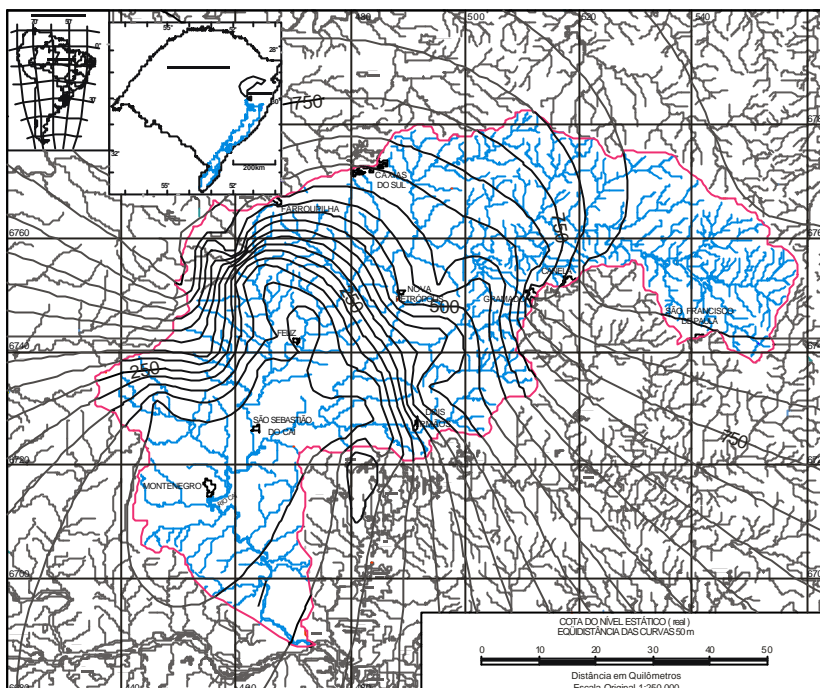


FIGURA 25 – Cartas de isolinhas para cota máxima do nível estático conhecido. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

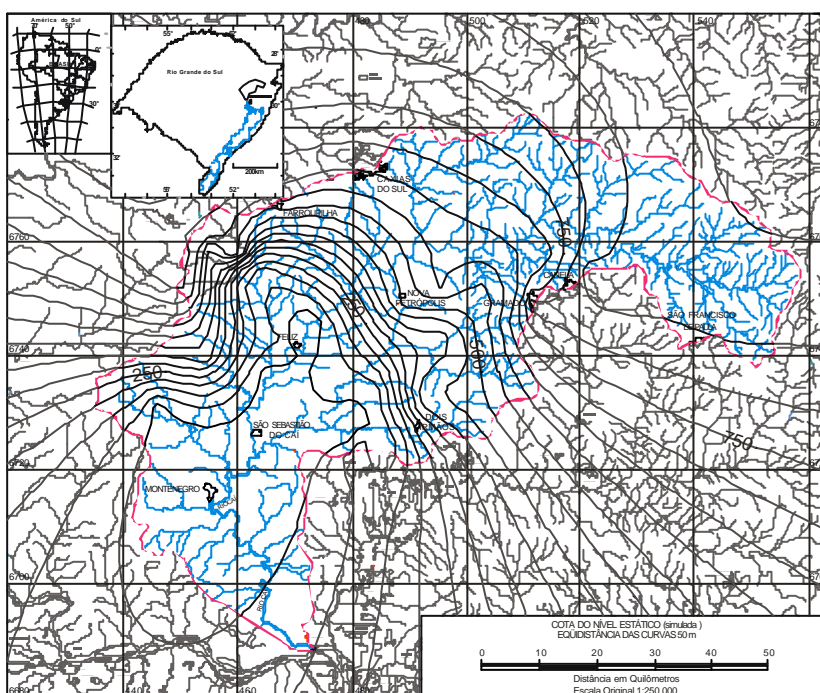


FIGURA 26 – Cartas de isolinhas para cota máxima do nível estático simulado. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

6.3 RESULTADOS REFERENTES ÀS ESTIMATIVAS DA CAPACIDADE ESPECÍFICA (RNA3)

O último teste realizado foi referente à estimativa da capacidade específica dos poços. A topologia com os melhores resultados foi a [5-4-2-1], apresentando na camada de entrada dados de localização dos poços (coordenadas UTM Este e Norte e altitude do terreno) e litologia (espessura da camada da Formação Serra Geral e penetração na Formação Botucatu), duas camadas intermediárias (com quatro e dois neurônios, respectivamente) e a camada de saída com os níveis estáticos dos poços (FIGURA 27).

As funções de ativação aplicadas foi a sigmoidal tangente hiperbólica em todas as camadas, exceto na segunda camada intermediária, onde foi aplicada a função linear. A função de erro foi a MSE (*Mean Square Error*), o algoritmo *backpropagation* foi o *Levenberg-Marquardt* e o aprendizado ocorreu em 600 ciclos de treinamento.




FIGURA 27 - Estrutura da RNA3.

Para avaliar as estimativas obtidas, os resultados da simulação foram comparados com os valores conhecidos, e dessa forma verificou-se que o erro médio absoluto foi da ordem de 0,21 m³/h/m com desvio padrão de 0,5 m³/h/m, conforme a TABELA 7. Do mesmo modo, os resultados simulados pela RNA3 estão comparados graficamente na FIGURA 28.

TABELA 7 - Estimativa da capacidade específica pela RNA3.

