

FERNANDO WEIGERT MACHADO

**MODELAGEM CHUVA-VAZÃO MENSAL UTILIZANDO
REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada como requisito parcial
à obtenção do grau de Mestre no Programa de
Pós-Graduação em Engenharia de Recursos
Hídricos e Ambiental, área de concentração
Engenharia Hidrológica, Setor de Tecnologia,
Universidade Federal do Paraná.

Orientadora: Prof. ^a Miriam Rita Moro Mine

Co-orientador: Prof. Eloy Kaviski

CURITIBA

2005

FERNANDO WEIGERT MACHADO

**MODELAGEM CHUVA-VAZÃO MENSAL UTILIZANDO
REDES NEURAIS ARTIFICIAIS**

**Dissertação apresentada como requisito parcial
à obtenção do grau de Mestre no Programa de
Pós-Graduação em Engenharia de Recursos
Hídricos e Ambiental, área de concentração
Engenharia Hidrológica, Setor de Tecnologia,
Universidade Federal do Paraná.**

Orientadora: Prof. ^a Miriam Rita Moro Mine

Co-orientador: Prof. Eloy Kaviski

CURITIBA

2005

Em memória de meu pai,
Roosevelt Gomes Machado, de
minha avó, Clara Gomes
Machado e pela coragem e
força de minha mãe, Hilda
Maria Weigert Machado.

AGRADECIMENTOS

À minha família, meus pais, Roosevelt Gomes Machado, *in memorian*, Hilda Maria Weigert Machado e meus irmãos Alexandre Weigert Machado, Éder Weigert Machado e Ricardo Weigert Machado, o berço de todos os meus conhecimentos mais valiosos;

À Silvia Fabiane Niwa, pelo companheirismo;

A Waldomiro Teixeira Weigert, Ady Pithan, Izabel Cristina Weigert, Evelyn Buske, Arthur Buske Machado;

À minha orientadora Dr^a Miriam Rita Moro Mine, pela oportunidade de trabalho;

Ao meu co-orientador Msc. Eloy Kaviski, pela colaboração no desenvolvimento desta pesquisa;

A Dalton Lúcio Brasil Perreira Filho e Irani dos Santos, pelas sugestões, pela colaboração no fornecimento de dados e desenvolvimentos de figuras;

Ao professor Dr. Heinz Dieter O. A. Fill, pela colaboração na publicação desta pesquisa, corrigindo e traduzindo alguns textos;

À Mara Bufrem Bossan Senna, pela ajuda na busca das referências bibliográficas;

Ao meu colega Ricardo Krauskopf Neto, exemplo de ética e vontade de mudar;

Aos colegas do dia a dia acadêmico, César Jhojy Yoshizawa, Cristiane Lourencetti

Burmester, Diego Baptista de Souza, Fábio Kazu Inoue, Josete de Fátima de Sá, Juliana Seixas Pilotto, Márcia Regina Chella, Marcos Vinícius Adriolo, Nicolas Lopardo, Rafael de Souza Favoreto, Rinaldo César de Carvalho, Simone Canfield Borgo e Sérgio Michelotto Braga, pelo incentivo;

À Cláudia Marília Lisicki e Helena Maria de Freitas, do DHS, pela alegria e boa vontade em ajudar.

Ao Conselho Nacional de Desenvolvimento e Pesquisa, CNPq, pelo apoio financeiro durante o desenvolvimento desta pesquisa.

Aos meus verdadeiros amigos.

SUMÁRIO

LISTA DE TABELAS	viii
LISTA DE FIGURAS	ix
LISTA DE SIGLAS	x
LISTA DE SÍMBOLOS	x
RESUMO	xiii
ABSTRACT	xiv
1.INTRODUÇÃO	1
1.1 GENERALIDADES	1
1.2 OBJETIVOS	3
1.3 ESTRUTURA DO TRABALHO	3
2. REVISÃO BIBLIOGRÁFICA	6
3. CONCEITOS GERAIS SOBRE MODELOS HIDROLÓGICOS	11
3.1 CICLO HIDROLÓGICO	11
3.1.1 Precipitação	14
3.1.2 Interceptação	16
3.1.3 Evaporação e Evapotranspiração	17
3.1.4 Infiltração	19
3.1.5 Escoamento superficial e subterrâneo	21
3.2 MODELAGEM	23
3.2.1 Introdução	23
3.2.2 Desenvolvimento de modelos	24
3.2.3 Classificação	26
3.3 MODELOS CHUVA-VAZÃO	28
3.3.1 Histórico	29
3.3.2 Aspectos gerais	31

4. REDES NEURAIS ARTIFICIAIS - RNA	34
4.1 INTRODUÇÃO	34
4.2 HISTÓRICO	36
4.3 NEURÔNIO ARTIFICIAL	37
4.4 FUNÇÃO DE TRANSFERÊNCIA	39
4.5 RNA DO TIPO <i>PERCEPTRON</i>	39
4.6 OUTROS TIPOS DE RNA	42
4.7 RNA DO TIPO <i>PERCEPTRON</i> MULTICAMADAS (MLP)	44
4.8 AJUSTES DOS PESOS	48
4.9 ALGORITMO <i>BACKPROPAGATION</i>	52
4.10 ALGORITMO <i>LEVENBERG MAQUARDT</i>	61
4.11 PRECAUÇÕES PARA UMA RNA DO TIPO MLP	63
4.11.1 Arquitetura	63
4.11.2 <i>Epochs</i>	64
4.11.3 Inicialização dos pesos	66
4.11.4 Normalização	67
5. MODELO IPHMEN	70
6. ESTUDO DE CASO	77
6.1 BACIA HIDROGRÁFICA	77
6.2 DADOS	80
6.2.1 Precipitação média	80
6.2.2 Evapotranspiração potencial	83
6.2.3 Vazão	84
7. APLICAÇÃO DOS MODELOS	86
7.1 REDES NEURAIS ARTIFICIAIS – RNA	87
7.1.1 Modelos propostos	87
7.1.2 Treinamento	89
7.2 IPHMEN	94

8. RESULTADOS E DISCUSSÕES	97
8.1 REDES NEURAIS ARTIFICIAIS - RNA.....	97
8.1.1 Análises específicas	102
8.1.2 Resultados	108
8.2 IPHMEN	111
8.3 CONFRONTO DOS RESULTADOS	114
9. CONCLUSÕES E RECOMENDAÇÕES	121
REFERÊNCIAS	125
APÊNDICES	129

LISTA DE TABELAS

TABELA 3.1 - CAPACIDADE MÁXIMA DO RESERVATÓRIO DE INTERCEPTAÇÃO.....	16
TABELA 3.2 - EXEMPLOS DE MODELOS	23
TABELA 4.1 - RELAÇÃO ENTRE OS TERMOS USADOS EM RNA E ESTATÍSTICA	46
TABELA 6.1 - COEFICIENTES DE <i>THIESSEN</i>	82
TABELA 7.1 - MODELOS PROPOSTOS.....	88
TABELA 7.2 - PARÂMETROS AJUSTADOS DO MODELO IPHMEN	96
TABELA 8.1 - MODELOS SELECIONADOS NA INCIALIZAÇÃO A	99
TABELA 8.2 - MODELOS SELECIONADOS NA INCIALIZAÇÃO B.....	99
TABELA 8.3 - MODELOS SELECIONADOS NA INCIALIZAÇÃO C.....	100
TABELA 8.4 - MODELOS SELECIONADOS NA INCIALIZAÇÃO D	100
TABELA 8.5 - MODELOS SELECIONADOS NA INCIALIZAÇÃO E.....	101
TABELA 8.6 - MODELOS SELECIONADOS NA INCIALIZAÇÃO F.....	101
TABELA 8.7 - NÚMERO DE PESOS E <i>VIESES</i> DAS RNA	105
TABELA 8.8 -FRÊNUENCIA DOS MELHORES RESULTADOS EM FUNÇÃO DO NÚMERO DE PESOS <i>VIESES</i> E O NÚMERO DE <i>EPOCHS</i>	105
TABELA 8.9 - INFLUÊNCIA DA INICIALIZAÇÃO NO TREINAMENTO DAS RNA	106
TABELA 8.10 INFLUÊNCIA DA INICIALIZAÇÃO NA DETERMINAÇÃO DO MELHOR MODELO PARA CADA CONJUNTO DE ENTRADA.....	107
TABELA 8.11-RESUMO DOS RESULTADOS NO TREINAMENTO DAS RNA E CALIBRAÇÃO DO MODELO IPHMEN.....	115
TABELA 8.12-RESUMO DOS RESULTADOS NA VALIDAÇÃO	115

LISTA DE FIGURAS

FIGURA 3.1 - CICLO HIDROLÓGICO	11
FIGURA 3.2 - TIPOS DE CHUVAS	15
FIGURA 3.3 - APARELHOS DE MONITORAMENTO DA PRECIPITAÇÃO	15
FIGURA 3.4 - HIDROGRAMA DE CHEIA.....	21
FIGURA 3.5 - REPRESENTAÇÃO ESQUEMÁTICA DE UM MODELO GERAL.....	23
FIGURA 3.6 - ETAPAS DO PROCESSO DE MODELAGEM.....	24
FIGURA 4.1 - CÉREBRO HUMANO	34
FIGURA 4.2 - NEURÔNIO BIOLÓGICO	35
FIGURA 4.3 - NEURÔNIO ARTIFICIAL.....	37
FIGURA 4.4 - FUNÇÕES DE TRANSFERÊNCIA	40
FIGURA 4.5 - <i>PERCEPTRON</i>	41
FIGURA 4.6 - RNA DE <i>HOPFIELD</i> E <i>RUMMELHART</i>	43
FIGURA 4.7 - REPRESENTAÇÃO DETALHADA DE UMA REDE DO TIPO MLP	45
FIGURA 4.8 - AJUSTE DOS MÍNIMOS QUADRADOS NÃO-LINEARES.....	47
FIGURA 4.9 - REPRESENTAÇÃO GRÁFICA DE UM PROBLEMA DE OTIMIZAÇÃO	49
FIGURA 4.10- FLUXO DE DADOS DE UMA RNA EM <i>FOWARD</i>	59
FIGURA 4.11- FLUXO DE DADOS DE UMA RNA EM <i>BACKWARD</i>	60
FIGURA 4.12- GENERALIZAÇÃO DAS RNA.....	65
FIGURA 6.1 - BACIA DO RIO JANGADA	77
FIGURA 6.2 - ESTAÇÕES HIDROMÉTRICAS	79
FIGURA 6.3 - PERÍODOS EXISTENTES DAS SÉRIES HIDROLÓGICAS.....	79
FIGURA 6.4 - CURVA DUPLA-ACUMULATIVA.....	81
FIGURA 6.5 - POLÍGONO DE <i>THIESSEN</i>	82
FIGURA 6.6 - EVAPOTRANSPIRAÇÃO POTENCIAL	84
FIGURA 6.7 - HIDROGRAMA DE CHEIA.....	85
FIGURA 7.1 - MÉTODO DE TREINAMENTO.....	92
FIGURA 8.1 - FREQUÊNCIA DO NÚMERO DE <i>EPOCHS</i> ENTRE OS MODELOS SELECIONADOS.....	102
FIGURA 8.2 - FREQUÊNCIA DO NÚMERO DE <i>EPOCHS</i> ENTRE OS MODELOS SELECIONADOS CONSIDERADOS OS DIFERENTES CONJUNTOS DE ENTRADA.....	104
FIGURA 8.3 - MELHOR RESULTADO PARA A ENTRADA 1 (RNA).....	109
FIGURA 8.4 - MELHOR RESULTADO PARA A ENTRADA 2 (RNA).....	110
FIGURA 8.5 - MELHOR RESULTADO PARA A ENTRADA 3 (RNA).....	111
FIGURA 8.6 - RESULTADO PARA A ENTRADA 1 (IPHEMEN)	112
FIGURA 8.7 - RESULTADO PARA A ENTRADA 2 (IPHEMEN)	113
FIGURA 8.8 - RESULTADO PARA A ENTRADA 3 (IPHEMEN)	114
FIGURA 8.9 - CURVA DE PERMANÊNCIA PARA A ENTRADA 1	116
FIGURA 8.10 -CURVA DE PERMANÊNCIA PARA A ENTRADA 2	117
FIGURA 8.11 -CURVA DE PERMANÊNCIA PARA A ENTRADA 3	119

LISTA DE SIGLAS

ARQ - ARQUITETURA
LMS – *LEAST MEAN-SQUARE*
MLP – *MULTILAYER PERCEPTRON*
MOD – MODELO
RNA – REDES NEURAIS ARTIFICIAIS
RMSE – *ROOT MEAN SQUARE ERROR*

LISTA DE SÍMBOLOS

α - coeficiente da evapotranspiração real
 β - fator de correção do parâmetro μ no algoritmo de otimização Levenberg Maquardt
 Δ - declividade da curva de pressão de vapor
 Δw_{ji} - variação do valor do peso na conexão ij proporcional ao erro na iteração (n)
 Δt - variação do tempo
 $\nabla \varepsilon$ - gradiente da função objetivo.
 δ - gradiente descendente
 ε - função objetivo
 γ - constante psicrométrica
 η - taxa de aprendizado
 φ - função de transferência
 λ_n - escalar positivo que determina o passo no sentido do ponto mínimo para o método do maior gradiente
 λ_n^* - escalar positivo que maximiza a função objetivo no método do maior gradiente
 μ - parâmetro do algoritmo de otimização Levenberg Maquardt
 a - parâmetro do modelo IPHMEN relacionado a equação de Horton
 a_i - termo independente da reta que relaciona $S(t)$ e $I(t)$ no modelo IPHMEN
 b_i - coeficiente angular da reta que relaciona $S(t)$ e $I(t)$ no modelo IPHMEN
 b_t - coeficiente angular da reta que relaciona $S(t)$ e $T(t)$ no modelo IPHMEN
 b - parâmetro do modelo IPHMEN relacionado a equação de Horton
 b - viés ou ruído aleatório
 b_j - viés do neurônio j
 b_k - viés do neurônio k
 c - parâmetro do modelo IPHMEN relacionado a equação de Horton
 Cr - fator de escoamento superficial no modelo IPHMEN
 d - elemento do vetor $\mathbf{D}$ das saídas desejadas
 d_{Nk} - elemento N do vetor $\mathbf{D}$ das saídas no neurônio k na camada de saída
 d - variável auxiliar na linearização da equação da evapotranspiração real no modelo IPHMEN
 $\mathbf{D}$ - vetor das saídas desejadas
DV - diferença de volumes observados e calculados
 e - erro entre valores calculados e desejados na saída da rede neural artificial
 e_{Nk} - erro para as entradas de número N no neurônio k na camada de saída
 e - variável auxiliar na linearização da equação da evapotranspiração real no modelo IPHMEN
 E - evapotranspiração real
 E_a - termo do balanço aerodinâmico
EV - evaporação potencial
EVT - evapotranspiração potencial
EVT(t) - evapotranspiração potencial no tempo t , mês corrente
EVT($t-1$) - evapotranspiração potencial no tempo $t-1$, um mês anterior
EVT($t-2$) - evapotranspiração potencial no tempo $t-2$, dois meses anteriores
FMAX - valor máximo na escala normalizada

F_{MIN} – valor mínimo na escala normalizada
 h - parâmetro da equação de Horton em função do tipo de solo calculado a partir de k
 H - termo de balanço de energia ou radiação útil
 $\mathbf{H}$ - matriz hessiana
 i - neurônio i da camada de entrada
 $\mathbf{I}$ - matriz identidade
 I - infiltração
 $I(t)$ - taxa de infiltração no tempo t
 I_b - taxa de infiltração mínima
 I_o - taxa de infiltração inicial
 j – neurônio j da camada intermediária
 $\mathbf{J}$ - matriz Jacobiana
 $\mathbf{J}^T$ – transposta da matriz Jacobiana
 k - parâmetro de decaimento das taxas de infiltração função do tipo de solo
 k – neurônio k da camada de saída
 K_b - tempo de variação do reservatório subterrâneo
 K_s - coeficiente de propagação superficial
 p - número de neurônios na camada de entrada
 P - precipitação média mensal
 P_i - parcela da precipitação infiltrada calculada pelo modelo IPHMEN
 $P(t)$ - precipitação média mensal no tempo t , mês corrente
 $P(t-1)$ - precipitação média mensal no tempo $t-1$, um mês anterior
 $P(t-2)$ - precipitação média mensal no tempo $t-2$, dois meses anteriores
 q - número de neurônios na camada intermediária
 Q_o – escoamento superficial observado
 Q_c – escoamento superficial calculado
 Q_b - escoamento de base calculado pelo modelo IPHMEN
 Q_s - escoamento superficial calculado pelo modelo IPHMEN
 $Q(t)$ – escoamento superficial calculado pela rede neural artificial e pelo modelo IPHMEN
 $Q(t-1)$ - escoamento superficial observado no tempo $t-1$, um mês anterior
 $Q(t-2)$ – escoamento superficial observado no tempo $t-2$, dois meses anteriores
 m – termo independente da equação diferencial que relaciona o armazenamento S ao longo do tempo t
 n – número ‘ n ’ da iteração de ajuste dos pesos e vieses das redes neurais artificiais.
 N – número de linhas da matriz $\mathbf{X}$ e do vetor $\mathbf{D}$
 S - armazenamento do solo
 S_0 – teor de umidade inicial
 $S(t)$ – armazenamento do solo num tempo t determinado
 S_{MAX} - armazenamento máximo do solo
 r – variável da equação diferencial que relaciona o armazenamento S ao longo do tempo t no modelo IPHMEN
 t - tempo
 $T(t)$ – Percolação
 u_j - combinação linear das entradas no neurônio j
 u_k - combinação linear das entradas no neurônio k
 v_j – soma da combinação linear u_j e b_j
 v_k – soma da combinação linear u_k e b_k
 V_i – volume infiltrado calculado pelo modelo IPHMEN
 V_p – volume percolado calculado pelo modelo IPHMEN
 V_s – volume escoado superficialmente calculado pelo modelo IPHMEN
 x – entrada das redes neurais artificiais
 x_{Ni} - elemento N , entrada i de p da matriz de entradas $\mathbf{X}$
 x_{norm} - valor normalizado do elemento x_{Ni} da matriz de entradas $\mathbf{X}$
 x_{max} - valor máximo de x_{Ni} na matriz de entradas $\mathbf{X}$
 x_{min} – valor mínimo de x_{Ni} na matriz de entradas $\mathbf{X}$
 $\mathbf{X}$ – matriz das entradas
 $\mathbf{x}_N$ - vetor linha com p elementos da matriz de entradas $\mathbf{X}$
 w – peso nas redes neurais artificiais
 $w_{ji}(n)$ - valor antigo do peso na conexão ij na iteração (n)

$w_{ji}(n+1)$ - valor do peso corrigido na conexão ij na iteração $(n+1)$
 w_{ji} - peso na conexão ji entre o neurônio i da camada de entrada e o neurônio j da camada intermediária
 w_{kj} - peso na conexão kj entre o neurônio j da camada intermediária e o neurônio k da camada de saída
 $\mathbf{W}$ - vetor dos pesos
 $\mathbf{W}_0$ - vetor com valor dos pesos iniciais
 $\mathbf{W}_n$ - vetor dos pesos antigos
 $\mathbf{W}_{n+1}$ - vetor dos pesos corrigidos
 $\mathbf{W}^*$ - vetor dos pesos ótimos
 y – saída das redes neurais artificiais.
 y_{Nj} - saída ou valor calculado pela rede neural artificial na camada j para a entrada $\overline{\mathbf{X}}_N$
 y_{Nk} - saída ou valor calculado pela rede neural artificial na camada k para a entrada $\overline{\mathbf{X}}_N$

RESUMO

Avaliar de maneira precisa o processo de transformação de chuva em vazão é importante para um melhor gerenciamento dos recursos hídricos. Para tal podem ser utilizados modelos chuva-vazão. Modelos que simulam o ciclo hidrológico descrevendo matematicamente suas diversas fases são ditos modelos conceituais. Estes modelos apresentam bons resultados, no entanto, a calibragem dos parâmetros é demorada e subjetiva e em certos casos são dependentes de levantamento de dados em campo. Uma alternativa aos modelos conceituais são modelos empíricos que relacionam entrada e saída através de uma função matemática sem relação com as características físicas do processo chuva-vazão. O objetivo desta pesquisa foi modelar a relação entre chuva e vazão através de uma técnica conhecida por redes neurais artificiais (RNA). As RNA são modelos empíricos com funcionamento semelhante ao funcionamento do cérebro humano. Nesta pesquisa foi avaliada a capacidade das RNA modelarem o processo chuva-vazão em base mensal. Foi considerado durante o treinamento das RNA as influências da arquitetura da rede, do número de *epochs* (épocas), da inicialização dos pesos e da extensão das séries de dados. Foi desenvolvido um algoritmo computacional que ao final do processo de treinamento gerou 1296 resultados. As três RNA que produziram os melhores resultados foram confrontados com os resultados do modelo conceitual IPHMEN. Os resultados foram muito satisfatórios.

Palavra-chave: Redes Neurais Artificiais, modelos chuva-vazão.

ABSTRACT

The precise evaluation of the rainfall-runoff process is an important aspect to improve the water resources management. To perform this task usually rainfall-runoff models are used. One class of these models, called conceptual models, simulate the hydrological cycle using a mathematical description of the main hydrologic processes. These models usually present good results, however often the adjustment of parameters is time consuming and depending on personal judgment. They also depend, in certain cases on additional field data surveys. An alternative to conceptual models are empirical or black-box models which relate input and output by a mathematical function without any relationship with the characteristics of the real rainfall-runoff process. The objective of this research is to establish a rainfall-runoff relationship by means of the artificial neural network (ANN) technique. The ANN are empirical models operating similar to the human brain. In this research the ability of ANN to model the rainfall-runoff process has been analysed on a monthly time step basis. During the training of the ANN the influence of network architecture, the number of epochs, weight initialization and data series length were considered. A computational algorithm which generated 1296 results has been developed. The three ANN that generated the best results were confronted with the results of a conceptual model called IPHMEN. The results were very satisfactory.

Key-words: Artificial Neural Network, rainfall-runoff relationship.

1.INTRODUÇÃO

1.1 GENERALIDADES

A transformação de chuva em vazão é um dos processos mais difíceis de serem entendidos devido ao grande número de variáveis que se modificam no espaço e no tempo. Avaliar este processo com certo grau de precisão é que permite gerenciar de maneira racional os diversos usos da água, como o abastecimento, irrigação, geração de energia e indústria e, além disso, prever eventos extremos de cheias e períodos de estiagem. Geralmente, a avaliação deste processo é realizada através de modelos conhecidos por modelos chuva-vazão.

Os primeiros modelos chuva-vazão surgiram na década de 30. No início estes modelos eram simples e nem sempre eram capazes de considerar os efeitos não lineares inerentes ao problema. Esta situação foi contornada com o advento do computador que, devido à facilidade de trabalhar com grande número de dados num pequeno intervalo de tempo, introduziu uma tendência natural pelo uso de modelos que simulassem o ciclo hidrológico considerando as características não lineares do processo. Esses novos modelos foram denominados de modelos conceituais por considerarem, embora de forma simplificada, os processos físicos que ocorrem na bacia hidrográfica. Precipitação, interceptção, evaporação, infiltração, escoamento superficial e escoamento subterrâneo são os principais processos descritos por esses modelos. Cada um destes processos é avaliado por um algoritmo independente que integrados constituem o modelo chuva-vazão conceitual.

Apesar dos bons resultados obtidos, os modelos conceituais apresentam certos limites em alguns aspectos como, a necessidade de interpretação do algoritmo do modelo, o grande número de parâmetros que devem ser calibrados e a necessidade de levantamento de dados em campo.

Para interpretar um modelo conceitual é necessário conhecer hidrologicamente quais são os principais processos envolvidos no ciclo hidrológico e

como eles são representados matematicamente. Esta análise torna-se mais complexa quando se considera a escala do tempo na modelagem. Devido à necessidade dos órgãos gestores dos recursos hídricos por informações horárias, diárias, semanais e mensais é necessário conhecer como o ciclo hidrológico ocorre nestas escalas do tempo. Um segundo problema na modelagem conceitual encontra-se no grande número de parâmetros dos modelos. A interação entre os parâmetros é muito complexa e o processo de otimização na calibração deve ser acompanhada de um procedimento de ajuste por tentativa e erro. Nestas circunstâncias a qualidade dos resultados obtidos pelos modelos conceituais torna-se muito subjetiva e muito dependente da experiência do usuário em relação ao modelo. O terceiro aspecto é a necessidade de levantamento de dados em campo. Alguns dos parâmetros dos modelos são relacionados com as características físicas da bacia, sendo às vezes necessário o levantamento de dados em campo. Isto faz da calibração dos modelos conceituais um processo demorado e oneroso economicamente.

Uma alternativa aos modelos conceituais são os modelos empíricos ou caixas pretas. Um modelo empírico é definido basicamente por uma equação matemática. A característica principal deste tipo de modelo consiste em estabelecer uma relação estável entre as variáveis de entrada e saída sem considerar neste processo quais as leis físicas que governam o processo natural de transformação da chuva em vazão. Exemplos destes modelos são equações lineares e não lineares multivariáveis, com os parâmetros estimados por mínimos quadrados, e redes neurais artificiais - RNA.

Em recursos hídricos as RNA vêm sendo utilizadas na solução de vários problemas (ASCE, 2000a,b). JAIN et al. (1999) utilizaram RNA na previsão da vazão afluente e operação de reservatórios. NEELAKANTAN e PUNDARIKANTHAN (2000) aplicaram RNA para simulação e otimização da operação de reservatórios. MACHADO et al. (2005) aplicaram RNA no ajuste de curvas de descargas.

Uma RNA é uma estrutura de elementos conhecidos por nós ou neurônios distribuídos espacialmente e que interconectados, matematicamente representam uma função. Há diversos tipos de RNA, as mais conhecidas e utilizadas são as RNA

Multilayer Perceptron – MLP (*Perceptron Multicamadas*). A característica principal destas RNA é ter os neurônios distribuídos em camadas com os dados do modelo se propagando numa única direção. Normalmente as RNA do tipo MLP's apresentam três camadas, uma camada de entrada, uma camada intermediária e uma camada de saída.

Para que uma RNA seja capaz de modelar o processo chuva-vazão, deve ter seus pesos e vieses (ruídos aleatórios) treinados. O processo de treinamento é influenciado pela: i) arquitetura da RNA; ii) número de *epochs*; iii) inicialização dos pesos; iv) extensão das séries de dados.

1.2 OBJETIVOS

O objetivo geral deste trabalho de pesquisa consiste em investigar a modelagem do processo de transformação de chuva em vazão utilizando RNA do tipo MLP e, para avaliar a qualidade destes resultados, confrontar com os resultados de um modelo conceitual.

O objetivo específico desta pesquisa é desenvolver um algoritmo computacional capaz de criar RNA e durante o treinamento considerar simultaneamente a influência da arquitetura da RNA, número de *epochs*, inicialização dos pesos, a extensão das séries de dados e poder concluir como cada uma destes elementos influencia no resultado final.

O estudo de caso foi realizado na bacia hidrográfica do rio Jangada, afluente do rio Iguaçu pela margem esquerda, localizado no estado do Paraná, Brasil e próxima às cidades de União da Vitória (PR) e Porto União (SC).

1.3 ESTRUTURA DO TRABALHO

O segundo capítulo deste trabalho apresenta uma breve revisão bibliográfica da aplicação das RNA na modelagem do processo de chuva-vazão.

O terceiro capítulo apresenta uma revisão geral sobre o ciclo hidrológico e a modelagem hidrológica e tem dois objetivos principais. O primeiro objetivo é

possibilitar ao leitor não especializado em recursos hídricos que venha até este texto em busca de informações sobre RNA, possa compreender a dinâmica do problema proposto. Nestas circunstâncias a leitura deste capítulo pode ser dispensável aos hidrólogos. O segundo objetivo é enfatizar a dificuldade de representar o ciclo hidrológico matematicamente. Cita-se neste capítulo os principais processos do ciclo hidrológico e como estes processos são hidrologicamente mensurados. Citam-se, também, como são desenvolvidos os modelos em geral, as principais classificações, um breve histórico dos modelos chuva-vazão, como estes modelos surgiram, sua aplicação e as principais diferenças.

O quarto e o quinto capítulos também fazem parte da revisão bibliográfica e referem-se respectivamente às redes neurais artificiais - RNA e ao modelo conceitual IPHMEN. Fez-se a opção por esta estrutura devido à extensão dos textos de um e outro modelo e pela necessidade de distinguir com clareza as diferenças entre ambos. O capítulo quatro apresenta uma breve introdução e histórico de como as RNA surgiram e funcionam. O ponto particular deste capítulo é explorar com profundidade como as RNA são representadas matematicamente e quais são os principais elementos que interferem na qualidade dos resultados. O capítulo cinco descreve todo o algoritmo do modelo IPHMEN e explica a função de cada um dos parâmetros do modelo.

O capítulo seis refere-se ao estudo de caso. Neste capítulo são apresentados em detalhe, às características da bacia hidrográfica do rio Jangada e todos os dados utilizados.

O capítulo sete apresenta a aplicação de ambos os modelos, RNA e IPHMEN, na modelagem do processo chuva-vazão para a bacia do rio Jangada. É apresentado neste capítulo como funciona o algoritmo proposto para treinar as RNA considerando arquitetura, número de treinamento, inicialização dos pesos e extensão das séries de dados. É apresentado também como o modelo IPHMEN foi calibrado.

O capítulo oito apresenta todos os resultados obtidos pelas RNA com uma abordagem especial enfatizando qual foi a influência em modificar a arquitetura, treinar as RNA para diferentes números de *epochs*, inicializar os pesos das RNA e

treiná-las com diferentes números de dados. Também são apresentados os resultados do modelo IPHMEN e, por fim, confronta-se os resultados das RNA com os resultados do modelo IPHMEN.

O último capítulo apresenta as conclusões e recomendações para trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

Estudos semelhantes ao aqui apresentado, quanto à aplicação de RNA na modelagem do processo de transformação da chuva em vazão já foram realizados anteriormente.

HSU et al. (1995) utilizaram RNA para modelar a relação entre chuva e vazão diariamente na bacia hidrográfica do rio *Leaf* próximo a *Collins* no *Mississippi*, EUA, uma bacia de médio porte. Neste trabalho os autores analisam um algoritmo de treinamento para as RNA e confrontam os resultados obtidos com os resultados do modelo conceitual Sacramento, SAC-SMA, e modelos estatísticos auto-regressivos tipo ARMAX. Eles analisaram os resultados em termos de parâmetros estatísticos, análises gráficas e de funções de autocorrelação concluído naquela ocasião que as RNA são capazes de representar a relação entre chuva e vazão e que o algoritmo de treinamento analisado se mostrou uma ótima ferramenta no treinamento de RNA. Naquela situação as RNA também apresentaram os menores erros e as menores diferenças de volumes.

ELSHORBAGY et al. (2000) utilizaram RNA na previsão de vazões na bacia hidrográfica do rio *Red River Valley*, no Canadá. Estes autores testaram várias estruturas de RNA e comparam os resultados com outros modelos empíricos, um modelo de regressão linear múltipla e um modelo não linear de regressão múltipla. Para avaliar o desempenho dos modelos os autores ainda propõem uma nova estatística chamada por PMSE. Eles também afirmam que as RNA apresentam os melhores resultados e que os resultados são dependentes da estrutura dos dados de entrada.

ANMALA et al. (2000) fizeram uma comparação semelhante a que ELSHORBAGY et al. (2000). ANMALA et al. (2000) utilizaram RNA *feedforward* e RNA recorrentes com entradas de temperatura e chuva mensal para calcular a vazão média mensal em três bacias hidrográficas no *Kansas*, EUA. Durante o desenvolvimento os autores também analisaram a influência do número de treinamento. Ao final eles concluíram que as RNA recorrentes apresentaram os

melhores resultados entre todos os modelos empíricos e que os bons resultados são obtidos para um número pequeno de iterações no treinamento.

TOKAR e MARKUS. (2000) utilizaram RNA na modelagem do processo chuva-vazão em três bacias hidrográficas nos EUA, bacia do rio *Fraser*, no Colorado, *Raccoon Creek*, em *Iowa* e *Little Patuxent* em *Maryland*. Na bacia do rio *Fraser* os autores confrontaram os resultados obtidos com os resultados do modelo conceitual *WATBAL*, mensal. Em *Raccoon Creek*, confrontaram RNA e o modelo, também conceitual, *SAC-SMA* (Sacramento), diário. No rio *Little Patuxent*, confrontaram os resultados da RNA com o modelo conceitual *SCRR*, também diário. Para todos os casos os resultados das RNA foram mais precisos. As principais entradas utilizadas para as RNA foram chuva, equivalente de neve derretida em água e temperatura.

Observa-se que, em estudos anteriores, as RNA na sua grande maioria vem sendo aplicada a modelagem chuva-vazão de mais curto prazo e que para estes casos vêm apresentando bons resultados.

São poucos os trabalhos com investigação quanto à possibilidade de se utilizar RNA na modelagem de mais longo prazo. LUNGU (apud ANMALA et al., 2000) analisou o processo chuva-vazão em escalas diárias, mensais e anuais na bacia hidrográfica de *Botswana* na África e afirma que a relação chuva-vazão mensal é provavelmente a mais difícil por ter de considerar processos do ciclo hidrológico tanto de curto como de longo prazo.