Poços	Cap. Específica Conhecida (m³/h/m)	Cap. Específica Simulada (m³/h/m)	Erro (m³/h/m)
4300002935	0.0002	0.0177	0.0200
4300007004	0.0030	0.0180	0.0100
4300010393	0.0050	0.0187	0.0100
4300006688	0.0100	0.0187	0.0100
4300010468	0.0130	0.0192	0.0100
4300006693	0.0160	0.0208	0.0048
4300007156	0.0180	0.0218	0.0038
4300007142	0.0280	0.0240	0.0040
4300006758	0.0350	0.0290	0.0060
4300007298	0.0350	0.0276	0.0074
4300006732	0.0400	0.0274	0.0126
4300010689	0.0400	0.0268	0.0132
4300007001	0.0490	0.0348	0.0142
4300001710	0.0650	0.0401	0.0249
4300009372	0.0750	0.0553	0.0197
4300007118	0.1080	0.0606	0.0474
4300010769	0.1100	0.0694	0.0406
4300007103	0.1210	0.0848	0.0362
4300007042	0.1250	0.1013	0.0237
4300007453	0.1280	0.1147	0.0133
4300010459	0.2050	0.1206	0.0844
4300010694	0.2160	0.1344	0.0816
4300007641	0.2190	0.1581	0.0609
4300017410	0.2490	0.1613	0.0877
4300007418	0.2500	0.1643	0.0857
4300010687	0.2500	0.1684	0.0816
4300007647	0.2510	0.1742	0.0769
4300002920	0.2670	0.1960	0.0710
4300010685	0.2740	0.2009	0.0731
4300002876	0.2986	0.2102	0.0884
4300006225	0.3010	0.2129	0.0881
4300006734	0.3040	0.2098	0.0942
4300001711	0.3066	0.1937	0.1129
4300007140	0.3200	0.1923	0.1277
4300010465	0.3270	0.2163	0.1107
4300006739	0.3900	0.2656	0.1244
4300006689	0.3940	0.2682	0.1258
4300010438	0.3970	0.2698	0.1272
4300007048	0.4010	0.2798	0.1212
4300006854	0.4050	0.2959	0.1091
4300007642	0.4500	0.3102	0.1398
4300002921	0.4712	0.3159	0.1553

continua

conclusão

Poços	Cap. Específica Conhecida (m ³ /h/m)	Cap. Específica Simulada (m ³ /h/m)	Erro (m ³ /h/m)
4300007644	0.4891	0.3252	0.1639
4300010774	0.4970	0.3414	0.1556
4300007026	0.5000	0.3674	0.1326
4300006853	0.5140	0.3992	0.1148
4300010695	0.5210	0.4417	0.0793
4300009370	0.5600	0.4552	0.1048
4300007029	0.6540	0.5026	0.1514
4300010437	0.7510	0.5148	0.2362
4300010767	0.9600	0.5893	0.3707
4300010433	1.0130	0.6518	0.3612
4300010754	1.2000	0.7568	0.4432
4300002916	1.3253	0.8697	0.4556
4300001746	1.3289	0.9425	0.3864
4300010758	1.3330	1.2721	0.0609
4300010425	1.4160	1.4160	0.0000
4300010684	1.4790	1.2578	0.2212
4300010693	1.5000	1.2822	0.2178
4300007645	1.5099	1.3380	0.1719
4300006198	1.5150	1.3458	0.1692
4300010752	1.6670	1.3530	0.3140
4300010435	1.8690	1.5011	0.3679
4300007403	2.4330	1.5421	0.8909
4300010427	2.6140	1.6172	0.9968
4300006231	7.2000	3.4407	3.7593
4300006855	7.5000	5.8295	1.6705
4300007171	10.2270	10.2137	0.0133

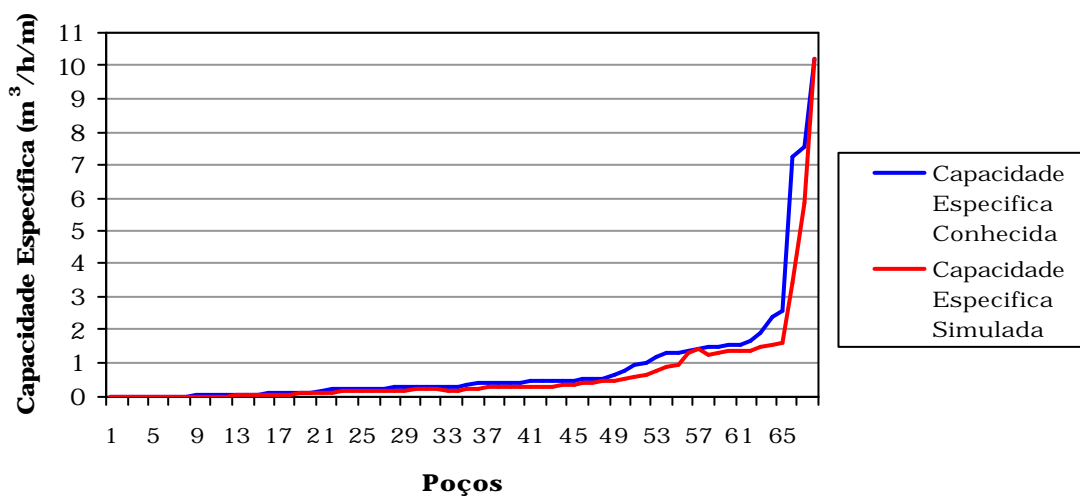


FIGURA 28 – Capacidade específica conhecida e simulada pela RNA3.

Através da regressão linear observou-se também uma correlação muito forte ($R^2 = 0,9292$) entre os valores simulados e os tomados como verdadeiros. Isso pode ser verificado na FIGURA 29.