São poucos os trabalhos que utilizam RNA na modelagem da relação entre chuva e vazão numa escala mensal. SAJIKUMAR e THANDAVESWARA (1999) aplicaram RNA temporais, uma derivação das RNA do tipo MLP, para modelar chuva-vazão mensal e confrontaram os resultados com outros modelos empíricos. ANMALA et al. (2000) utilizaram RNA do tipo MLP e também confrontaram os resultados com modelos empíricos. LIMA e FERREIRA FILHO (2003) apenas utilizaram as RNA na modelagem em escala mensal, mas não confrontaram os resultados com nenhum outro modelo. Não foi encontrado na literatura especializada além de TOKAR e MARKUS. (2000) nenhum trabalho que confrontasse os resultados de uma RNA na modelagem

chuva-vazão mensal com um modelo conceitual do mesmo tipo.

Isto posto, as RNA nesta pesquisa são utilizadas para modelagem do processo chuva-vazão numa escala mensal e os resultados são confrontados com os resultados do modelo conceitual IPHMEN, objetivo geral. O IPHMEN é um modelo de domínio público desenvolvido pelo Instituto de Pesquisas Hidráulicas – IPH da Universidade Federal do Rio Grande do Sul. Este modelo foi aqui escolhido devido ao pequeno número de parâmetros utilizados para calibração, e pela experiência do autor em relação ao modelo adquirida numa oportunidade anterior.

A relação entre chuva e vazão é altamente não linear. HAYKIN (1994) cita que RNA com três camadas são capazes de aproximar qualquer função com características não lineares. Esta mesma conclusão também é apresentada por GALVÃO et al. (1999) e FERNANDES et al. (1996). Isto justifica a tentativa de modelar a relação entre chuva e vazão mensalmente através de RNA.

Para que uma RNA seja capaz de modelar este processo à mesma deve ter seus pesos e vieses calibrados ou, treinados, que é o termo mais apropriado em relação às RNA. Durante este processo alguns cuidados devem ser tomados em relação à arquitetura da RNA, ao número de treinamentos, inicialização dos pesos e a extensão das séries para o treinamento.

A arquitetura é a forma como os neurônios estão distribuídos entre as camadas. É a arquitetura que define a forma funcional da RNA do tipo MLP. Algumas investigações quanto à arquitetura da RNA foram apresentadas por KADOWAKI e ANDRADE (1997), BALLINI et al. (1997), CAMPOLO et al. (1999), TOKAR e JOHNSON (1999), ANMALA et al. (2000), THIRUMALAIAH e DEO (2000) e RAMOS e GALVÃO (2001), LIMA e FERREIRA FILHO (2003) com destaque para os trabalhos de TOKAR e JOHNSON (1999), LIMA e FERREIRA FILHO (2003) e RAMOS e GALVÃO (2001).

TOKAR e JOHNSON (1999) aplicaram RNA na previsão de vazões na bacia hidrográfica do rio *Little Patuxent* em *Maryland*, EUA. As entradas utilizadas para as RNA foram precipitação, temperatura e o equivalente de neve derretida em água. Para

avaliar os resultados fez-se a confronto entre as RNA e os resultados de modelos de regressão e o modelo conceitual SCRR. Os resultados foram confrontados a partir da razão entre o erro padrão e o desvio padrão. As RNA apresentaram os melhores resultados. Durante o estudo os autores avaliaram a arquitetura da RNA e associaram o número de entradas com a extensão das séries de dados sugerindo que o aumento do número de entradas deve ser seguindo de um aumento das extensões das séries de dados para o treinamento.

LIMA e FERREIRA FILHO (2003) aplicaram RNA na modelagem chuva-vazão mensal na bacia hidrográfica do rio Acaraú no semi-árido Cearense, Brasil. Os autores avaliaram várias RNA com diferentes entradas, ditos modelos, e número de neurônios na camada intermediária. Além disso cada RNA foi treinada com números diferentes de dados. Os resultados são muitos satisfatórios com coeficiente de correlação em torno de 93% na validação, no entanto os autores não confrontam estes resultados com os resultados de outro modelo.

RAMOS e GALVÃO (2001) apresentam uma metodologia para determinação da arquitetura das RNA. Nesta metodologia, eles citam a reinicialização de pesos, a mudança em certas funções de transferência e a extensão das séries de dados como elementos importantes.

A extensão das séries de dados também foi avaliada por SAJIKUMAR e THANDAVESWARA (1999). Estes autores aplicaram RNA temporais na modelagem chuva-vazão mensal nas bacias hidrográficas do rio *Lee*, no Reino Unido, e na bacia do rio *Thuthapuzha*, em *Kerala* na Índia e durante o desenvolvimento avaliaram a influência de utilizar séries de dados com diferentes extensões para no treinamento da RNA. Neste trabalho eles ainda confrontaram os resultados obtidos pela RNA com três outros modelos empíricos concluindo, novamente, que os melhores resultados foram obtidos pelas RNA.

O número de treinamentos ou, *epochs*, também o termo mais apropriado para as RNA, é o número de vezes que os pesos e os vieses da RNA são modificados. O principal trabalho quanto à avaliação do número de *epochs* é o trabalho de ANMALA

et al. (2000).

Outro problema no treinamento das RNA é a inicialização dos pesos. Os pesos das RNA ajustados a cada treinamento. Vários autores citam como sendo importante a inicialização dos pesos, no entanto não há nenhuma investigação em especial.

Não foi encontrado na literatura nenhum trabalho que considere no treinamento das RNA, ao mesmo tempo, a influência da arquitetura, o número de *epochs*, a inicialização dos pesos e a extensão das séries de dados no treinamento. Também não há entre os trabalhos estudados nenhuma recomendação em especial da influência destes elementos no treinamento. Estes são os objetivos específicos desta pesquisa.

O oceano é a principal fonte de água para evaporação, aproximadamente 70% do total. A água no oceano evapora devido à energia suprida pela radiação solar. Para evaporar 1g de água a 15 °C são necessários 2470 J de energia (MÜLLER, 1995). A água que evapora dos oceanos assume a forma de vapor e chega até a atmosfera. A atmosfera é o principal responsável pela dinâmica do ciclo hidrológico que transporta as massas de vapor através das correntes aéreas. A maior parte deste processo ocorre numa camada de 8 a 16 Km conhecida por troposfera. Cerca de 90% de toda a umidade atmosférica está localizada nesta camada. Acima da troposfera está situada a estratosfera, com uma espessura entre 40 e 70 km, é onde reside a camada de ozônio, responsável por regular os níveis de radiação solar que chegam até a superfície terrestre. Como esta camada não é homogênea em todo o planeta, algumas regiões recebem mais e outras menos quantidades de energia. A desuniformidade com que a energia solar atinge diversos locais também sofre influência da rotação e eixo de inclinação da Terra, variabilidade dos solos e coberturas vegetais, quantidade de gás carbônico na atmosfera entre outros, o que contribui em muito com a dinâmica da atmosfera.

O vapor de água que chega à troposfera é invisível. As nuvens que se formam nesta camada se tornam visíveis, porque não são formadas apenas pelo vapor de água, mas sim, por microgotículas de água, poeira e dependendo da região e estação do ano, por partículas de gelo que se aglutinam entre si formando o aerossol conhecido por nuvem.

As microgotículas de água, vapor e poeira se mantêm em suspensão dentro das nuvens devido à turbulência natural das correntes de ar que se opõem à força da gravidade. No entanto, o processo de aglutinação dentro das nuvens é intermitente. Ao longo deste processo as partículas crescem. Quando o peso destas partículas for maior que os efeitos de turbulência e as correntes de ar, ocorre a precipitação. A precipitação pode ocorrer, principalmente, na forma de chuva, granizo ou neve.

Durante o processo de precipitação, parte do volume precipitado é vaporado.

Em algumas situações, a precipitação pode ser totalmente vaporizada antes de alcançar a superfície.

Ao alcançar a superfície, parte do volume precipitado ainda é interceptado pela vegetação que retém água. Dependendo das condições de vento, estes volumes podem se reprecipitar para o solo.

No solo, a água poderá infiltrar ou escoar superficialmente. Se a superfície do solo não estiver saturada, então toda precipitação que chega ao solo é infiltrada. Se a precipitação for contínua ocorre que em certo momento deste processo a superfície do solo torna-se saturada e a partir deste momento inicia-se a saturação das camadas mais profundas até que se chegue a uma taxa residual de infiltração e o excesso de precipitação é escoado superficialmente. De toda água que infiltra, parte é absorvida pelas plantas e retorna à atmosfera por transpiração, parte escoa sub-superficialmente e parte é percolada para os lençóis freáticos que contribuem para o escoamento subterrâneo.

Se o solo estiver saturado, então toda a água que chegar até a superfície escoará superficialmente. Este movimento ocorre naturalmente impulsionado pela ação da força da gravidade que movimenta as partículas das cotas mais altas para as cotas mais baixas através de uma rede efêmera de micro drenagem que converge para cursos de água mais estáveis, formados por rios e seus afluentes. A vegetação do solo representa uma resistência ao escoamento superficial. Esta resistência diminui a velocidade do escoamento superficial, aumenta a infiltração ao longo do seu percurso e minimiza os efeitos de erosão.

Toda a água que chega aos rios através do escoamento superficial ou através do escoamento de base é transportada pela rede de drenagem até alcançar novamente os oceanos reiniciando-se o ciclo hidrológico (TUCCI ,1993), (RAMOS et al., 1989) e (RAUDIKIVI, 1979).

O desafio para os modelos chuva-vazão é, conhecendo como o ciclo hidrológico ocorre, obter, principalmente, a partir da precipitação num certo

momento, quais os volumes escoados.


3.1.1 Precipitação

A precipitação é toda a água proveniente da atmosfera que atinge a superfície terrestre. Neblina, granizo, orvalho, geada, neve e chuva são as diferentes formas de precipitação. A diferença principal é a forma com que a água alcança a superfície terrestre. No nosso clima a mais importante destas formas é a chuva. Conhecer como a chuva ocorre é de fundamental importância para o gerenciamento de uma bacia hidrográfica.

As chuvas podem ser classificadas em: convectivas, orográficas e frontais ou ciclônicas (figura 3.2).

- i) convectivas: acontece quando o ar úmido junto ao solo é aquecido e se desloca verticalmente, na atmosfera, condensa parte do vapor de água para formar nuvens e precipitar. São, geralmente, chuvas de pequena duração e grande intensidade agindo sobre pequenas áreas.
- ii) orográficas: ocorrem quando o ar quente e úmido que sopra do oceano para o continente encontra uma barreira montanhosa, o ar sobe, se resfria, ocorre condensação, formam-se nuvens e ocorre a precipitação. São chuvas de baixa intensidade, durações mais prolongadas em relação às chuvas convectivas e agem sobre médias áreas.
- iii) frontais ou ciclônicas: resultam do encontro de uma massa de ar quente com uma massa de ar frio. São chuvas menos intensas, de maior duração e atingem grandes áreas.

FIGURA 3.2 – TIPOS DE CHUVAS




As características qualitativas das chuvas quanto à intensidade e duração podem ser avaliadas em números através da coleta de dados em campo. Os principais aparelhos utilizados nesta coleta são o pluviômetro, o pluviógrafo e redes telemétricas (figura 3.3).

FIGURA 3.3 – APARELHOS DE MONITORAMENTO DA PRECIPITAÇÃO.



3.3 (a) PLUVIÔMETRO



3.3 (b) PLUVIÓGRAFO

FONTE: SANTOS et al. (2001)

O pluviômetro fornece o total precipitado ao final de um intervalo de tempo determinado. O pluviógrafo fornece dados contínuos e as redes telemétricas fornecem dados a cada 5, 10 ou 15 minutos. Através do estudo e observação destes dados é possível avaliar não somente a intensidade e duração, mas os totais precipitados, a frequência com que os eventos pluviométricos ocorrem e a distribuição temporal e espacial.

Na modelagem hidrológica, muitos modelos chuva-vazão consideram a precipitação média na bacia hidrográfica como entrada ao modelo. A maneira mais comum para obter a precipitação média numa bacia é através do método de *Thiessen* que considera a não-uniformidade da distribuição espacial dos postos.

3.1.2 Intercepção

A intercepção pode ser entendida como a parcela do volume precipitado interceptado antes que alcance o solo. A principal forma de intercepção é a retenção de volumes de água pelas folhas e troncos da vegetação da bacia hidrográfica em questão. LINSLEY (apud TUCCI 1993) cita que as perdas por intercepção vegetal podem chegar até 25% da precipitação anual. Há várias formas de se avaliar os volumes interceptados, no entanto, a forma mais clássica de tratar o problema é considerar a intercepção como um reservatório de uma dada capacidade máxima enchido pela chuva e deplecionado pela evaporação (CRAWFORD e LINSLEY, apud TUCCI, 1993). Esses autores enfatizam que a intercepção é função do tipo de cobertura vegetal (tabela 3.1).

TABELA 3.1 – CAPACIDADE MÁXIMA DO RESERVATÓRIO DE INTERCEPTAÇÃO

COBERTURA	CAPACIDADE MÁXIMA mm
Campo, prado	2,50
Floresta ou mato	3,75
Floresta ou mato denso	5,00

FONTE: TUCCI (1993)

Outra forma de interceptação de volumes da precipitação, conhecida por retenção, ocorre devido às depressões existentes ao longo da bacia. A dinâmica deste tipo de interceptação é função principalmente do tipo de solo. Em solos arenosos, os volumes interceptados infiltram rapidamente retornando ao fluxo normal da bacia. Em solos mais argilosos, a infiltração é lenta e a interceptação nas depressões é significativa reduzindo a vazão média da bacia.

3.1.3 Evaporação e Evapotranspiração

Além da interceptação e retenção, a precipitação perde água devido à evaporação e a evapotranspiração. A evaporação é o processo de vaporização que ocorre durante o trajeto da água até a superfície e sobre superfícies líquidas de rios, lagos e oceanos. A evapotranspiração é o processo de vaporização da água no solo e nas plantas (transpiração). Avaliar e quantificar como estes dois processos, evaporação e evapotranspiração, ocorrem é de suma importância na solução dos problemas de engenharia de recursos hídricos, pois interferem diretamente nos volumes escoados.

O “motor” dos processos de evaporação e evapotranspiração é a radiação solar que fornece a energia necessária para a transformação da água em vapor. Além da radiação solar interferem no processo, a temperatura do ar, vento e pressão de vapor.

Ambos os processos podem ser analisados em termos potenciais ou reais. A evaporação potencial, é a evaporação possível nas condições atmosféricas dadas. A evaporação real é aquela que realmente ocorre e é menor que a evaporação potencial. A mesma nomenclatura é dada a evapotranspiração, ou seja, evapotranspiração potencial e evapotranspiração real. Em problemas de engenharia é difícil quantificar o comportamento real da evaporação e evapotranspiração. É normal, nestes casos, a abordagem em termos potenciais.

Apesar da evaporação e evapotranspiração serem muito importantes na

determinação dos volumes escoados, na prática, a sua avaliação quantitativa direta é difícil, assim a principal forma de quantificar estas grandezas é através de métodos indiretos (equações empíricas e semi-empíricas).

Os métodos mais utilizados para determinar a evaporação são: balanço aerodinâmico, balanço de energia, método combinado, balanço hídrico, equações empíricas e evaporímetros.

Os métodos normalmente utilizados para determinar a evapotranspiração são: método combinado, balanço hídrico, métodos baseados na temperatura, métodos baseados na radiação e medidas diretas.

Conforme MÜLLER (1995) o método combinado também conhecido como o método de Penman é o método recomendado no estado do Paraná tanto na avaliação da evaporação potencial da superfície líquida quanto da evapotranspiração potencial da bacia hidrográfica.

O método de Penman (3.1) é resultado da combinação dos métodos do balanço aerodinâmico e do balanço de energia.

$$EV = \frac{\Delta}{\Delta + \gamma} H + \frac{\gamma}{\Delta + \gamma} E_a \quad (3.1)$$

EV – evaporação potencial (mm/dia).

Δ - declividade da curva de pressão de vapor (Pa/K)

γ - constante psicrométrica (Pa/K)

H – termo de balanço de energia ou radiação útil (mm/dia)

E_a – termo do balanço aerodinâmico (mm/dia)

A mesma equação que Penman determinou para avaliar a evaporação das superfícies líquidas, é utilizada na determinação da evapotranspiração (EVT), no

entanto, o termo de radiação útil e o termo do balanço aerodinâmico, respectivamente, H e E_a , devem ser mudados para considerar as propriedades diferentes da superfície vegetal (albedo, rugosidade, propriedades biológicas das plantas).

3.1.4 Infiltração

Do volume precipitado menos as perdas nas intercepções e na evaporação direta, o restante é infiltrado ou é escoado superficialmente, se a intensidade de chuva exceder a capacidade de infiltração. A infiltração é o processo de passagem da água da superfície para o interior do solo. A forma com que este processo ocorre depende, fundamentalmente, do tipo de solo e da quantidade de água disponível. A diversidade de solos quanto à textura, a estrutura, o perfil vertical e horizontal e a variabilidade espacial é que torna a quantificação da infiltração um dos processos mais difíceis entre os processos do ciclo hidrológico.