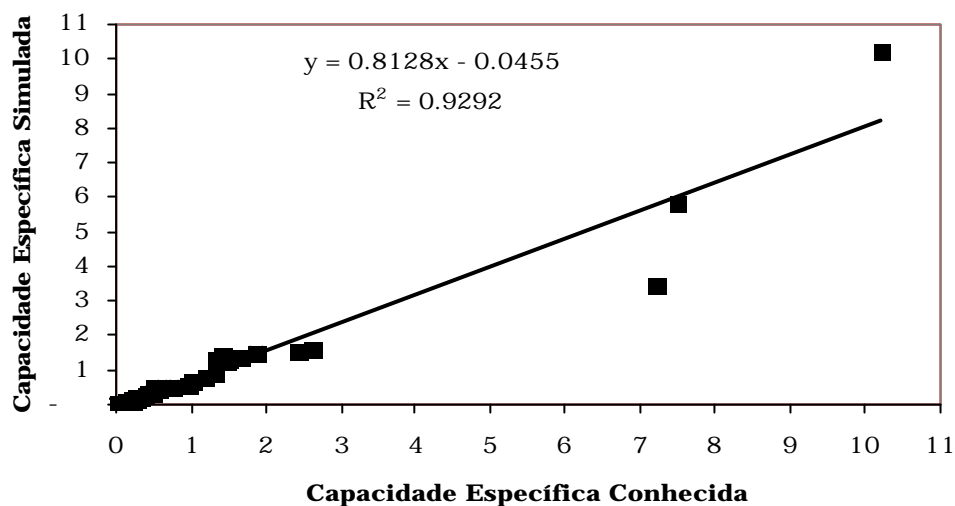


FIGURA 29 – Regressão linear para a capacidade específica conhecida e simulada pela RNA3

Da mesma forma que nas estimativas das variáveis supracitadas, efetuou-se o teste de hipótese para verificar se o modelo proposto é estatisticamente igual ao modelo tomado como real. Para um nível de significância de 5%, o teste t avaliou a igualdade das duas médias (M_1 e M_2). A hipótese testada foi $M_1 = M_2$. Se $\text{Prob} > t$ fosse menor que 0.05, rejeitar-se-ia a hipótese e então M_1 seria diferente de M_2 . A TABELA 8 mostra os resultados do teste estatístico realizado.

TABELA 8 – Resultados do teste de hipótese para RNA3 (M1= valores reais e M2= valores simulados).

M	N	Média	Desvio Padrão	Variâncias	t	Grau de liberdade	Prob>(t)
1	68	0.89039176	1.73845992	Desigual	0.7696	130.3	0.4429
2	68	0.67817412	1.46578659	Igual	0.7696	134.0	0.4429

Para H_0 : variâncias são iguais, $F' = 1.41$

$\text{Prob}>F' = 0.1652$

Nível de significância = 5%

Com base nos valores reais e simulados pela RNA3, foram geradas isolinhas (FIGURAS 30 e 31), que apresentam o comportamento das capacidades específicas conhecidas e simuladas, respectivamente, dos poços para a Bacia Hidrográfica do Rio Caí.

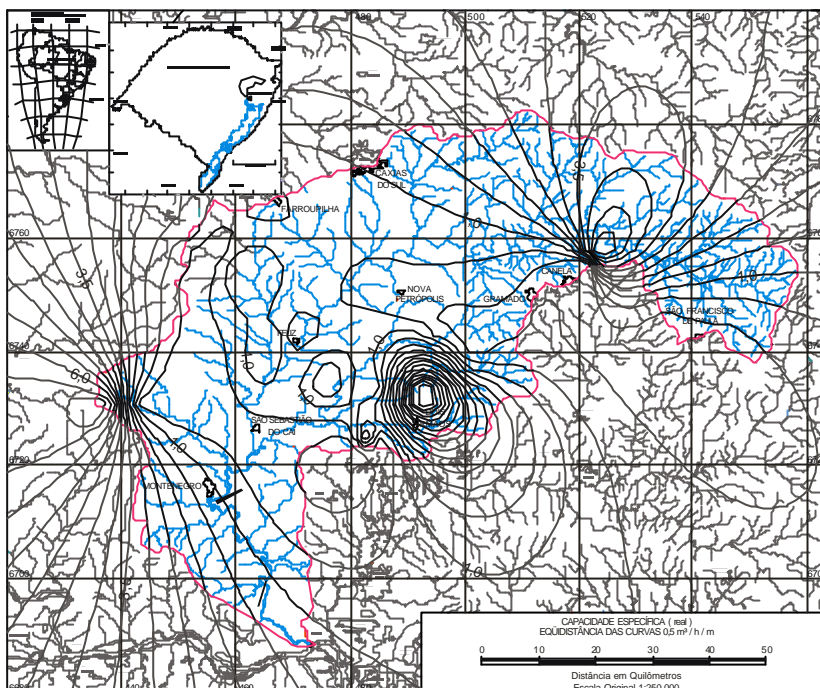


FIGURA 30 – Isolinhas para a capacidade específica conhecida. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.




FIGURA 31 – Isolinhas para a capacidade específica simulada. Sistema de Projeção UTM, Elipsóide de Referência Hayford e Meridiano Central 51°W.

7 DISCUSSÃO DOS RESULTADOS

7.1 CONSTRUÇÃO DAS REDES NEURAIAS ARTIFICIAIS

As arquiteturas das RNAs foram determinadas de modo empírico; sendo assim, todas as etapas da construção passaram por diversos testes.

A seleção dos parâmetros hidrogeológicos para as entradas e saídas das redes enfrentou a falta de informações sobre os poços cadastrados no banco de dados. Este problema, já relatado por Machado e Freitas (2005), eliminou muitos poços, diminuindo a malha de amostragem e causando diversas lacunas e restrições na escala de treinamento e simulação, fato que pode ter influenciado a ocorrência de erros pontuais nas redes. Entretanto, a ausência de certos parâmetros no SIAGAS não impediu a construção dos modelos por Redes Neurais e inclusive direcionou o estudo para a possibilidade de utilização de parâmetros alternativos à modelagem convencional.

Dentre as alternativas disponíveis, a escolha dos parâmetros hidrogeológicos mais apropriados a cada rede se deu através da avaliação do comportamento dos modelos frente à inserção ou exclusão de cada parâmetro. Por exemplo, a profundidade dos poços foi excluída porque ficou subentendida na espessura e/ou penetração das camadas litológicas. Sendo assim, sua inclusão não acrescentava melhorias à rede.

Quanto à distribuição dos dados no conjunto de treinamento e simulação, não foi possível o uso dos mesmos conjuntos para a construção das três redes, pois a escala de treinamento se tornou deficitária no caso da RNA1. O desempenho da rede durante a fase de simulação foi determinado por sua fase de treinamento, porque, após treinar, os pesos das conexões entre neurônios foram mantidos fixos durante a simulação, conforme proposto por Balkhair (2002). Isso significa que, quando a seleção da escala de treinamento não apresenta exemplos em quantidades suficientes para o aprendizado, a capacidade de generalização da rede fica prejudicada (Lin e

Chen, 2006). Desse modo, na RNA1 houve uma redistribuição dos dados dos poços no conjunto de treinamento e simulação, visando uma melhor exemplificação das situações reais. Assim, foi possível proporcionar um melhor aprendizado e otimizar os resultados da RNA. Por sua vez, na RNA2 e RNA3 foi possível manter o mesmo grupo de treinamento com resultados satisfatórios.

No que se refere aos parâmetros que compõem a rede (função de ativação, número de camadas e neurônios, etc.) realizaram-se vários tipos de testes, e a cada modificação avaliava-se a sensibilidade da RNA de acordo com a variação dos resultados da simulação, até que se atingisse um desempenho considerado ótimo com base em estatística. Por exemplo, os resultados mostraram um melhor desempenho de todas as RNAs quando se utilizou duas camadas intermediárias.

O aumento do número de camadas não aumentou o tempo de processamento, devido ao fato da quantidade de dados de entrada não ser grande. Tal fato pode proporcionar uma maior variabilidade dos erros, pois faz com que as RNAs percam sensibilidade, subestimando ou superestimando valores, ou ainda, pode não fazer diferença significativa. A constatação desses fatos também pode ser verificada em (Rohn e Mine, 2003; Maracajá, 2005; Garcia e Shigidi, 2006).

Em relação às funções de ativação, nas redes RNA2 e RNA3 fez-se uso associado das funções tangente hiperbólica e linear nos neurônios da camada intermediária e de saída, pois segundo Rubini (2006) essa combinação cria uma rede neural capaz de descrever, com precisão arbitrária, qualquer sistema não linear se a camada intermediária contiver o número de neurônios suficientes.

7.2 RNA1: ESPESSURA DA FORMAÇÃO SERRA GERAL

A RNA1, rede para estimativa da espessura da camada da Formação Serra Geral, manteve-se estável e obteve bons resultados em suas

estimativas. Em termos estatísticos, a maior parte dos valores calculados pelo modelo está dentro do desvio padrão da média de erro, com apenas algumas exceções. Entretanto, no intervalo dos 100 aos 200 m a rede passou a gerar erros superiores ao desvio padrão da média de erro.

Observando-se o comportamento das saídas simuladas no intervalo dos 100 aos 200 m, percebe-se que os erros crescem conforme aumenta a espessura da camada e que não há uma generalização adequada dos parâmetros. Mas, por outro lado, a rede mantém estabilidade na determinação da espessura da Formação Serra Geral: mesmo os resultados estando subestimados, continuam em crescimento, sem a ocorrência de erros em picos significativos. A estabilidade apresentada pela RNA1 indica que os erros não estão relacionados à escolha dos parâmetros de entrada da mesma, deduz-se então, que estes são adequados ao modelo. Sendo assim, a deficiência da rede deve estar associada a uma malha de amostragem deficiente para esta faixa de dados no conjunto de treinamento, impedindo que a rede reconhecesse e aprendesse adequadamente os padrões da região para retirar as relações relevantes. Outra possibilidade seria uma deficiência do próprio algoritmo *backpropagation* que converge os resultados a mínimos locais, que são pontos na superfície de erro que apresentam uma solução estável, embora a saída não seja correta (Braga *et al*, 2000).

Apesar do problema supracitado, o gráfico comparativo entre os valores reais e simulados mostra que a RNA1 conseguiu realizar uma aproximação satisfatória. Por meio da análise da regressão linear foi possível comprovar que existe uma correlação muito forte entre os valores reais e os simulados. Do mesmo modo, o teste de hipótese confirmou que as médias da espessura da camada da Formação Serra Geral reais e as simuladas pela RNA1 são estatisticamente iguais, com um grau de confiança de 95%.

As cartas de isolinhas para espessura da Formação Serra Geral real e simulada tendências bastante semelhantes, existindo alguns pontos com pequenas divergências. Isso mostra que a RNA conseguiu aprender o comportamento da espessura da formação estudada de uma maneira bastante eficiente. Em ambas, os valores da espessura são mais acentuados nas regiões sudeste e norte da Bacia, decrescendo em direção à parte central

e sudoeste. Da mesma maneira, as cartas referentes às cotas máximas da Formação Botucatu possuem muita similaridade entre si. Nessas, verifica-se que as áreas de maior altitude localizam-se a nordeste com declividade para sudoeste.

7.3 RNA2: REDE PARA NÍVEIS ESTÁTICOS

A RNA2 foi responsável pela determinação do nível estático dos poços e alcançou bom desempenho, com um baixo erro médio absoluto. Além disso, observa-se que a rede obteve erros inferiores ao desvio padrão da média em praticamente todo conjunto de simulação, ocorrendo erros significativos em apenas alguns poços.

Analisando-se o comportamento dos valores calculados em relação aos reais, nota-se a existência de dois pontos da rede onde houve erros significativos. O primeiro pico de erro ocorreu entre os valores reais de 40 m e 58 m, no qual seis valores foram subestimados, enquanto no segundo, dois valores foram superestimados entre os valores reais de 93 m e 98 m. Em ambos os casos, a resposta pode estar em uma malha de amostragem deficiente para essas faixas de dados no conjunto de treinamento. De modo geral, a capacidade de extrapolação da rede decai quando não há exemplos suficientes para que a mesma possa reconhecer e aprender adequadamente os padrões e retirar as relações relevantes.