No início do processo a água que chega até a superfície infiltra umedecendo o solo das camadas superiores para as camadas inferiores formando um gradiente de umidade. Se os volumes precipitados forem contínuos, o perfil tende à saturação em toda a sua profundidade. Este processo dificilmente ocorre devido a chuvas de pequena intensidade e curta duração onde a saturação do solo se limita às camadas superiores. À medida que os volumes de precipitação decrescem e cessam, o processo de infiltração deixa de existir e a umidade do interior do solo sofre uma redistribuição. Parte do volume infiltrado evapora, parte é consumida pela vegetação que transpira, parte escoa e o restante propaga-se para as camadas mais profundas na direção dos lençóis freáticos resultando na inversão do perfil de umidade. As camadas superiores se tornam mais secas e as camadas mais profundas mais úmidas.

O conhecimento da dinâmica do processo de infiltração permite avaliar e diferenciar capacidade de infiltração de taxa de infiltração. No início do processo de infiltração, as camadas superiores são mais secas, ou seja, naquele momento a capacidade de infiltração é maior que num momento posterior. As taxas de infiltração

são função da quantidade de água disponível. Se esta quantidade for maior que a capacidade de infiltração, então o processo de infiltração ocorre com taxas iguais à capacidade do solo. Neste processo, a capacidade e portanto as taxas de infiltração tendem a diminuir. Se a quantidade de água disponível for menor do que a capacidade de infiltração, então o processo ocorrerá com taxas menores que a capacidade do solo e iguais a intensidade da precipitação. À medida que a capacidade do solo diminui esta se aproxima das taxas de infiltração existentes naquele momento. Quando a capacidade de infiltração for igual à taxa de infiltração, então, novamente, ambas diminuirão até que o solo se torne saturado, quando então a capacidade de infiltração é nula.

Quando os volumes precipitados cessam, como descrito anteriormente, ocorre uma redistribuição da umidade do solo com as camadas superiores tornando-as mais secas e as camadas inferiores mais úmidas. Isto aumenta novamente a capacidade de infiltração do solo.

Para que exista escoamento superficial a intensidade da precipitação deve ser maior que a capacidade de infiltração e a altura precipitada deve ser suficiente para que o solo alcance a capacidade de campo. *Horton* em 1939 estabeleceu, através de experimentos de campo, uma relação matemática para a capacidade de infiltração em função do tempo.

$$I_t = I_b + (I_o - I_b)e^{-kt} \quad (3.3)$$

onde

I_t – taxa de infiltração no tempo t (mm/h)

I_b – taxa de infiltração mínima (mm/h)

I_o – taxa de infiltração inicial (mm/h)


k – parâmetro de decaimento da capacidade de infiltração função do tipo de solo. (h^{-1})

3.1.5 Escoamentos superficial e subterrâneo.

Se a precipitação for tal que supere as perdas por interceptação e evaporação, e ainda sua intensidade seja superior a capacidade de infiltração, então ocorre o escoamento superficial. O escoamento superficial se caracteriza pelo movimento sobre o solo do excesso de água precipitado dos pontos mais altos para os pontos mais baixos pela ação da gravidade. Neste trajeto as partículas de água passam por redes efêmeras de drenagem até encontrar os canais principais, rios e lagos. Os volumes que chegam até o rio ou lago geram um aumento da vazão ou dos volumes armazenados. Quantificar estes volumes é o principal problema na engenharia de recursos hídricos. A variação da vazão num rio interfere diretamente no gerenciamento dos recursos hídricos.

A característica principal de um evento chuvoso é o aumento da vazão dos rios. A variação da vazão ao longo do tempo é representada graficamente através de um hidrograma. O hidrograma observado após um evento chuvoso é conhecido por hidrograma de cheia. Este hidrograma apresenta um comportamento bem característico, um alto gradiente de ascensão, um pico e um trecho de recessão (figura 3.4).

FIGURA 3.4 – HIDROGRAMA DE CHEIA



FONTE: Adaptado de TUCCI (1993)

Entre o início da chuva e o início da ascensão decorre certo tempo conhecido por tempo de retardamento devido às perdas por intercepções, depressões no solo, além do próprio retardo de resposta da bacia devido ao tempo de deslocamento das partículas de água até o canal principal. O trecho de ascensão está altamente relacionado a intensidade da precipitação. No final do trecho de ascensão há o pico; a partir deste ponto os volumes escoados começam a diminuir devido à redução das chuvas. Este processo persiste até que o escoamento superficial cessa e o canal é alimentado pelo escoamento subterrâneo.

De todo o volume precipitado, a parcela deste volume que realmente gera escoamento superficial, é chamada por precipitação efetiva.

As águas subterrâneas são provenientes da infiltração e percolação de um evento de precipitação qualquer anterior. Durante os períodos de seca, os volumes disponíveis das águas subterrâneas diminuem. Na prática, isto é caracterizado pelo rebaixamento do lençol freático. A recarga destes lençóis está condicionada a novos eventos de precipitação. No início de um novo evento, os volumes escoados superficialmente alcançam o canal principal mais rapidamente. Isto eleva o nível do rio e represa ou inverte o fluxo do escoamento subterrâneo para dentro dos aquíferos. O fluxo normal é retomado quando a percolação aumenta e o fluxo superficial diminui. Todo este comportamento do escoamento subterrâneo é representado na figura 3.4 pela linha tracejada.


Apesar do hidrograma de cheias ser bem característico, ascensão, pico e recessão, são vários os fatores que interferem na forma com que o mesmo se apresenta, por exemplo, o gradiente de ascensão e o valor da vazão de pico. Os principais fatores que interferem neste tipo de comportamento são o relevo da bacia, a cobertura vegetal, modificações antrópicas no rio e a distribuição, duração e intensidade da precipitação.

3.2 MODELAGEM

3.2.1 Introdução

A modelagem é uma ferramenta, em geral, constituído de um conjunto de equações, que de forma simplificada, é utilizada para representar o comportamento de um sistema físico mais complexo. O sistema é uma estrutura qualquer com procedimentos particulares que, a partir de um estímulo, gera uma resposta. O objetivo da modelagem é avaliar de maneira coerente quais as possíveis respostas de um sistema a partir de certos estímulos utilizando para isto uma abordagem simplificada da estrutura e das transformações internas deste mesmo sistema (figura 3.5).

FIGURA 3.5 – REPRESENTAÇÃO ESQUEMÁTICA DE UM MODELO GERAL



O cálculo da flecha de uma viga bi-apoiada com uma carga distribuída, por exemplo, é também obtida a partir de um modelo. O modelo leva em consideração condições de apoio e características do material mais simples e não exatamente iguais às reais. No entanto, estas simplificações não invalidam os resultados obtidos pelo modelo, sendo as diferenças entre realidade física do sistema e do modelo aceitáveis para os fins almejados. Isto justifica a simplificação dos sistemas e a sua conseqüente utilização. O estímulo deste modelo é a carga distribuída, a resposta é a flecha. Outros exemplos de modelos são apresentados na tabela 3.2 a seguir

TABELA 3.2 – EXEMPLOS DE MODELOS


ESTÍMULO	MODELO vs SISTEMA	RESPOSTA
VAZÃO	CANAL	PROFUNDIDADE
INVESTIMENTO	MERCADO FINANCEIRO	LUCRO
POPULAÇÃO	CRESCIMENTO	POPULAÇÃO FUTURA

3.2.2 Desenvolvimento de modelos

A modelagem de um sistema não é necessariamente algo simples, mas segue uma seqüência lógica (figura 3.6).

A primeira etapa no processo de modelagem de um sistema consiste no trabalho de percepção de como este sistema se comporta. Na modelagem da deformação da viga bi-apoiada citada anteriormente, deve-se ter a percepção de que a viga sendo carregada apresentará uma flecha e que sendo o carregamento uma carga distribuída, a maior flecha ocorrerá no meio do vão. Esta é uma primeira etapa deste processo.

FIGURA 3.6 – ETAPAS DO PROCESSO DE MODELAGEM



FONTE: Adaptado de BEVEN (2001)

É importante avaliar qual a sensibilidade do sistema a diferentes estímulos, por exemplo, na mesma viga bi-apoiada, aumentar a carga significará um aumento na dimensão da flecha. O exemplo da viga bi-apoiada é um exemplo simples, mas o suficiente para exemplificar no que consiste o trabalho de percepção. É o

conhecimento qualitativo de como o sistema funciona e responde a diferentes estímulos. Os modelos podem ser: físicos, analógicos e matemáticos. Todos estes modelos têm o mesmo objetivo, ou seja, representar através de uma abordagem simplificada as respostas do sistema para diferentes estímulos. Em recursos hídricos os modelos matemáticos são os mais utilizados. Isto significa que as aproximações do comportamento do sistema são feitas através de equações.

Definir quais as equações que melhor representam o modelo e ressaltar quais são as simplificações adotadas fazem parte de uma segunda etapa no processo de modelagem do sistema. TUCCI (1998) apresenta as equações mais utilizadas na modelagem e solução de problemas em recursos hídricos.

A terceira etapa consiste em implementar o modelo, ou seja, codificar as equações e simplificações adotadas numa linguagem computacional. Este trabalho pode parecer oneroso e desnecessário na modelagem de uma viga bi-apoiada, mas é extremamente importante na modelagem do ciclo hidrológico, um sistema complexo e que para ser modelado necessita de uma grande quantidade de informações para se obter boas respostas.

Dependendo do modelo proposto, as equações definidas na segunda etapa dependem de um conjunto de parâmetros. Estes parâmetros não necessariamente devem ter alguma conotação com a realidade do sistema modelado. Calibrar o modelo consiste em determinar valores numéricos a estes parâmetros. Essa é a quarta etapa da modelagem de um sistema.

A quinta e última etapa se resume na validação do modelo. A validação consiste em verificar se com os parâmetros calibrados na etapa anterior o modelo reproduz satisfatoriamente alguns eventos não usados na calibração. Durante a validação é verificado se o modelo proposto é capaz de representar o sistema. Qualquer conclusão negativa nesta etapa será passível de intervenção nas etapas anteriores.

Quando as equações do modelo procuram reproduzir os principais processos

envolvidos no ciclo hidrológico, usando equações cujos parâmetros possuem significado físico os modelos são denominados conceituais. Esses modelos apresentam em geral uma estrutura complexa e um grande número de parâmetros.

Uma alternativa aos modelos conceituais que descrevem todo o ciclo hidrológico são os modelos empíricos. A característica principal destes modelos é definir através de uma única equação matemática, em geral sem relação com os processos físicos envolvidos, a relação entre as variáveis de entrada e saída. Estes modelos não seguem rigorosamente a metodologia descrita anteriormente, por exemplo, não é necessário ter uma percepção do sistema para se aplicar um modelo empírico. Detalhes sobre modelos conceituais e empíricos são apresentados a seguir.

3.2.3 Classificação

Tanto os sistemas quanto os modelos são classificados segundo diversos critérios. A mesma classificação com que os sistemas são abordados é aplicada aos modelos. No entanto, é importante ressaltar que nem sempre um sistema é representado por um modelo do mesmo tipo. É comum, por exemplo, a utilização de modelos lineares na representação de sistemas não lineares. Esta abordagem é justificável quando os erros envolvidos são próximos daqueles obtidos por uma representação mais complexa do sistema. Os critérios utilizados na classificação de sistemas e modelos são apresentados a seguir. Esta classificação é uma classificação geral aplicável a qualquer tipo de modelo, no entanto, de forma ilustrativa, os exemplos apresentados estão relacionados a modelos utilizados na solução de problemas em recursos hídricos.

i) memória: a memória expressa a relação de dependência do modelo em relação a informações passadas. Um modelo independente de informações passadas é dito sem memória ou memória zero. Quando o modelo é dependente destas informações, o mesmo é dito como um modelo com memória. O mesmo pode ter uma

memória infinita quando depende de todo o passado ou finita quando depende de parte das informações passadas. Um exemplo de modelo sem memória é o sorteio de números aleatórios. Um exemplo de modelo com memória é a modelagem do ciclo hidrológico.

ii) linearidade: o modelo é linear quando a representação do mesmo é feita a partir de relações lineares diretas. A condição necessária para que o modelo seja linear é a validade do princípio da superposição, ou seja, conhecido duas entradas x_1 e x_2 as quais, respectivamente, produzem as saídas y_1 e y_2 , então o modelo será linear se a entrada $x_1 + x_2$ produzir a saída $y_1 + y_2$. O hidrograma unitário é um exemplo de modelo linear. O escoamento em canais é um exemplo de modelo não-linear.

iii) contínuo ou discreto: os modelos são ditos contínuos quando as variáveis de entrada e saída ocorrem de forma contínua ao longo do tempo e espaço. Quando as variáveis assumem valores apenas em intervalos espaçados de tempo e distância o modelo é dito como discreto. Atualmente dado que os computadores são intrinsecamente discretos grande parte dos modelos também são discretos. Na prática, é comum coletar os valores de uma variável contínua em intervalos discretos. A escolha deste intervalo é função dos recursos computacionais disponíveis e da precisão desejada nos resultados. Um exemplo de registro de uma variável contínua em intervalos discretos são os níveis de um rio. Normalmente estes níveis são registrados por um observador duas vezes ao dia. O registro contínuo deste mesmo procedimento é feito através de um aparelho chamado de linígrafo, mas ao ser processado no computador esse registro é discretizado em intervalos de tempo fixos.

iv) concentrados ou distribuídos: os modelos concentrados são modelos que não levam em consideração a variabilidade espacial das variáveis hidrológicas envolvidas no processo modelado. Nestes modelos a principal variável é o tempo. Na modelagem concentrada do processo chuva-vazão de uma bacia hidrográfica, por exemplo, todas as variáveis do sistema são avaliados em termos da média espacial. Isto significa que chuva, evaporação, infiltração, vazões e outras variáveis são

consideradas em termos médios na bacia. Já os modelos distribuídos, além de considerar como cada fenômeno ocorre ao longo do tempo, também consideram as variações espaciais. Na mesma bacia hidrográfica isto significa que ao invés do modelo considerar chuva, evaporação, infiltração e vazão em termos médios, ele considera que cada um destes processos varia entre os elementos de área da bacia. A utilização de um modelo distribuído, aparentemente mais sofisticado, não significa necessariamente ganho de qualidade na representação do sistema, uma vez que os resultados dos modelos são altamente dependentes da qualidade dos dados de entrada e nem sempre disponíveis em todos os pontos da bacia.

v) estocásticos ou determinísticos: os modelos que explicitamente levam em consideração a probabilidade que certo evento ocorra são ditos modelos estocásticos, por exemplo, o nível futuro de um reservatório depende da vazão afluyente futura que é uma variável aleatória com uma dada distribuição de probabilidade. Se o modelo não considerar a natureza probabilística de certas variáveis hidrológicas então o modelo é dito determinístico e a forma como um determinado evento ocorrerá será produto de regras claras e entradas bem determinadas.

vi) conceitual ou empírico – um modelo é conceitual quando as equações utilizadas para modelar o sistema são baseadas em conceitos derivados das leis que rege os vários processos do sistema. Já os modelos empíricos ou “caixa preta” são modelos que ajustam os estímulos às repostas desejadas através de uma equação que em geral não tem relação com as leis que regem os processos do sistema.

3.3 MODELOS CHUVA-VAZÃO.

A definição de um modelo chuva-vazão é uma extensão da definição geral de modelos, ou seja, um modelo chuva-vazão é uma ferramenta que, através de uma abordagem simplificada dos processos do ciclo hidrológico, tem como objetivo

principal, avaliar qual a resposta em termos de vazão de uma dada bacia hidrográfica em função de uma precipitação qualquer. Estes modelos devem ser capazes de descrever em função da precipitação, as perdas por evaporação, interceptação, infiltração e percolação da água subterrânea e de calcular o escoamento superficial e o escoamento de base.

3.3.1 Histórico

Os primeiros modelos chuva-vazão surgiram logo após a 2ª guerra mundial como consequência da utilização dos computadores na engenharia de recursos hídricos. No Brasil este processo se intensificou apenas na década de 70.

Um dos primeiros modelos chuva-vazão é o chamado SSARR (*Streamflow Synthesis and Reservoir Regulation*), um modelo do tipo conceitual desenvolvido pela *U. S. Army Corps Engineers* em 1958 com objetivo de simular o ciclo hidrológico e regularizar vazões. Em 1966 *Crawford* e *Linsley* apresentaram o STANDFORD IV, também conceitual, com discretização a cada 15 minutos, sendo considerado um dos mais completos em relação à quantidade de processos representados.

A principal característica destes primeiros modelos foi a de tentar representar por completo o ciclo hidrológico. Ao longo do tempo outros modelos surgiram com a mesma proposta, mas com pequenas diferenças em seus algoritmos, ressaltando um ou outro processo, como por exemplo, a infiltração ou a evapotranspiração. O *Kentucky Model* e o *Texas Watershed Model* são exemplos de modelos que surgiram nesta época. No Brasil se destacam os modelos IPH e IPHMEN elaborados pelo Instituto de pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul.