O grau de similaridade do nível estático simulado pelo modelo com os reais pode ser percebido através do gráfico comparativo. Já a análise de regressão linear mostrou que há uma correlação forte entre ambos. O teste de hipótese indicou que as médias dos níveis estáticos reais e as simulados pela RNA2 são estatisticamente iguais, com um grau de confiança de 95%.

As cartas de isolinhas de nível estático ilustram a situação do nível da água no poço nos momentos em que não está ocorrendo bombeamento. As comparações visuais entre as cartas geradas a partir dos valores simulados e os reais exibem tendências semelhantes, estando os valores estimados pela

RNA2 muito bem ajustados ao resultado do fenômeno real. As cartas contendo a profundidade do nível estático mantêm uma distribuição relativamente homogênea em toda a área. Já as cartas referentes às cotas máximas do nível estático aumentam de sudoeste para nordeste, acompanhando o relevo da Bacia Hidrográfica.

7.4 RNA3: REDE PARA CAPACIDADES ESPECÍFICAS

As previsões obtidas na RNA3 tiveram bons resultados e a mesma alcançou um baixo erro médio absoluto. A rede foi capaz de simular bem os eventos, não conseguindo explicar somente uma pequena parcela da variação da capacidade específica.

Analisando-se, então, o comportamento da simulação da RNA3 em relação aos dados reais, nota-se que o modelo aproximou bem tanto as capacidades específicas baixas como as altas. Todavia, houve um ponto da rede com valores subestimados, gerando divergências significativas. Esses erros podem estar associados à escala de treinamento, pois ao analisar as informações provenientes do banco de dados percebeu-se que 91% dos dados de capacidade específica estão compreendidos entre 0,001 e 2,0 m³/h/m. As lacunas existentes entre os demais valores (2,0 a 10,2 m³/h/m), por sua vez, impediram que a RNA3 extraísse os padrões de comportamento da capacidade específica de modo adequado.

As deficiências existentes no banco de dados são compreensíveis para esse parâmetro, pois praticamente 95% da Bacia Hidrográfica do Rio Cai está localizada em sistemas aquíferos de baixa produtividade (menos de 0,5 m³/h/m), que são os sistemas aquíferos Botucatu/Pirambóia e Serra Geral II (SEMA, 2007). Excepcionalmente os valores de capacidade específica fogem aos baixos valores habituais pelo fato de os poços se localizarem sobre áreas fraturadas que permitem a passagem da água, tornando maior a produtividade (Machado e Freitas, 2005). Esta situação pode ser comprovada facilmente através da simples comparação dos quatro poços contendo erros significativos aos demais localizados nos respectivos municípios. Todos os

poços estão localizados no sistema aquífero Serra Geral II nos municípios de São José do Hortêncio, Ivoti, Brochier e Canela. Em cada um dos casos, a produtividade dos poços em questão é muito superior à produtividade média dos demais poços existentes no município. Além disso, ao serem plotados sobre uma carta geológica, localizam-se em pontos específicos que indicam a existência de fálha. Sendo assim, provavelmente esses pontos de captação estão situados sobre falhamentos da estrutura geológica.

O gráfico comparativo apresenta traçados muito próximos entre a capacidade específica simulada e real. Da mesma maneira, a regressão linear demonstrou que há uma correlação forte entre as mesmas. O teste de hipótese também indicou que as médias das capacidades específicas reais e simuladas pela RNA3 são estatisticamente iguais, com um grau de confiança de 95%.

As cartas de isolinhas de capacidade específica demonstraram grande correspondência entre as tendências da previsão gerada pela RNA3 e os dados reais. As potencialidades de água subterrânea apresentam distribuição homogênea, predominando, como já esperado, capacidades específicas baixas. Apesar disso, as cartas apontam à presença de áreas pontuais de produtividade elevada, sendo esses os pontos de divergência entre a carta simulada e a real, estando a primeira subestimando os valores.

8 CONCLUSÕES E CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi desenvolver modelos baseados em redes neurais artificiais que fossem capazes de simular parâmetros de água subterrânea a partir de informações retiradas do banco de dados SIAGAS, para que servissem de base para a elaboração de cartas de isolinhas para a Bacia Hidrográfica do Rio Cai. Deste modo, foram propostos três modelos distintos: determinação da espessura da Formação Serra Geral, previsão do nível estático e a capacidade específica dos poços.

Através das análises comparativas realizadas neste trabalho, as RNAs demonstraram ser ferramentas eficientes na previsão de parâmetros de sistemas hidrogeológicos. As principais vantagens encontradas na utilização da abordagem desenvolvida foram:

- Economia - permite o uso de variáveis simples disponíveis em bancos de dados ou obtidos de modo mais rápido e fácil do que aquelas utilizadas pela metodologia convencional. Pode-se, então, simplificar processos e reduzir custos operacionais, tais como de pessoal, procedimentos e equipamentos de medição;
- Rapidez - o tempo de desenvolvimento de um modelo baseado em RNAs é mais rápido do que um sistema convencional;
- Simplicidade - a construção do modelo não exige o conhecimento aprofundado de um especialista e possui uma estrutura de fácil entendimento e implementação;
- Versatilidade - por serem sistemas altamente adaptativos, as estimativas podem ser obtidas quase que instantaneamente, possibilitando aplicações em tempo real, sem que seja necessária a readaptação de parâmetros estruturais, bastando apenas a atualização de suas entradas. Além disso, não exige que as variáveis envolvidas no modelamento tenham uma correlação explícita.
- Confiabilidade: os valores obtidos pela rede fornecem valores bem próximos dos valores reais, confirmados pela análise estatística.

A análise dos modelamentos realizados com base nas simulações da RNA1 mostrou que apenas com a localização do ponto de captação de água subterrânea é possível estabelecer parte da caracterização litoestratigráfica da região, sugerir o aquífero explorado e inferir parâmetros correlacionados, como por exemplo, a produtividade. Assim, os resultados demonstram que através do uso das RNAs é possível estimar, somente com dados de localização, a espessura da Formação Serra Geral ou a altitude máxima da Formação Botucatu, orientando a alocação e a perfuração de poços para locais de interesse.

A exatidão na determinação das tendências da região para o nível estático representados pelos resultados e isolinhas da RNA2 confirma que a metodologia sugerida pode ser utilizada de modo eficiente na previsão desse tipo de parâmetro de água subterrânea. Assim, pode servir para estabelecer critérios operacionais de poços, simulando várias situações e possibilitando a escolha de procedimentos mais viáveis e vantajosos para a aplicação prática, conforme sugerido por Saggioro *et al.* (2000). Ainda, pode auxiliar na elaboração de ferramentas de gestão, como na determinação de áreas vulneráveis a contaminação da água subterrânea, pois poços com níveis estáticos mais profundos tornam mais difícil a contaminação, já que o contaminante precisa atravessar uma maior espessura de rocha para chegar ao aquífero.

A representação das potencialidades distintas de produção obtidas pela RNA3 para a Bacia Hidrográfica do Rio Caí demonstrou que esse tipo de modelo é capaz de realizar de modo satisfatório o zoneamento dos prováveis potenciais do aquífero, podendo, assim, orientar a exploração da água subterrânea de modo a atender as necessidades de diferentes atividades, levando em consideração as condições estruturais que regem a ocorrência e circulação da água na região.

Os modelos RNA2 e RNA3 apresentaram muitas semelhanças estruturais, o que sugere o aperfeiçoamento de uma rede única com duas saídas (nível estático e capacidade específica).

Cabe ressaltar que, apesar das RNAs possuírem a capacidade de extrair relações entre as variáveis em uma pequena amostra, seu sucesso

está associado a um conjunto mínimo de eventos utilizados no treinamento. Quanto maior esse conjunto e mais heterogêneos esses eventos, melhores serão os resultados obtidos. O uso de um número maior de exemplos de calibração e o aperfeiçoamento dos detalhes do método pode reduzir os erros ao mesmo nível dos modelos hidrogeológicos convencionais. Outra maneira para melhorar os resultados seria utilizar outras metodologias de validação, como, por exemplo, a validação cruzada, que fornece uma maior consistência às previsões.

Outro fator relevante na construção dos modelos baseados em RNAs está na idéia inicial que, por ser uma técnica puramente matemática, não é preciso levar em conta a teoria intrínseca do problema. Entretanto, no desenrolar do estudo percebeu-se a necessidade do conhecimento básico do problema, principalmente para selecionar, entre os parâmetros disponíveis, quais possuem relevância para contribuir efetivamente para o modelo.

Finalmente, o bom desempenho apresentado pelos modelos sugere a aplicação de RNAs para a previsão de parâmetros de água subterrânea como método alternativo à modelagem convencional. Mesmo assim, recomenda-se a inclusão de novas séries de dados para o preenchimento de lacunas e otimização dos resultados, tais como a atualização regular dos dados de treinamento, para que o modelo possa acompanhar a variação do aquífero ao longo dos anos.

9 REFERÊNCIAS

ADELOYE, Adabayo J.; MUNARI, Annalisa de. Artificial neural network based generalized storage-yield-reliability models using the Levenberg-Marquardt algorithm. **Journal of Hydrology**, article in press, p.1-16, 2005.

ADELOYE, Adabayo J.; LALLEMAND, F., MCMAHON, T.A. Regression models for within-year capacity adjustment in reservoir planning. **Hydrological Sciences Journal**, v. 48, n. 4, p. 539-552, 2003.

ANDRADE, Andréia Faria; CENTENO, Jorge Antonio Silva. Integração de informações espectrais e de forma na classificação de imagens com redes neurais. **Boletim Ciências Geoidais**, Curitiba, v. 9, n. 2, p. 217-231, jul./dez. 2003.

BACA, J. F. M. Redes Neurais Artificiais (RNA) aplicadas na modelagem numérica do terreno. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 20., Porto Alegre. **Anais**. Porto Alegre: IBGE, 2001.

BALKHAIR, Khaled. Aquifer parameters determination for large diameter wells using neural network approach. **Journal of Hydrology**, v. 265, p. 118-128, 2002.

BIZZI, Luiz; SCHOBENHAUS, Carlos; VIDOTTI, Roberta; GONÇALVES, João. **Geologia, tectônica e recursos minerais do Brasil**: Texto, mapas e SIG. Brasília: CPRM – Serviço Geológico do Brasil, 2003, 692p.

BRAGA, Antônio de Pádua; CARVALHO, André Carlos LUDERMIR, Teresa Bernarda. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: 11^a Escola de Computação, Universidade Federal do Rio de Janeiro, 1998.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda; CARVALHO, André Carlos. **Redes Neurais Artificiais**: Teoria e aplicações. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000, 262p.

CABRAL, Jaime; DEMÉTRIO, José Geilson Alves. Aplicação de Modelos em Hidrogeologia. In: FEITOSA, Fernando; MANOEL FILHO, João. **Hidrogeologia: Conceitos e aplicações**. Fortaleza: CPRM, 1997, p. 367-390.

CAPUCCI, Egmont; MARTINS, Anderson Marques; MANSUR, Kátia Leite; MONSORES, André Luiz Mussel. **Poços tubulares e outras captações de águas subterrâneas: orientação aos usuários**. Rio de Janeiro: Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável, 2001. Disponível em: <http://www.drm.rj.gov.br/download/Pocos_tubulares.pdf>. Acesso em: 7 mar. 2007.

CHEN, Jieyun; ADAMS, Barry. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. **Journal of Hydrology**, v. 318, p. 232-249, 2006.

CINTRA, E.C. **Aplicação de redes neurais no controle de teores de cobre e ouro do depósito de Chapada (GO)**. 2003. 151 f. Tese (Doutorado em Geologia Regional) - Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista. Rio Claro, 2003.