A escolha por um ou outro modelo é subjetiva e depende, além de questões como objetivos, limites, quantidade e qualidade de dados, também da questão de maior ou menor sensibilidade do usuário com o modelo. Não é válido afirmar que um modelo seja melhor que outro quando se leva em consideração nesta avaliação o rigor que os mesmos tratam dos processos do ciclo hidrológico. Isto é válido quando se sabe

que os erros embutidos pela simplificação de um ou outro processo são menores que os erros referentes aos dados de entradas. A precipitação é um exemplo disto, os erros devido às simplificações quanto à distribuição temporal e espacial da mesma são muito maiores do que qualquer refinamento da metodologia que simule os processos físicos da bacia.

Os primeiros modelos chuva-vazão que surgiram tinham como objetivo principal representar com qualidade os hidrográficos de cheia. Como as informações sobre as bacias eram escassas, estes modelos simulavam o ciclo hidrológico em termos do macroprocesso. Isto significa que variáveis como, por exemplo, infiltração e evapotranspiração eram representadas em termos médios. Estes modelos eram conhecidos por modelos determinísticos conceituais. Em termos gerais estes modelos apresentavam as mesmas características, ou seja, representam o ciclo hidrológico através da conservação de volumes e de equações empíricas, utilizadas para retratar um ou outro processo da bacia. Como as equações empíricas são obtidas através de experimentações pontuais, os parâmetros físicos estimados a partir dessas, em termos médios nem sempre levam a uma boa relação entre vazões calculadas e observadas o que limita a utilização destes modelos. Outra limitação importante é a forma como os modelos foram calibrados, ou seja, os parâmetros escolhidos para ajustar os dados de entrada ao hidrográfico de cheia de eventos passados não são capazes de prever uma urbanização ou desmatamento da bacia no futuro.

Os modelos determinísticos conceituais têm diversas aplicações na engenharia, no entanto, não são capazes de simular uma situação diferente daquela para a qual foram calibrados. A necessidade de simular cenários ou de planejar a ocupação das bacias hidrográficas e avaliar estes riscos gerou a necessidade de um maior detalhamento da bacia e de seus processos. Com este intuito uma nova proposta de modelos chuva-vazão foi criada. Estes modelos eram do tipo distribuído para evitar o problema dos parâmetros médios e incorporam uma formulação do ciclo hidrológico que estabelece uma relação direta entre parâmetros obtidos das propriedades físicas

das áreas elementares e as transformações da bacia. Um exemplo deste tipo de modelo é o TOPMODEL.

3.3.2 Aspectos gerais

Em termos gerais os modelos chuva-vazão são utilizados para: estudo do comportamento dos fenômenos físicos hidrológicos; análise de consistência e preenchimento de falhas; previsão de vazão em tempo real; previsão de cenários de planejamento; efeitos resultantes da modificação do uso do solo; dimensionamento de obras hidráulicas (TUCCI, 1998) e (BARTH et al., 1987).

Na escolha de um modelo chuva-vazão deve-se levar em consideração aspectos como: os objetivos para os quais o modelo será utilizado, as limitações do modelo e qualidade e quantidade de dados (TUCCI, 1998). Em termos gerais os sistemas hidrológicos são quase sempre contínuos, distribuídos, não lineares e estocásticos, no entanto nem todos os modelos chuva-vazão tratam o sistema como realmente ele é ou ocorre.

As principais diferenças que podem ser encontradas em relação aos modelos chuva-vazão são quanto a:

i) Discretização da bacia hidrográfica – a discretização diz respeito à forma como os modelos fazem a subdivisão da bacia. Neste quesito os modelos podem ser: concentrados quando a precipitação é representada em termos médios e as variáveis são concentradas no espaço. Este tipo de modelo é muito utilizado em bacias de pequenas dimensões. Em bacias maiores as variáveis são geralmente distribuídas por sub-bacias ou distribuídos por elementos de área (*pixels*), quando a bacia é discretizada em pequenos quadrados, com o objetivo de caracterizar espacialmente todos os processos do ciclo hidrológico.

ii) Entradas – as principais entradas dos modelos chuva-vazão são a precipitação, evapotranspiração potencial e a vazão em tempos anteriores. Os dados de

entradas podem ser utilizados em intervalos de horas, dias, semanas, meses e anos.

iii) Estrutura do modelo – os modelos chuva-vazão mais completos são estruturados em dois módulos. O primeiro módulo é o módulo bacia, responsável pelo balanço vertical dos fluxos e pelo escoamento superficial. O segundo é o módulo canal responsável pela propagação do escoamento de montante para jusante considerando neste trajeto a contribuição lateral. Quando a bacia é pequena não há necessidade do cálculo da propagação do escoamento. Neste caso é suficiente a utilização de um modelo que contenha apenas o módulo bacia.

iv) Aquisição dos dados da bacia – como comentado anteriormente a maior parte dos modelos chuva-vazão utilizam como dados de entrada a precipitação, a evapotranspiração e a vazão em tempos anteriores. Normalmente estes dados são obtidos através de leituras de pluviômetros, em estações meteorológicas e em réguas de níveis. No entanto, há modelos que exigem uma maior quantidade de informações sobre a bacia hidrográfica como, variabilidade das características naturais e uso do solo. Os modelos discretizados por módulo são os principais exemplos destes tipos de modelos. Nestes modelos a aquisição de dados é feita através de Sistemas de Informação Geográficos – SIG e Sensoriamento Remoto. A utilização destas ferramentas permite obter informações sobre as características climatológicas e físicas da bacia. Um exemplo de informação física é o modelo digital do terreno.

v) Determinação dos parâmetros – dependendo do tipo de modelo, os parâmetros podem ser estimados em função das características físicas da bacia ou serem ajustados em função dos dados de entrada e saída. No primeiro caso, o valor de um determinado parâmetro pode ser investigado em campo por experimentação. O que ocorre neste caso é que os números de experimentações de campo são geralmente muito pequenos em relação à verdadeira necessidade. Este fato decorre dos efeitos de escala de uma bacia, pois um valor experimental pontual não pode ser extrapolada para toda bacia uma vez que as variações das características físicas da mesma são muito grandes mesmo em intervalos pequenos do espaço. Neste caso os parâmetros são

determinados via experimentação para diferentes tipos de uso do solo e os valores médios são determinados por médias ponderadas pela distribuição do uso do solo na bacia. No segundo caso, quando os modelos são ajustados em função dos dados de precipitação e vazão de eventos passados, os parâmetros são determinados por tentativa e erro ou com a utilização de algoritmos de otimização.


4. REDES NEURAIS ARTIFICIAIS - RNA

Uma rede neural artificial - RNA é um modelo matemático empírico, com memória e não linear desenvolvido com base no funcionamento do cérebro humano. Dependendo de como ele é abordado, pode ser classificado em contínuo ou discreto, concentrado ou distribuído e ainda em estocástico ou determinístico.

4.1 INTRODUÇÃO

O cérebro humano contém cerca de 10 bilhões de neurônios, cada um destes conectado com aproximadamente outros 10.000 neurônios formam uma grande malha capaz de aprender, identificar padrões e processar informações em paralelo.

FIGURA 4.1 – CÉREBRO HUMANO




FONTE: STANFORD (2004)

Os pontos amarelos na figura 4.1 acima são identificados como o corpo de uma célula neural biológica (soma). As linhas entre um e outro ponto são responsáveis pela comunicação entre os neurônios (sinapses). A comunicação entre eles é feita através de impulsos eletroquímicos. O neurônio recebe impulsos por ligações de entradas chamadas de dendritos (figura 4.2). A soma de todos os impulsos que chegam até um neurônio representa uma energia. Esta energia gera um grau de ativação no neurônio e uma resposta, também, em forma de impulso eletroquímico, o qual é

transmitido para o neurônio seguinte. A resposta gerada pelo neurônio é transmitida através do axônio.

FIGURA 4.2 – NEURÔNIO BIOLÓGICO



As RNA foram desenvolvidas inspiradas neste processo, ou seja, são constituídas por vários elementos de processamento conectados entre si onde cada elemento recebe e envia informações de forma semelhante a uma célula neural biológica. Com uma malha muito menor de elementos do que a do cérebro humano as RNA são capazes de aprender, executar operações não lógicas, transformações e comparações, descobrir relações ou regras e testar situações em paralelo de um problema específico (TAFNER et al., 1996), características estas que justificam a aplicabilidade desta ferramenta em vários ramos da ciência e tecnologia, dentre as quais pode-se citar (MATLAB, 2004):

- i) Geoprocessamento - identificação de imagens de satélite;
- ii) Economia – previsão de índices econômicos;
- iii) Indústrias – reconhecimento de padrões em linhas de montagem;
- iv) Recursos hídricos – previsão de chuva e vazão, modelos chuva-vazão .

4.2 HISTÓRICO

Os primeiros estudos sobre o funcionamento do cérebro humano e que de certa forma são básicos para os atuais conceitos e características das RNA datam do final do século XIX e início do século XX.

Em 1943 o neurofisiologista *Warren McCullough* e o matemático *Walter Pitts* fizeram a primeira analogia entre o comportamento da célula neural viva e os processos eletrônicos. Este trabalho consistia num modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio. Um pouco depois, em 1949, o psicólogo *Donald Hebb* descobriu a base de aprendizado das RNA, quando explicou o que ocorre, a nível celular, durante o processo de aprendizado no cérebro. *Hebb* propôs a utilização de pesos como uma forma representativa da RNA assimilar o conhecimento. A introdução da idéia de pesos como forma de aprendizado das RNA permitiu, que em 1951, *Marvin Minsky* construísse o primeiro neurocomputador, *Snark*, mas ainda sem nenhuma aplicação prática (GORNI, 1993).

No final da década de 50, *Frank Rosenblatt*, considerado o pai da neurocomputação, concebeu a primeira RNA nos mesmos moldes das RNA utilizadas hoje. A RNA de *Rosenblatt*, denominada de *Perceptron*, é uma RNA de uma camada com a capacidade de apreender e identificar padrões conforme as regras propostas por *Hebb*.

Em 1960, *Widrow* e *Hoff*, introduziram o *least mean-square* (LMS) utilizado para formular a RNA *Adaline* (*Adaptive Linear Element*).


Em 1969, *Marvin Minsky* e *Seymour Papert*, dois cientistas de renome na época, publicaram o livro “PERCEPTRON”, no qual resumiram e criticaram seriamente a pesquisa sobre as RNA, alegando que, além de utilizar processos de aproximação empíricos, não realizavam algumas operações *booleanas*. O impacto desta publicação foi fatal, retraíram com a crítica, praticamente todo o investimento e programas de pesquisa para essa tecnologia. Novos rumores sobre RNA surgiram novamente em 1974 com *Paul Werbos*, que lançou as bases do algoritmo de

treinamento *backpropagation* (retropropagação) que, mais tarde, em 1986, seria apresentado por *Rumelhart, Hinton e Williams*. No mesmo ano, o livro *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, escrito por *Rumelhart e McClelland*, foi publicado se tornando mais tarde o livro de maior influência no uso do método de aprendizado *backpropagation* (HAYKIN, 1994).

4.3 NEURÔNIO ARTIFICIAL

O neurônio artificial é o elemento básico que constitui uma RNA, conhecido também por nó, elemento ou unidade de processamento (figura 4.3).

FIGURA 4.3 – NEURÔNIO ARTIFICIAL



FONTE: Adaptado de STANFORD (2004)

Um neurônio artificial é apenas um elemento de uma RNA. Este elemento é idealizado matematicamente de tal forma a simular o mesmo comportamento de uma célula neural biológica, ou seja, o neurônio artificial apresenta estrutura para receber dados, processar estímulos e transmitir uma resposta a outros elementos conectados a este. Basicamente, o neurônio artificial é constituído de três elementos:

- i) Conjunto de pesos: conforme *Hebb*, em 1949, são os pesos que atribuem à RNA a capacidade de aprendizado. A utilização de pesos simula a forma de entrada de dados em uma célula neural biológica. De forma algébrica, dada uma matriz de entrada $\mathbf{X}$ [$x_{11}, x_{12}, x_{13} \dots x_{1p}; x_{21} x_{22}, x_{23} \dots x_{2p}; x_{N1} x_{N2}, x_{N3} \dots x_{Np}$], cada linha da matriz $\mathbf{X}$ é multiplicado pelos pesos $\mathbf{W}$ ($w_1; w_2; \dots w_p; \dots$).
- ii) Somatório: esta unidade é responsável pelo estímulo que chega à unidade de processamento, ou seja, a soma das correntes eletroquímicas. No neurônio artificial o somatório é o resultado do produto dos elementos da matriz $\mathbf{X}$ pelos pesos $\mathbf{W}$, [$x_{11} w_1 + x_{12} w_2 \dots + x_{1p} w_p; x_{21} w_1 + x_{22} w_2 \dots + x_{2p} w_p; x_{N1} w_1 + x_{N2} w_2 \dots + x_{Np} w_p$]. A operação descrita aqui é a combinação linear dos dados de entrada.
- iii) Função de transferência: é a própria unidade de processamento, recebe o estímulo, resultado do somatório, e transfere a resposta, obtida pela aplicação do estímulo a função de transferência, aos neurônios adjacentes. No modelo matemático a função de transferência ainda limita a amplitude da saída do neurônio. Normalmente esta saída está no intervalo entre [0,1] ou [-1,1].

O neurônio artificial mostrado na figura 4.3 anterior também inclui a entrada de um elemento externo b , chamado de viés (ruído aleatório). Isto significa que a combinação linear da unidade somatório deve ser aumentada em um termo para implementar o termo b .

Em termos matemáticos, pode-se descrever um neurônio j pelo seguinte par de equações.

$$u_j = \sum_{i=1}^p w_i x_{Ni} \quad (4.1)$$

$$y_{Nj} = \varphi(u_j + b_j) \quad (4.2)$$

Onde, novamente, x_{Nj} , w_i são, respectivamente, elementos da matriz $\mathbf{X}$, das entradas, e pesos de $\mathbf{W}$; b_j é o viés no neurônio j , $\varphi(.)$ é a função de transferência e y_{Nj} saída N do neurônio j (HAYKIN, 1994).

4.4 FUNÇÃO DE TRANSFERÊNCIA.


A função de transferência, denotada por $\varphi(.)$, define a saída do neurônio em função do nível de atividade na entrada. A utilização da função de transferência permite às RNA identificar relações lineares e não lineares entre as variáveis de entrada e as saída. As funções de transferência mais utilizadas são mostradas na figura 4.4 a seguir.

Muitas vezes as funções de transferência possuem características restritivas, isto significa que podem não produzir efeito num neurônio seguinte quando o estímulo for abaixo de um valor mínimo. As funções rampa e degrau possuem ações restritivas para valores extremos. Isto significa que ultrapassado certo limite, a função dispara o valor 0; 1 ou -1. A função sigmóide produz um valor 0 somente quando o estímulo for um grande valor negativo, e produz uma saída igual a 1 quando a ativação tiver um grande valor positivo. Essa função faz a transição entre os extremos de forma suave. (TAFNER et al., 1996).

4.5 RNA DO TIPO *PERCEPTRON*


Uma RNA é a combinação de diversos neurônios. *Perceptron* é o modelo de RNA mais simples. Criado por *Rosenblatt* no final da década de 50, a RNA do tipo *Perceptron* é constituída por vários elementos de entrada conectados aos neurônios de uma única camada de saída (figura 4.5). A função de transferência utilizada pelas RNA do tipo *Perceptron* limita a saída da RNA aos valores -1, 0 ou 1. Entre as conexões são introduzidos pesos os quais simulam o conhecimento da RNA sobre um problema proposto. As RNA do tipo *Perceptron* são aplicadas, principalmente, na

FIGURA 4.4 – FUNÇÕES DE TRANSFERÊNCIA




Degrau

$$\begin{aligned} x < 0 \quad y &= -1 \\ x > 0 \quad y &= 1 \end{aligned}$$




Rampa

$$\begin{aligned} x < 0 \quad y &= 0 \\ 0 \leq x < 1 \quad y &= x \\ x > 1 \quad y &= 1 \end{aligned}$$




Linear

$$x = y$$



Sigmoide -logística

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




Sigmoide -tangente hiperbólica

$$\begin{aligned} x \geq 0 \quad y &= 1 - \frac{1}{(1 + x)} \\ x < 0 \quad y &= -1 + \frac{1}{(1 - x)} \end{aligned}$$

FONTE: Adaptado de TAFNER et al. (1996)

FIGURA 4.5 – PERCEPTRON



FONTE: Adaptado de WHASHITONG (2004)

classificação de dados e identificação de padrões. Estas RNA também podem ajustar algumas funções lineares.

Para que uma RNA seja utilizada num problema prático, a mesma deve passar por um processo de treinamento. O processo de treinamento consiste em ajustar os pesos entre as conexões até que se minimize o erro na saída da RNA. As RNA, em geral, podem ser treinadas basicamente de duas formas, treinamento supervisionado e não supervisionado.

- Treinamento Supervisionado – no aprendizado supervisionado a RNA deverá possuir pares de entrada e saída. Toda vez que uma entrada for apresentada à RNA, uma saída será obtida. Se a diferença entre a saída obtida e a saída desejada estiver fora dos limites considerados satisfatórios os pesos entre as conexões deverão ser ajustados. Este processo é repetido até que os erros tornem-se aceitáveis. Esta é a forma de aprendizado mais utilizada.
- Treinamento Não-Supervisionado – também conhecido por auto-supervisionado, a RNA trabalha as entradas e se organiza de modo que acabe classificando-as, usando, para isso, os seus critérios internos próprios, previamente definidos.

As RNA do tipo *Perceptron* são treinadas através do método supervisionado. O algoritmo de treinamento do *Perceptron* sugerido por *Widrow e Hoff*, também conhecido como regra delta, constitui um dos mais simples, conforme equação (4.3). Inicialmente atribui-se aos pesos valores aleatórios, calcula-se a resposta e o erro na saída da RNA. Caso o erro seja inaceitável, faz o ajuste dos pesos proporcionalmente ao erro.

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (4.3)$$

onde:

$w_{ji}(n+1)$ - valor do peso corrigido na conexão ij na iteração $(n+1)$;

$w_{ji}(n)$ - valor antigo do peso na conexão ij na iteração (n) ;

$\Delta w_{ji}(n)$ - variação do no valor do peso na conexão ij proporcional ao erro na iteração (n) .

Este algoritmo garante a minimização do erro ao longo do tempo, através de ajustes nos pesos, ou seja, sua convergência garante que a adaptação dos pesos seja realizada num número finito de iterações (GALVÃO et al., 1999).

4.6 OUTROS TIPOS DE RNA


A RNA do tipo *Perceptron* mostrada na figura 4.5 é uma RNA com apenas duas camadas. Uma camada de entrada e uma camada de processamento, a principal limitação deste tipo de RNA. A partir desta estrutura, as RNA do tipo *Perceptron* estavam limitadas apenas à solução de problemas linearmente separáveis. Em 1982 e 1986 *Hopfield e Rumelhart* respectivamente, publicaram seus trabalhos propondo outros dois tipos de RNA como alternativa na solução de problemas não-lineares.

Hopfield propôs uma RNA com todos os neurônios interconectados e fluxo


de dados em todas direções. O processo é conhecido por *Recurrent-feedback* ou simplesmente *feedback*. A estrutura da RNA de *Hopfield*, a qual leva o seu nome, é apresentada na figura 4.6 (a) a seguir. *Rummelhart*, que também cedeu seu nome às RNA *Rummelhart*, propôs uma RNA mais semelhante a *Perceptron* com neurônios dispostos em camadas bem distintas com fluxo de dados numa única direção. Este processo é conhecido como *feedforward*. A figura 4.6 (b) apresenta uma RNA com três camadas: camada de entrada, intermediária e camada de saída. FERNANDES et al. (1996) citam num trecho de seu trabalho que “uma RNA, com um número suficiente de neurônios na camada intermediária e uma função de transferência do tipo” sigmóide “consegue aproximar, com grau de precisão desejado, qualquer mapa de um espaço dimensional finito em um outro espaço dimensional finito qualquer”, ou seja, garantem que as RNA de *Rummelhart* com três camadas são ajustáveis a qualquer problema não-linear. Esta afirmação também é apresentada na síntese do trabalho de GALVÃO et al. (1999).

Outros tipos de RNA, variações das RNA de *Rummelhart* e *Hopfield*, são propostas com objetivo de melhorar o desempenho das RNA existentes. Estas RNA podem ser encontradas em MATLAB (2004) e HAYKIN (1994), por exemplo, RNA de base radial, utilizadas por LIN e CHEN (2004) e RNA temporais (SAJIKUMAR e THANDAVESWARA, 1999).

FIGURA 4.6 – RNA DE HOPFIELD E RUMMELHART



4.6 (a) HOPFIELD



4.6 (b) RUMMELHART

FONTE: Adaptado de GORNI (1993)

4.7 RNA DO TIPO *PERCEPTRON* MULTICAMADAS – MLP

Perceptron Multicamadas ou *Multilayers Perceptron* – MLP é a forma mais popular de como é conhecida a RNA proposta por *Rummelhart*. Estas RNA também são conhecidas por RNA *feedforward*.

As RNA do tipo MLP são formadas por um conjunto de neurônios dispostos em camadas, uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Cada um dos neurônios da camada de entrada está conectada a todos os neurônios da camada intermediária. Da mesma forma, cada neurônio da camada intermediária está conectada com todos os neurônios da camada de saída. Não há conexões diretas entre a camada de entrada e a camada de saída. Entre todas as conexões são introduzidos pesos que, semelhante à RNA do tipo *Perceptron*, são incorporados para simular o conhecimento da RNA sobre o problema proposto. Os pesos são ajustados durante um processo de treinamento. O processo de treinamento tem o objetivo de minimizar os erros na saída da RNA. Na maior parte das vezes as RNA do tipo MLP são treinadas de maneira supervisionada.

Dentro da RNA do tipo MLP o fluxo de dados se dá numa única direção, *feedforward*, ou seja, os dados de entrada propagam-se através da RNA, camada a camada, no sentido progressivo. As entradas da camada de entrada são multiplicadas pelos pesos das respectivas conexões. Cada neurônio da camada intermediária recebe uma combinação linear dos elementos de entrada. Esta combinação gera um estímulo na função de transferência que emite uma resposta. Ao contrário das RNA do tipo *Perceptron*, onde a resposta da função de transferência é considerada a resposta da RNA, aqui na RNA do tipo *Perceptron* Multicamadas, a resposta da função de transferência é a entrada para a próxima camada, esta por sua vez, pode ser, mais uma camada intermediária ou a camada de saída.


A entrada da camada de saída é a combinação linear das saídas da camada intermediária. A saída da camada de saída é a resposta da RNA do tipo MLP.

Em termos matemáticos, este processo pode ser descrito da seguinte forma.

Supondo uma RNA do tipo MLP da mesma forma apresentada na figura 4.6 (b), três camadas, com p , q e 1 neurônios em cada camada (figura 4.7).

Supondo novamente a matriz de entrada $\mathbf{X}$ [x_{11} , x_{12} , x_{13} x_{1p} ; x_{21} x_{22} , x_{23} x_{2p} ; x_{N1} x_{N2} , x_{N3} x_{Np}], um vetor de saídas $\mathbf{D}$ [d_0 ; d_1 ; d_2 ; d_N] e o conjunto dos pesos iniciais $\mathbf{W}$ (w_{j1} , w_{j2} w_{ji} , w_{k1} , w_{k2} w_{kj}) entre as conexões da RNA. Cada entrada no neurônio j da camada intermediária é a combinação linear do vetor de entrada mais o elemento b_j , equação 4.4.

FIGURA 4.7 – REPRESENTAÇÃO DETALHADA DE UMA RNA DO TIPO MLP.



FONTE: Adaptado de HAYKIN (1994)

$$\sum_{i=1}^p w_{ji} x_{Ni} + b_j = w_{j1} x_{N1} + w_{j2} x_{N2} + w_{j3} x_{N3} + \dots + w_{jp} x_{Np} + b_j \quad (4.4)$$

A saída do neurônio j é a resposta da função de transferência conforme o estímulo dado.

$$y_{Nj} = \varphi \left(\sum_{i=1}^p w_{ji} x_{Ni} + b_j \right) \quad (4.5)$$

A resposta do neurônio j é o dado de entrada para o neurônio k da camada de saída. Assumindo a existência de q neurônios na camada intermediária a entrada no neurônio k da camada de saída é dada por:

$$\sum_{j=1}^q w_{kj} y_{N_j} + b_k = w_{k1} y_{N_1} + w_{k2} y_{N_2} + w_{k3} y_{N_3} + \dots + w_{kq} y_{N_q} + b_k \quad (4.6)$$

A saída da camada de saída ou a saída da RNA é igual a

$$y_{N_k} = \phi \left(\sum_{j=1}^q w_{kj} y_{N_j} + b_k \right) \quad (4.7)$$

ou, substituindo (4.5) em (4.7) FERNANDES et al. (1996) e HSU et al. (1995),

$$y_{N_k} = \phi \left(\sum_{j=1}^q w_{kj} \phi \left(\sum_{i=1}^p w_{ji} x_{N_i} + b_j \right) + b_k \right) \quad (4.8)$$

FERNANDES et al. (1996) comentam que, ao contrário do que parece a primeira vista, uma RNA, no caso MLP, tem vários pontos em comum com modelos estatísticos. Estas ligações parecem muito diferentes pelo uso de termos técnicos distintos. A tabela 4.1, a seguir, apresenta um “dicionário” RNA-estatística.

TABELA 4.1 – RELAÇÃO ENTRE OS TERMOS USADOS EM RNA E ESTATÍSTICA


RNA	ESTATÍSTICA
Pesos	Parâmetros
Conjunto de treinamento	Amostra
Entradas	Variáveis exógenas
Saídas	Variáveis endógenas
Retropropagação	Aproximação estatística
Treinamento ou aprendizado	Estimação
Sinal de entrada	Valor das variáveis exógenas
Sinal de saída	Valor estimado
Alvo	Valor da variável endógena

FONTE: FERNANDES et al. (1996)

A equação (4.8) representa a saída da RNA em função das entradas da matriz e dos diversos pesos, $\mathbf{W}$, ou seja, $f(\bar{\mathbf{x}}_N, \mathbf{W})$, onde $\bar{\mathbf{x}}_N$ é um vetor linha com p elementos da matriz $\mathbf{X}$. A equação $f(\bar{\mathbf{x}}_N, \mathbf{W})$ é a forma matemática de uma RNA do tipo MLP. A forma precisa desta equação depende do número de neurônios dispostos em cada camada. Optar por uma RNA para a solução de um problema consiste em resolver duas questões: a escolha da forma funcional de $f(\bar{\mathbf{x}}_N, \mathbf{W})$ e a estimação dos pesos $\mathbf{W}$, que pode ser feita de várias maneiras.

Do ponto de vista estatístico, a função $f(\bar{\mathbf{x}}_N, \mathbf{W})$ é uma função de regressão, no caso não-linear, utilizada para ajustar uma relação entre um número de entradas da matriz $\mathbf{X}$ [$x_{11}, x_{12}, x_{13}, \dots, x_{1p}; x_{21}, x_{22}, x_{23}, \dots, x_{2p}; x_{N1}, x_{N2}, x_{N3}, \dots, x_{Np}$] ao vetor de saída $\mathbf{D}$ [$d_0; d_1; d_2; \dots, d_N$]. Os elementos da matriz $\mathbf{X}$ são abordados como variáveis exógenas e $\mathbf{W}$ como o conjunto de parâmetros. A $f(\bar{\mathbf{x}}_N, \mathbf{W})$ definida *a priori*, representa uma família de curvas. O problema estatístico é obter o estimador ótimo $\mathbf{W}^*$, no caso, aquele que minimize o quadrado dos resíduos, ou seja, o problema estatístico consiste em, de uma família de curvas, determinar $f(\bar{\mathbf{x}}_N, \mathbf{W})$ que represente o melhor ajuste (figura 4.8).

FIGURA 4.8 – AJUSTE DOS MÍNIMOS QUADRADOS NÃO-LINEARES



FONTE: Adaptado de FERNANDES et al. (1996)

WHITE (apud FERNANDES et al., 1996) cita que “o estimador de mínimos quadrados não lineares ($\mathbf{W}$) tende assintoticamente para os pesos ótimos aprendidos

pela RNA ($\mathbf{W}^$). É neste sentido que se pode afirmar que a grande novidade introduzida pelas RNA consiste em focalizar a atenção na forma funcional de $f(\bar{\mathbf{x}}_N, \mathbf{W})$ ”.*

4.8 AJUSTE DOS PESOS

A abordagem mais genérica que se pode usar na determinação do estimador ótimo de um problema estatístico e, no caso, no ajuste dos pesos de uma RNA é fundamentada na solução de um problema de otimização. BRONSON (1995) em seu livro “Pesquisa Operacional” cita diversas formas como estes problemas aparecem e suas respectivas soluções.

Um problema de otimização é caracterizado por uma função objetivo e equações ou inequações de restrições. A função objetivo pode ser da forma linear, não linear monovariável e não linear multivariável. As funções lineares e as não lineares monovariáveis são representadas por linhas e curvas no plano (figura 4.9 (a)). As funções multivariáveis são representadas por superfícies em três e mais dimensões dependendo do número de variáveis independentes (figura 4.9 (b)). Se o número de variáveis independentes for igual a dois então a superfície da função objetivo será representada em três dimensões, caso contrário, ter-se-á uma superfície com mais de três dimensões que não pode ser representada graficamente.

Um problema estatístico de regressão que utiliza o método dos mínimos quadrados para ajustar uma curva ou função a uma malha de pontos apresenta a seguinte forma:

$$MIN \varepsilon = \sum e^2 \quad (4.9)$$

onde


ε - função objetivo

e – erro dado por $e=d-y$


d – saída desejada

y - saída da função $f(.)$.

FIGURA 4.9 – REPRESENTAÇÃO GRÁFICA DE UM PROBLEMA DE OTIMIZAÇÃO



4.9 (a) PROBLEMA NÃO-LINEAR MONOVARIÁVEL.



4.9 (b) PROBLEMA NÃO-LINEAR MULTI-VARIÁVEL.

FONTE: MÜLLER (1996)

No problema, o método de otimização ajustará os coeficiente das variáveis independentes da função $f(\cdot)$. Se existir uma única variável independente, a solução do

problema estará num plano. Se existirem duas variáveis a solução estará no mínimo global da superfície representada no espaço 3D. Se existirem mais de duas variáveis a solução se encontrará no mínimo global de uma hiper-superfície, no entanto deve-se ressaltar que as hiper-superfícies, com mais de três dimensões, são muito irregulares e a maneira como serão utilizados os algoritmos de otimização poderão indicar mínimos locais.

Para solução de problemas de otimização não lineares podem-se utilizar duas técnicas consagradas e citadas por BRONSON (1995) como o método do maior gradiente e o método de Newton-Raphson.

Pelo método do maior gradiente escolhe-se um vetor inicial W_0 e, em seguida, determinam-se os vetores $W_1, W_2, W_3, \dots$ pela relação recorrente:

$$W_{n+1} = W_n - \lambda_n^* \nabla \varepsilon|_{W_n} \quad (4.10)$$

onde

W_{n+1} - vetor dos coeficientes na iteração $(n+1)$;

W_n - vetor dos coeficientes na iteração (n) ;

$\nabla \varepsilon|_{W_n}$ - gradiente da função objetivo em W_n .

λ_n^* - escalar positivo que maximize $f(\lambda_n \nabla \varepsilon|_{W_n})$

n - iteração de número n .

O uso do sinal negativo indica a descida do gradiente na superfície de erro. O processo iterativo termina quando a diferença entre os valores da função objetivo para dois conjuntos W , sucessivos, for menor que uma tolerância pré-estabelecida. O último conjunto W computado torna-se a aproximação final de W^* .

Pelo método de Newton-Raphson escolhe-se um vetor inicial W_0 da mesma forma que no método do maior gradiente e determinam-se os vetores W_1, W_2, W_3 recursivamente por intermédio de:

$$\mathbf{W}_{n+1} = \mathbf{W}_n - (\mathbf{H}_\varepsilon|_{\mathbf{W}_n})^{-1} \nabla \varepsilon|_{\mathbf{W}_n} \quad (4.11)$$

onde

$\mathbf{H}_\varepsilon|_{\mathbf{W}_n}$ - matriz hessiana em $\mathbf{W}_n$.

A regra de parada é a mesma do método do maior gradiente.

Se $\mathbf{W}_0$ não for escolhido corretamente, o método poderá convergir para um mínimo local ou não convergir de forma alguma. Em qualquer dos casos o processo é interrompido e se recomeça a partir de uma nova condição inicial.

Da mesma forma como foram abordados os problemas de regressão estatísticos pode-se abordar o problema de ajustes dos pesos de uma RNA do tipo MLP, ou seja, incorporar um modelo de otimização na solução do problema.

Supondo a função objetivo da mesma forma que a equação (4.9) tem-se:

$$\text{MIN } \varepsilon = \sum (d - f(\bar{\mathbf{x}}_N, \mathbf{W}))^2 \quad (4.12)$$

Para solução deste problema podem-se citar várias técnicas consagradas e algumas ainda em investigação. Entre as técnicas consagradas citam-se o algoritmo *backpropagation* que se confunde com o gradiente descendente, gradiente descendente com termo *momentum*, gradiente cascata, Gauss-Newton e Levenberg-Maquardt.