CORREIA, G.N. **Classificação de geofones utilizando redes neurais artificiais**. 2005. 45 f. Monografia (Graduação em Ciência da Computação) - Departamento de Matemática, Universidade Federal da Bahia. Salvador, 2005

DALIAKOPOULOS, Ioannis; COULIBALY, Paulin; TSANIS, Ioannis. Groundwater level forecasting using artificial neural networks. **Journal of Hydrology**, v. 309, p. 229-240, 2005.

DEUTSCH, C.V.; JOURNEL, A.G. **GSLIB: Geostatistical software library and user's guide**. New York: Oxford University Press, 1992, 339 p.

ESPINHOSA, Maria Cristina. **Utilização de sensoriamento remoto orbital e redes neurais artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios**. 2004. 112 f. Dissertação (Mestrado em Ciências Cartográficas) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista. Presidente Prudente, 2004.

FACCINI, Ubiratan Ferruccio; GIARDIN, Arnaldo; MACHADO, José Luiz Flores. Heterogeneidades litofaciológicas e hidroestratigrafia do Sistema Aquífero Guarani na região central do estado do Rio Grande do Sul. In: PAIM, Paulo Sergio Gomes; FACCINI, Ubiratan Ferruccio; NETTO, Renata

Guimarães. **Geometria, arquitetura e heterogeneidades de corpos sedimentares**: estudo de casos. São Leopoldo: Unisinos, 2003

FEPAM. **Bacia Hidrográfica do Rio Cai**: 2007. Disponível em: <<http://www.fepam.rs.gov.br>> Acesso em: 21 nov. 2007.

FERREIRA, Niraldo Roberto; PORSANI, Milton. Aplicação das redes neurais artificiais na inversão de sondagem elétrica vertical. In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA, 5., São Paulo. **Anais**. São Paulo: SBGf, 1997.

FLECK, Ernesto Marchioni; PEDREIRA, Carlos Eduardo; SANTOS, Rogério. Agrupamento de dados sísmicos através do algoritmo de Kohonen. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 6., São Paulo. **Anais**. São Paulo, 2003.

FREIRE, Cleuda Custódio; PEREIRA, Jaildo Santos; Kirchhein, ROBERTO; Ribeiro, Márcia Maria; LANNA, Antônio Eduardo. Aspectos legais da gestão dos recursos hídricos subterrâneos no Brasil. In: SIMPOSIO DE RECURSOS HIDRICOS DEL CONOSUR, 2., 1998. **Anais**. Santa Fé, Argentina: Instituto Nacional del Agua y del Ambiente, 1998.

GALO, M.L.B.T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo**. 2005. 205 f. Tese (Doutorado em Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2005.

GALVÃO, Wougran Soares; MENESES, Paulo Roberto. Geração de mapa de potencial à locação de estações na bacia do rio São Francisco como um produto estratégico de apoio às ações de planejamento de redes fluviométricas, através do uso e do classificador neural supervisionado. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., Goiânia. **Anais**. Goiânia: INPE, 2005.

GARCIA, Luis; SHIGIDI, Abdalla. Using neural networks for parameter estimation in ground water. **Journal of Hydrology**, v. 318, p. 215-231, 2006.

GARTNER, Leslie; HIATT, James. **Tratado de Histologia**. Rio de Janeiro: Editora Guanabara-Koogan, 1999. 425p.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. Porto Alegre: Editora Bookman, 2001. 900p.

HERNANDEZ-PAJARES, Manuel; JUAN, Jose Miguel; SANZ, Jaime. Neural network modeling of the ionospheric electron content at global scale using GPS data. **Radio Science**, v. 32, n. 3, p. 1081-1089. 1997.

JIA, Yanbing; CULVER, Teresa. Bootstrapped artificial neural networks for synthetic flow generation with a small data sample. **Journal of Hydrology**, article in press, p. 1-11. 2006.

LALLAHEM, Sami; MANIA, Jacky; HANI, A.; NAJJAR, Y. On the use of neural networks to evaluate groundwater levels in fractured media. **Journal of Hydrology**, v. 307, p. 92-111. 2005.

LEANDRO, Rodrigo F. A new technique to TEC regional modeling using a neural network. In: PROCEEDINGS OF THE ION GNSS, Long Beach. **Anais**. Long Beach: 2004.

LIN, Gwo-Fong; CHEN, Guo-Rong. Determination of aquifer parameters using radial basis function network approach. **Journal of the Chinese Institute of Engineers**, v. 28, n. 2, p. 241-249. 2005.

LIN, Gwo-Fong; CHEN, Guo-Rong. An improved neural network approach to the determination of aquifer parameters. **Journal of Hydrology**, v. 316, p. 281-289. 2006.

MACHADO, José Luiz Flores; FREITAS, Marcos Alexandre. **Mapa hidrogeológico do Rio Grande do Sul**. Porto Alegre: CPRM, 2005. 61p.

MAIA, T.C.B. **Utilização de redes neurais artificiais na determinação de modelos geoidais**. 2003. 130 f. Tese (Doutorado em Engenharia de Transportes) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2003.

MARACAJÁ, J.R.A. **Previsão de vazão sazonal utilizando redes neurais artificiais**. 2005. 120 f. Dissertação (Mestrado em Engenharia de Recursos Hídricos) - Programa de Pós-graduação em Engenharia Civil e Ambiental, Universidade Federal de Campina Grande. Campina Grande, 2005.

MIRLEAN, Nicolai; MACHADO, Maria Isabel; OSINALDI, Guilherme Martinez; DEMOLINER, Adriana; BAISCH, Paulo. O impacto industrial na composição química das águas subterrâneas com enfoque de consumo humano, Rio Grande, RS. **Química Nova**, v. 28, n. 5, p. 788-791. 2005.

MÜLLER, Maurício; FILL, Heinz Dieter. Redes Neurais aplicadas na propagação de vazões. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15., Curitiba. **Anais**. Curitiba: ABRH, 2003.