Entre as técnicas em investigação pode-se citar o trabalho de HSU et al. (1995) que propuseram o algoritmo de treinamento LLSSIM (*Linear least square simplex*) para treinamento de RNA do tipo MLP com três camadas. HSU et al. (1995) criaram duas novas funções objetivo, uma para os pesos entre as camadas de entrada e a camada intermediária e outra para os pesos entre a camada intermediária e a camada de saída. HU et al. (2002) fizeram a minimização da função objetivo não linear utilizando sucessivas técnicas de programação linear. SARMENTO (1996) cita a utilização de algoritmos genéticos na minimização dos erros da função objetivo.

Em recursos hídricos, as técnicas mais utilizadas são o algoritmo *backpropagation* ou gradiente descendente e o algoritmo Levenberg-Maquardt.

Cabe ressaltar que nem todas RNA possuem uma função objetivo na forma da equação (4.12). HAYKIN (1994) apresenta a função objetivo da seguinte forma:

$$MIN \varepsilon = \frac{1}{2} \sum (d - f(\bar{\mathbf{x}}_N, \mathbf{W}))^2 \quad (4.13)$$

HU et al. (2001) citam que a função objetivo pode ser, por exemplo, a média do erro quadrático e que utilizar funções objetivo diferentes levam os pesos à ajustes diferentes. O MATLAB utiliza a função na forma apresentada em (4.12).

4.9 ALGORITMO *BACKPROPAGATION*

O algoritmo *backpropagation* de ajuste dos pesos de uma RNA do tipo MLP foi apresentado pela primeira vez por *Paul Werbos* (1974) e popularizada por *Rummelhart, Hinton e Williams* (1986). Uma classificação mais geral que pode ser dada ao algoritmo *backpropagation* é a de um método de otimização. Na verdade o algoritmo *backpropagation* é, em parte, uma adaptação dos métodos de otimização convencionais que leva em consideração a distribuição da RNA em camadas.

Os métodos de otimização convencionais na forma apresentada anteriormente têm o objetivo de ajustar os coeficientes das variáveis independentes a fim de minimizar o erro ao quadrado entre os valores de regressão e a variável dependente. Cada coeficiente está correlacionado intimamente a uma única variável independente, e neste caso todas as variáveis têm a mesma “responsabilidade” sobre o erro.

No caso das RNA de *Rummelhart* os neurônios são dispostos em camadas. Os pesos entre a camada de entrada e a primeira camada intermediária estão diretamente relacionados com as variáveis de entrada, já os pesos das camadas seguintes estão relacionados com as variáveis modificadas por combinações lineares e

pelas funções de transferência. Neste caso nem todos os pesos têm a mesma responsabilidade sobre o erro na saída da RNA.

O algoritmo *backpropagation* leva em consideração esta característica das RNA e corrige o peso entre cada conexão de forma proporcional ao erro que este esteja causando na saída da RNA. Apesar desta ser a principal característica deste algoritmo, o termo *backpropagation* é usado para caracterizar outras situações. Por exemplo, devido à grande popularidade as RNA do tipo MLP são muitas vezes ditas como sendo uma RNA *backpropagation*. Este termo também é usado para caracterizar o treinamento das RNA multicamadas (GALVÃO et al., 1999). Matematicamente o que este algoritmo faz é fornecer um método eficiente para obter as primeiras derivadas da função objetivo em relação aos pesos e *vieses* da mesma.

Na forma mais clássica, do algoritmo *backpropagation*, os pesos das conexões da RNA são ajustados proporcionalmente à primeira derivada. Este método de ajuste é conhecido por gradiente descendente e difere do método do maior gradiente pelo termo λ . No método do maior gradiente, λ é calculado a cada ajuste a fim de maximizar o caminhamento na direção do mínimo do problema. No método do gradiente descendente, o termo λ é substituído por η (equação 4.14), onde η é dito taxa de aprendizado. O valor de η é determinado inicialmente. Um valor baixo para η significa um processo de otimização mais lento. Quando os valores de η são altos a convergência para uma solução também pode ser alta, no entanto há o risco de ultrapassar o ponto mínimo.

$$\mathbf{W}_{n+1} = \mathbf{W}_n - \eta \nabla \varepsilon \big|_{\mathbf{W}_n} \quad (4.14)$$

A equação (4.14) é a forma generalizada de correção dos pesos proposta por *Widrow e Hoff* para as RNA do tipo *Perceptron* onde Δw_{ji} , em (4.3) é igual a $\eta \nabla \varepsilon \big|_{\mathbf{W}_n}$.

A seguir é apresentado como, através do método *backpropagation*, calculam-se as primeiras derivadas da função objetivo.

Considerando novamente a figura 4.7, tem-se que o erro no neurônio k da

camada de saída é dado por:

$$e_{Nk}(n) = d_{Nk}(n) - y_{Nk}(n) \quad (4.15)$$

onde

$e_{Nk}(n)$ - erro na saída da RNA para a entrada N na iteração n

$d_{Nk}(n)$ - saída desejada para RNA para a entrada N na iteração n

$y_{Nk}(n)$ - saída calculada pela RNA para a entrada N na iteração n

A função objetivo $\varepsilon(n)$ é da mesma forma que a equação (4.12) com $y_{Nk}(n)$ no lugar de $f(\bar{\mathbf{x}}_N, \mathbf{W})$

$$\varepsilon(n) = \sum_I^N e_{Nk}(n)^2 \quad (4.16)$$

Cabe ressaltar novamente que nem todas as RNA apresentam a função objetivo na forma da equação (4.12). A forma apresentada aqui é aquela utilizada pelo *software* MATLAB.

A combinação linear das entradas no neurônio k e a resposta são dadas respectivamente pelas equações (4.17) e (4.18).

$$v_{Nk}(n) = \sum_{j=1}^q w_{kj} y_{Nj} + b_k \quad (4.17)$$

$$y_{Nk}(n) = \varphi_k(v_{Nk}(n)) \quad (4.18)$$

Conhecendo o gradiente da função objetivo $\nabla \varepsilon|_{w_n}$:

$$\nabla \varepsilon|_{w_n} = \left[\frac{\partial \varepsilon(n)}{\partial w_{j1}(n)} \quad \frac{\partial \varepsilon(n)}{\partial w_{j2}(n)} \quad \cdots \quad \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad \frac{\partial \varepsilon(n)}{\partial w_{jp}(n)} \quad \frac{\partial \varepsilon(n)}{\partial w_{k1}(n)} \quad \frac{\partial \varepsilon(n)}{\partial w_{k2}(n)} \quad \cdots \quad \frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} \quad \frac{\partial \varepsilon(n)}{\partial w_{kq}(n)} \right]^T \Big|_{w_n} \quad (4.19)$$

O elemento genérico $\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)}$ pode ser expresso da seguinte forma:

$$\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} = \frac{\partial \varepsilon(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial w_{kj}(n)} \quad (4.20)$$

Diferenciando ambos os lados da equação (4.16) em relação a $e_{Nk}(n)$ obtém-se:

$$\frac{\partial \varepsilon(n)}{\partial e_{Nk}(n)} = 2e_{Nk}(n) \quad (4.21)$$

Diferenciando ambos os lados da equação (4.15) em relação a $y_{Nk}(n)$ obtém-se:

$$\frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} = -1 \quad (4.22)$$

A seguir diferenciando (4.18) em relação a $v_{Nk}(n)$ obtém-se:

$$\frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} = \varphi'_k(v_{Nk}(n)) \quad (4.23)$$

Finalmente, diferenciando (4.17) em relação a $w_{kj}(n)$ produz-se:

$$\frac{\partial v_{Nk}(n)}{\partial w_{kj}(n)} = y_{Nj}(n) \quad (4.24)$$

A partir de (4.21), (4.22), (4.23) e (4.24) em (4.20) obtém Δw_{kj} em (4.14) na seguinte forma:

$$\Delta w_{jk} = \eta \delta_{Nk}(n) y_{Nj}(n) \quad (4.25)$$

onde $\delta_{Nk}(n)$ é o gradiente local definido por:

$$\begin{aligned}
 \delta_{Nk}(n) &= -\frac{\partial \varepsilon(n)}{\partial v_{Nk}(n)} \\
 &= -\frac{\partial \varepsilon(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} \\
 &= 2e_{Nk}(n)\varphi'(v_{Nk}(n))
 \end{aligned} \tag{4.26}$$

O gradiente local aponta para as modificações necessárias nos pesos. De acordo com a equação (4.26), o gradiente local $\delta_{Nk}(n)$ para o neurônio de saída k é igual ao produto de duas vezes o erro $e_{Nk}(n)$ pela derivada $\varphi'(v_{Nk}(n))$ da função de transferência associada.

Das equações (4.25) e (4.26) nota-se um fator-chave envolvido no ajuste dos pesos, o erro $e_{Nk}(n)$ na saída do neurônio k . No caso de um neurônio j na camada intermediária o gradiente local deve ser reformulado uma vez que não se sabe o erro existente entre as conexões intermediárias. Da própria equação (4.26) pode-se reformular o gradiente local para:

$$\begin{aligned}
 \delta_{Nj}(n) &= -\frac{\partial \varepsilon(n)}{\partial y_{Nj}(n)} \frac{\partial y_{Nj}(n)}{\partial v_{Nj}(n)} \\
 \delta_{Nj}(n) &= -\frac{\partial \varepsilon(n)}{\partial y_{Nj}(n)} \varphi'_j(v_{Nj}(n))
 \end{aligned} \tag{4.27}$$

Diferenciando (4.16) em relação $y_{Nj}(n)$ obtém-se:

$$\frac{\partial \varepsilon(n)}{\partial y_{Nj}(n)} = 2 \sum_{k=1}^N e_{Nk}(n) \frac{\partial e_{Nk}(n)}{\partial y_{Nj}(n)} \tag{4.28}$$

Desenvolvendo a derivada parcial $\partial e_{Nk}(n) / \partial y_{Nj}(n)$ em cadeia e reescrevendo (4.28) obtém a forma:

$$\frac{\partial \varepsilon(n)}{\partial y_{Nj}(n)} = 2 \sum_1^N e_{Nk}(n) \frac{\partial e_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial y_{Nj}(n)} \quad (4.29)$$

De (4.15) e (4.18) vem:

$$e_{Nk}(n) = d_{Nk}(n) - \varphi_k(v_{Nk}(n)) \quad (4.30)$$

Assim,

$$\frac{\partial e_{Nk}(n)}{\partial v_{Nk}(n)} = -\varphi'_k(v_{Nk}(n)) \quad (4.31)$$

Diferenciando (4.17) em relação $y_{Nj}(n)$ obtém-se:

$$\frac{\partial v_{Nk}(n)}{\partial y_{Nj}(n)} = w_{kj}(n) \quad (4.32)$$

Substituindo (4.31) e (4.32) em (4.29) obtém-se a derivada parcial desejada

$$\begin{aligned} \frac{\partial \varepsilon(n)}{\partial y_{Nj}(n)} &= -2 \sum_1^N e_{Nk}(n) \varphi'_k(v_{Nk}(n)) w_{kj}(n) \\ &= -\sum_1^N \delta_{Nk}(n) w_{kj}(n) \end{aligned} \quad (4.33)$$

Finalmente substituindo (4.33) em (4.27) obtém a equação para gradiente local nas camadas intermediárias

$$\delta_{Nj}(n) = \varphi'_j(v_{Nj}(n)) \sum_1^N \delta_{Nk}(n) w_{kj}(n) \quad (4.34)$$

O ajuste dos pesos entre a camada de entrada e a camada intermediária é igual àquela feita pela equação (4.25) substituindo $\delta_{Nk}(n)$ por $\delta_{Nj}(n)$.

Durante o processo de treinamento os *viéses* ou os *b's*, da RNA também devem ser ajustados, logo:

$$\frac{\partial \varepsilon(n)}{\partial b_k(n)} = \frac{\partial \varepsilon(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial b_k(n)} \quad (4.35)$$

O único termo desconhecido em (4.35) é $\frac{\partial v_{Nk}(n)}{\partial b_k(n)}$, obtido diferenciando $v_{Nk}(n)$ na equação (4.17) em relação a $b_k(n)$.


$$\frac{\partial v_{Nk}(n)}{\partial b_k(n)} = 1 \quad (4.36)$$

Substituindo (4.21), (4.22), (4.23) e (4.36) em (4.14) obtém Δb_k


$$\Delta b_k = \eta \delta_{Nk}(n) \quad (4.37)$$

O ajuste dos *vieses* da camada intermediária é feito substituindo $\delta_{Nk}(n)$ por $\delta_{Nj}(n)$ em (4.37).

O diagrama das figuras 4.10 e 4.11 a seguir representam o fluxo de dados, respectivamente, em *forward* e *backward* de uma RNA com três camadas e um único neurônio na camada de saída.

FIGURA 4.10 – FLUXO DE DADOS EM UMA RNA EM *FOWARD*

FONTE: O autor

FIGURA 4.11 – FLUXO DE DADOS EM UMA RNA EM *BACKWARD*

FONTE: O autor

4.10 ALGORITMO LEVENBERG-MAQUARDT

Da mesma forma que o gradiente descendente é uma extensão do método de otimização do maior gradiente e utiliza o algoritmo *backpropagation* para obter as primeiras derivadas da função objetivo, o algoritmo Levenberg-Maquardt é uma extensão do método de Newton-Rapshon e utiliza o mesmo algoritmo *backpropagation* na determinação das primeiras e segundas derivadas desta mesma função. A opção pelo algoritmo Levenberg-Maquardt no ajuste dos pesos de uma RNA torna o ajuste mais rápido e eficiente (MATLAB, 2004). Na forma clássica como o método de Newton-Rapshon é apresentado, o ajuste dos pesos da função objetivo é dada pela razão entre as primeiras e segundas derivadas ou a razão entre o vetor gradiente e a matriz hessiana.

$$\Delta w_{jk} = - \frac{\nabla \varepsilon \big|_{w_n}}{\mathbf{H}_{\varepsilon} \big|_{w_n}} \quad (4.38)$$

Se a função objetivo é quadrática, da forma da equação 4.16, pode-se demonstrar que MATLAB (2004), HAGAN e MENHAJ (1994):

$$\nabla \varepsilon \big|_{w_n} = \mathbf{J}^T(n) e(n) \quad (4.39)$$

$$\mathbf{H}_{\varepsilon} \big|_{w_n} = \mathbf{J}^T(n) \mathbf{J}(n) \quad (4.40)$$

onde $\mathbf{J}(n)$ é a matriz das primeiras derivadas da função erro em relação aos pesos e *vieses* das RNA ou, mais comumente, matriz Jacobiana.

Substituindo-se (4.39) e (4.40) em (4.38) tem-se

$$\Delta w_{jk} = -[\mathbf{J}^T(n) \mathbf{J}(n)]^{-1} \mathbf{J}^T(n) e(n) \quad (4.41)$$

Na equação (4.41), o termo $[\mathbf{J}^T(n) \mathbf{J}(n)]^{-1}$ é a forma simplificada de se obter a

matriz hessiana a partir das primeiras derivadas. No entanto, para que o método de otimização funcione, deve-se garantir que esta matriz seja definida positivamente para todo N e n . A forma algébrica utilizada para assegurar esta hipótese é adicionar a matriz diagonal $\mu \mathbf{I}$ ao termo $[\mathbf{J}^T(n)\mathbf{J}(n)]^{-1}$ da equação (4.41) obtendo-se assim o método de otimização de Levenberg-Maquardt (HAGAN e MENHAJ, 2004).

$$\Delta w_{jk} = -[\mathbf{J}^T(n)\mathbf{J}(n) + \mu \mathbf{I}]^{-1} \mathbf{J}^T(n)e(n) \quad (4.42)$$

Na equação (4.42), μ é um valor positivo escolhido no início do processo de otimização. Quando μ é próximo de zero os valores adicionados ao termo $[\mathbf{J}^T(n)\mathbf{J}(n)]^{-1}$ são muitos pequenos e o algoritmo se aproxima do método de Newton-Rapshon. Quando μ é muito grande o termo $[\mathbf{J}^T(n)\mathbf{J}(n)]^{-1}$ torna-se insignificante e o algoritmo se aproxima do método do gradiente descendente com η próximo a $1/\mu$. Durante o processo de otimização o valor de μ pode ser ajustado conforme a performance da função objetivo. Se a performance da função objetivo piora, ou seja, se os erros aumentam entre uma e outra iteração, então o valor de μ é multiplicado por um fator β previamente determinado. Se a performance diminui, então μ é dividido pelo fator β .