NAYAK, Purna; SATYAJI RAO, Y. R.; SUDHEER, K. P. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. **Water Resources Management**, v. 20, p. 77-90. 2006.

NÓBREGA, Rodrigo Parreira; SOUZA FILHO, Carlos Roberto. Análise espacial guiado pelos dados (data-driven): o uso de redes neurais para avaliação do potencial poli-minerálico na região centro-leste da Bahia. **Revista Brasileira de Geociências**, v. 33, n. 2, p. 111-120. 2003.

PEIXINHO, Frederico Cláudio; OLIVEIRA, José Emílio Carvalho. **Sistema de Informações de Águas Subterrâneas - SIAGAS**: as suas funcionalidades e importância no contexto das políticas públicas. Disponível em: <http://www.cprm.gov.br/publique/media/siagas_pub.pdf>. Acesso em: 12 abr 2007.

RAO, Zheng-fu; JAMIESON, Derek. The use of neural networks and genetic algorithms for design of groundwater remediation schemes. **Hydrology and Earth System Sciences**, v. 1, n. 2, p. 345-356. 1997.

REBOUÇAS, Aldo Cunha. A política nacional de recursos hídricos e as águas subterrâneas. **Revista Águas Subterrâneas**, v. 16, p. 95-107. 2002.

RIBEIRO, Selma Regina Aranha; CENTENO, Jorge Silva. Classificação do uso do solo utilizando redes neurais e algoritmo MAXVER. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 5., Foz do Iguaçu. **Anais**. Foz do Iguaçu: INPE - SELPER, 2001.

ROHN, Márian da Costa; MINE, Miriam Rita Moro. Uma aplicação das redes neurais artificiais à previsão de chuvas de curtíssimo prazo. In: SIMPÓSIO

BRASILEIRO DE RECURSOS HÍDRICOS, 15., Curitiba. **Anais**. Curitiba: ABRH, 2003.

RUBINI, B.R. **Desenvolvimento de modelos matemáticos para uma planta de deslignificação de polpa celulásica com oxigênio**. 2006. 152 f. Dissertação (Mestrado em Engenharia Química) – Programa de Pós-graduação em Engenharia, Universidade Federal do Paraná. Curitiba, 2006

SAGGIORO, N.J.; SILVA, I.N; CAGNON, J.A. Análise do comportamento de aquíferos em poços profundos utilizando-se de redes neurais artificiais. In: CONGRESSO INTERAMERICANO DE ENGENHARIA SANITÁRIA E AMBIENTAL, 27., Porto Alegre. **Anais**. Porto Alegre: ABES, 2000.

SAHOO, Goloka Behary; RAY, Chittaranjan. Flow forecasting for a Hawaii stream using rating curves and neural networks. **Journal of Hydrology**, v. 317, p. 63-80. 2006.

SAMANI, Nozar; GOHARI-MOGHADAM, Mohammad; SAFAVI, Aliakbar. A simple neural network model for the determination of aquifer parameters. **Journal of Hydrology**, v. 340, p. 1-11. 2007.

SEMA. **Relatório Anual sobre a situação dos recursos hídricos no estado do Rio Grande do Sul**: 2006. Disponível em: <<http://www.sema.rs.gov.br/sema/html/pdf/modulo1.pdf>> Acesso em: 4 set. 2007.

SENA, Marcelo; POPPI, Ronei; FRIGUETTO, Rosa; VALARINI, Pedro. Avaliação do uso de métodos quimiométricos em análise de solos. **Química Nova**, v. 23, n. 4, p. 547-556. 2000.

SIAGAS. **Sistema de Informação de Águas Subterrâneas**. Disponível em: <<http://siagas.cprm.gov.br>>. Acesso em: 20 mar. 2006.

SILVA, Antonio; RAMOS, Rui; SOUZA, Léa; RODRIGUES, Daniel; MENDES, José. **SIG – Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes**: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, redes neurais artificiais. São Carlos: Editora dos Autores, 2004. 221p.

SILVA, C.A.U. **Um Método para Estimar Observáveis GPS Usando Redes Neurais Artificiais**. 2003. 128f. Tese (Doutorado em Engenharia Civil: Transportes) - Escola de Engenharia de São Carlos da Universidade de São Paulo, 2003.

TAFNER, Malcon Anderson; XEREZ, Marcos; RODRIGUES FILHO, Iلسon.
Redes neurais artificiais: introdução e princípios de neurocomputação.
Blumenau: Editora Eko, 1996. 199p.

TUCCI, Carlos Eduardo Morelli. **Modelos Hidrológicos.** Porto Alegre: Editora da Universidade, 1998. 669p.

VALIM A. **Utilização de redes neurais e espectro-colorimetria na classificação das tipologias minerais e na previsão da alvura final de caulins da jazida Morro do Felipe (AP).** 1998. 90f. Dissertação (Mestrado em Engenharia de Minas, Metalúrgica e de Materiais) - Universidade Federal do Rio Grande do Sul. Porto Alegre, 1998.

VERONEZ, Maurício Roberto; VALLES, Telmo; THUM, Adriane. Artificial Neural Networks applied in the determination of soil surface temperatura - SST. In: PROCEEDINGS OF THE ACCURACY, 7., Lisboa. **Anais.** Lisboa: Instituto Geográfico Português, 2006.

VERONEZ, Maurício Roberto; THUM, Adriane; SOUZA, Genival Córrea. A new method for obtaining geoidal undulations through artificial neural networks. In: SPATIAL ACCURACY ASSESMENT IN NATURAL RESOURCES AND ENVIROMENTAL SCIENCES, 7., Lisboa. **Anais.** Lisboa: Instituto Geográfico Português, 2006.

WANDRESEN, Romualdo; MITISHITA, Edson; ANDRADE, José Bittencourt. Identificação de pontos de apoio pré-sinalizados com o uso de redes neurais artificiais e correlação. **Boletim Ciências Geoidais**, Curitiba, v. 9, n. 2, p.179-198. 2003.