A matriz $\mathbf{J}(n)$ na equação (4.42) é obtida a partir do algoritmo *backpropagation* com pequenas modificações. O algoritmo *backpropagation* é uma forma de se obter a primeira derivada da função objetivo em relação aos pesos e *vieses* da RNA, ou seja, é uma forma para se obter o seguinte termo:

$$\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} \quad (4.43)$$

Diferenciando ambos os lados da equação (4.16) obtém-se uma relação direta entre o termo em (4.43) e as primeiras derivadas do erro em relação aos pesos e *vieses* da RNA.

$$\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} = 2e(n) \frac{\partial e(n)}{\partial w_{kj}(n)} \quad (4.44)$$

A matriz Jacobiana no método de otimização de Levenberg-Maquardt é obtida calculando-se o termo (4.43) em cada conexão através do algoritmo *backpropagation*. Conhecido (4.43), a primeira derivada do erro em relação aos pesos da RNA é obtido dividindo-se o termo (4.43) por duas vezes o erro.

$$\frac{\partial e(n)}{\partial w_{kj}(n)} = \frac{1}{2e(n)} \frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} \quad (4.45)$$

A diferencial do erro em relação aos *vieses* da RNA é obtida da mesma forma

$$\frac{\partial e(n)}{\partial b_k(n)} = \frac{1}{2e(n)} \frac{\partial \varepsilon(n)}{\partial b_k(n)} \quad (4.46)$$

4.11 PRECAUÇÕES PARA UMA RNA DO TIPO MLP

Além dos modelos de otimização e da função objetivo citados anteriormente, há outros elementos que influenciam no desempenho de uma RNA e que devem ser avaliados para melhorar o seu desempenho. A seguir são apresentados os cuidados que devem ser considerados para melhorar o desempenho de uma RNA.

4.11.1 Arquitetura

Uma diferença importante entre as RNA e os métodos estatísticos é a determinação da forma funcional $f(\bar{\mathbf{x}}_N, \mathbf{W})$ (FERNANDES et al., 1996), ou seja, a determinação da arquitetura da RNA. Definir uma arquitetura para uma RNA consiste em determinar o número de camadas e o número de neurônios em cada camada. FERNANDES et al. (1996), GALVÃO et al. (1996) e de HAYKIN (1994) afirmam

que para determinar a solução de qualquer problema de aproximação de uma função a um conjunto de dados é suficiente uma RNA com três camadas. Neste caso, definir a arquitetura de uma RNA se limita a determinar o número de entradas e o número de neurônios na camada intermediária. O número de saídas é consequência do problema proposto. Poderia se afirmar que as entradas são função das variáveis disponíveis, no entanto, TOKAR e JOHNSON (1999), citam em seu trabalho que as entradas são função do tamanho do banco de dados disponível, ou seja, o número de entradas pode ser tão grande quanto for o tamanho do banco de dados. O número de neurônios na camada intermediária é arbitrário, no entanto sabe-se que RNA com poucos neurônios nesta camada não são capazes de se ajustar ao problema proposto. Aumentar excessivamente o número de neurônios nesta camada aumenta o tempo gasto no treinamento e não generaliza o problema. Há várias regras matemáticas que de alguma forma auxiliam na determinação do número de neurônios nesta camada. O que se vê em termos práticos é um ajuste por tentativa. LIMA e FERREIRA FILHO (2003) criaram RNA com 3, 5, 8 e 10 neurônios na camada intermediária e avaliaram o desempenho destas RNA em termos de R^2 e da raiz do erro quadrático médio RMSE. THIRUMALAI AH E DEO (1998, 2000) utilizaram o algoritmo de correlação em cascata que a partir de um número inicial de neurônios na camada intermediária agrega neurônios um a um até que se obtenha o desempenho ótimo. ANMALA et al. (2000) também fizeram várias avaliações quanto à arquitetura da RNA. Nesta oportunidade eles fizeram o teste de RNA com quatro camadas obtendo resultados razoáveis, mas inferiores às RNA com três camadas.


4.11.2 *Epochs*

Epochs ou épocas representam o número de atualizações ocorridas nos pesos e vieses. As atualizações nos pesos podem ocorrer de duas formas: *on-line* ou em *batch*. (MATLAB, 2004). Quando a RNA opera *on-line* cada uma das linhas da matriz

X são apresentados à RNA individualmente, os pesos e *vieses* são atualizados e é registrado uma *epoch*. Quando a RNA opera em *batch* todos os valores do vetor X são apresentados à RNA, para, em seguida, ocorrer à atualização dos pesos. Cada vez que este processo ocorre também é registrada uma *epoch*. O processo mais comum de atualização dos pesos e registro do número de *epochs* é o *batch*. Este é o mesmo processo padrão para as RNA criadas no *software* MATLAB.

O número de *epochs* representa os estágios de aprendizado de uma RNA. No início do treinamento os erros são altos e as RNA são capazes de ajustar apenas funções mais simples. À medida que o número de *epochs* aumenta, o erro diminui e torna-se possível o mapeamento de funções mais complexas. No entanto, nem sempre aumentar o número de *epochs* significará um melhor desempenho da RNA no ajuste de funções. No início do processo de treinamento, os pesos rapidamente se ajustam para uma situação genérica; esta situação é representada por uma curva que passa próxima a todos os pontos. A figura 4.12 a seguir ilustra este processo.

FIGURA 4.12 – GENERALIZAÇÃO DAS RNA



FONTE: O autor

Os pontos em preto representam os dados a que se deseja ajustar uma função $f(\bar{x}_N, W)$ qualquer; a curva em azul é o resultado dos primeiros estágios do

treinamento, onde a RNA representa o “desenvolvimento”, a forma gráfica ou a forma genérica da função $f(\bar{\mathbf{x}}_N, \mathbf{W})$. Com o aumento do número de *epochs*, a RNA aproxima os pontos genéricos dos pontos particulares tomando a forma da curva vermelha. Este processo é conhecido por *overfitting*. Neste caso, o erro no processo de treinamento é menor, mas os pesos encontrados não representarão o problema investigado porque a RNA se ajusta ao problema particular da amostra utilizada durante o treinamento.

A investigação sobre o número de *epochs* ideal durante o treinamento de uma RNA está diretamente ligada à capacidade de generalização da RNA em relação ao problema proposto. ANMALA et al. (2000) fizeram uma investigação detalhada quanto à avaliação do número de *epochs* no desempenho das RNA em recursos hídricos. Cabe ainda ressaltar que o mesmo efeito alcançado pelo aumento excessivo do número de *epochs* no treinamento, também, é alcançado pelo número excessivo de neurônios nas camadas intermediárias.

4.11.3 Inicialização dos pesos

Por definição os pesos das conexões de uma RNA são responsáveis por armazenar o conhecimento da RNA sobre o problema proposto. Matematicamente foi visto que os pesos entre as conexões definem um ponto na superfície da função objetivo. Se os pesos em questão forem os pesos ótimos então o conjunto dos pesos deve representar o ponto de mínimo da mesma superfície. É dito deve pois nem sempre o processo de otimização conduzirá a solução para um mínimo global. É comum que o processo de otimização conduza a solução a um mínimo local. Esta abordagem foi feita por HSU et al. (1995). Neste trabalho, os autores citam que as RNA do tipo MLP geram superfícies muito irregulares e que o risco em chegar numa solução ótima local é muito alto. Se o ponto inicial estiver próximo a um mínimo local, a solução fatalmente recairá sobre este ponto. Evitar que a solução do problema recaia num mínimo local está diretamente correlacionada com a escolha dos pesos

iniciais. Isto significa que ao avaliar o desempenho de uma RNA em relação aos pesos é necessário alterar certo número de vezes os pesos iniciais, ou seja, mudar o ponto inicial na superfície de erro.

Além desta abordagem, é importante enfocar a escala dos valores dos pesos. HAYKIN (1994) e TAFNER et al. (1996) citam que pesos iniciais com valores muito altos tornam a ação das funções de transferência restritivas. Nesta situação os gradientes locais assumem valores pequenos, o que, por sua vez ocasionará uma diminuição da velocidade do processo de aprendizagem. Por outro lado, quando os valores iniciais são muito pequenos, o método de otimização pode operar em uma região muito plana HAYKIN (1994). TAFNER et al. (1996) citam que os pesos iniciais podem ser inicializados iguais a zero ou aleatoriamente entre -1 e 1. THIRUMALAIHA E DEO (1998, 2000) inicializaram os pesos de suas RNA aleatoriamente entre -0,5 e 0,5, ANMALA et al. (2000) inicializaram os pesos entre -0,3 e 0,3. HAYKIN (1994) cita uma técnica especial para inicialização dos pesos. Outro método particular para inicialização dos pesos pode ser visto em NGUYEN E WIDROW (apud HAGAN e MENHAJ, 1994).

4.11.4 Normalização

A entrada de dados num neurônio artificial é a combinação linear de todos os sinais que chegam até este mesmo neurônio. O resultado desta combinação linear é o estímulo para a função de transferência. Com exceção da função linear (figura 4.4), todas as outras funções apresentam ações restritivas para estímulos extremos, ou seja, no caso mais geral, quando o estímulo é maior que 1 ou menor que -1 as funções respondem com valores 0; 1 e -1. No entanto, na maior parte dos problemas práticos, sejam matemáticos, físicos ou de engenharia, os valores das entradas vão muito além da escala [-1,1]. Isto significa que quando a função de transferência utilizada for diferente da função linear os valores das entradas devem passar por algum tipo de transformação. Esta transformação de uma escala real para um escala compatível com

a função de transferência utilizada chama-se normalização. Em recursos hídricos as funções de transferência mais utilizadas são a sigmóide na camada intermediária e linear na camada de saída. As respostas da função sigmóide são todas positivas. Respostas negativas em geral são incoerentes com a realidade física dos problemas de recursos hídricos. Novamente afirma-se que não há uma regra clara sobre qual é o melhor tipo de normalização a ser adotada, SAJIKUMAR E THANDAVESWARA (1999) utilizaram RNA na modelagem do processo chuva mensal e utilizaram a equação (4.47) a seguir na normalização dos dados de entrada.

$$x_{norm} = FMIN + \frac{(x - x_{min})}{(x_{max} - x_{min})}(FMAX - FMIN) \quad (4.47)$$

onde x e x_{norm} representam, respectivamente, a variável a ser normalizada e o seu valor normalizado, x_{max} e x_{min} são os valores máximo e mínimo da variável a ser normalizada. $FMAX$ e $FMIN$ representam, respectivamente, os valores máximos e mínimos na escala normalizada. Estes valores devem ser selecionados cuidadosamente; eles não podem diminuir a escala dos dados porque isto influenciaria negativamente o treinamento; em contrapartida não podem exceder certos limites para permitir a extrapolação. No trabalho de SAJIKUMAR E THANDAVESWARA (1999) foi utilizado $FMAX = 0,95$ e $FMIN = 0,05$. LIMA e FERREIRA FILHO (2003) utilizaram a mesma equação proposta por SAJIKUMAR E THANDAVESWARA (1999), no entanto LIMA e FERREIRA FILHO (2003) utilizaram valores de $FMAX$ e $FMIN$ recomendados por HSU et al. (1995) e iguais a 0,9 e 0,1.

CAMPOLO et al. (1999) utilizaram as RNA para previsão vazões horárias. Estes autores propuseram uma equação muito semelhante àquela apresentada por SAJIKUMAR E THANDAVESWARA (1999).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} (0,9 - 0,1) \quad (4.48)$$

RAJURKAR et al. (2002,2004) normalizaram os dados de entrada na escala [0,1; 0,9]. Eles utilizaram a seguinte equação:

$$x_{norm} = 0,1 + 0,8 \left(\frac{x}{x_{max}} \right) \quad (4.49)$$

Tanto a forma proposta por SAJIKUMAR E THANDAVESWARA (1999), como a forma apresentada por CAMPOLO et al. (1999) e RAJURKAR et al. (2002,2004) tiveram a preocupação em especial em ajustar os dados reais a uma escala menor que a escala inicialmente abordada [-1,1]. O primeiro objetivo é não trabalhar com valores negativos. O segundo objetivo é permitir que os dados possam ser extrapolados. Outros autores como SPERB et al. (1999) desconsideraram estas hipóteses e apenas dividiram todos os valores da cada variável a ser normalizado pelo maior valor da variável, FMAX.

HAYKIN (1994) diz que a normalização dos dados afeta o processo de treinamento dos pesos. HAYKIN (1994) recomenda que uma normalização deve ser seguida de uma remoção da média dos dados originais, uma descorrelação das variáveis e finalmente uma equalização da covariância.

5. MODELO IPHMEN

O modelo IPHMEN é um modelo do tipo chuva-vazão conceitual, com memória e não linear, concentrado, determinístico com discretização do ciclo hidrológico na escala mensal desenvolvido pelo Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul (TUCCI, 1998).

A utilização do modelo depende, basicamente, de três etapas: a calibração, a validação e a simulação. A calibração consiste no ajuste dos parâmetros do modelo. A validação tem o objetivo de comprovar se os parâmetros ajustados na fase de calibração condizem com a realidade física. A simulação é a utilização do modelo propriamente dito.

Os parâmetros do modelo IPHMEN são:

a , b e c – parâmetros relacionados com a equação de Horton;

α - parâmetro relacionado com a evapotranspiração real;

Ks – coeficiente de propagação superficial;

Kb – tempo de variação do reservatório subterrâneo;

Cr – fator de escoamento superficial.

O modelo IPHMEN é dividido em três algoritmos básicos:

- i) distribuição de volumes;
- ii) escoamento superficial e subterrâneo;
- iii) otimização dos parâmetros.

A distribuição de volumes consiste na determinação quantitativa dos volumes escoados e infiltrados. Para determinar a distribuição dos volumes, o modelo IPHMEN utiliza a equação da continuidade.

$$\frac{dS}{dt} = I(t) - T(t) - E(t) \quad (5.1)$$

onde S é o armazenamento na camada superior do solo, $I(t)$ é a infiltração, $T(t)$ é a percolação e $E(t)$ a evapotranspiração.

No modelo IPHMEN, a infiltração é determinada através da equação de Horton representada na, equação (3.4). A equação (3.4) difere da equação (5.2) somente pelo termo e^{-kt} substituído aqui por h^t com h igual a e^{-k} .

$$I(t) = I_b + (I_0 - I_b)h^t \quad (5.2)$$

A percolação é determinada pela seguinte equação:

$$T(t) = I_b(1 - h^t) \quad (5.3)$$

A evapotranspiração real (E) pode ser estimada como uma relação da evapotranspiração potencial (EVT) e da capacidade de umidade do solo.

$$E = EVT \left[1 - e^{\left(-\alpha \frac{S}{S_{MAX}} \right)} \right] \quad (5.4)$$

onde S representa o armazenamento do solo no instante t ; S_{MAX} é o armazenamento máximo; α parâmetro relacionado a evapotranspiração real, quanto maior, maior a evapotranspiração real. A evapotranspiração potencial pode ser calculada por qualquer um dos métodos apresentados em 3.1.3.

Substituindo as equações (5.2) e (5.3) na equação diferencial (5.1), desconsiderando o termo da evapotranspiração, e integrando desde $t = 0$ até t obtém-se uma relação entre o armazenamento na bacia e os parâmetros da equação de Horton.

$$S = S_0 + \frac{I_0}{\ln h} (h^t - 1) \quad (5.5)$$

onde S_0 é o teor de umidade inicial, ou seja, teor no instante que inicia a percolação. A equação (5.5) “simula” o processo de infiltração, percolação e retenção de água do solo descrito em 3.1.4.

Isolando-se h^t nas equações (5.2) e (5.3) e substituindo na equação (5.5), resultam duas equações que relacionam o armazenamento com a infiltração e a percolação (TUCCI, 1998):

$$S(t) = ai + bi I(t) \quad (5.6)$$

$$S(t) = bt T(t) \quad (5.7)$$

onde ai , bi e bt são:

$$ai = \frac{-I_0^2}{\ln h(I_0 - I_b)} \quad bi = \frac{I_0}{\ln h(I_0 - I_b)} \quad bt = \frac{-I_0}{\ln h I_b} \quad (5.8)$$

Os parâmetros a , b e c do modelo IPHMEN são obtidos à partir de ai , bi e bt na forma $a = ai/bi$ ($-I_0$); $b = -1/bi$ e $c = 1/bt$.

A abordagem de se utilizar uma escala mensal distorce a definição dos parâmetros da equação de infiltração já que o processo ocorre em minutos ou, no máximo, em horas. Neste contexto os parâmetros dificilmente guardam alguma relação com os experimentos de Horton. Mesmo assim permitem estabelecer uma base para uma avaliação dos macroprocessos ao longo do tempo.

O máximo armazenamento do solo é dado em função de a , b e c através de (5.9):

$$S_{MAX} = \frac{a}{c - b} \quad (5.9)$$

A equação (5.1) pode ser analisada para duas condições específicas: quando a precipitação é maior que a capacidade de infiltração e quando a precipitação é menor que capacidade de infiltração. Se a capacidade de armazenamento não é máxima e a precipitação é maior que a capacidade de infiltração, esta pode ser representada pela equação de Horton (5.2). Caso contrário, se a precipitação é menor que a capacidade de infiltração, toda a água infiltra. No entanto, considerando a distribuição espacial ao longo do mês pode-se concluir que, em algum instante, a precipitação seja maior que a capacidade de infiltração e neste instante há escoamento superficial. Logo, para simular este comportamento, o modelo IPHMEN introduz um parâmetro que determina uma parcela de escoamento superficial gerada pela bacia em função da relação de P/I .

$$Pi = P \left[1 - \frac{(P/I)^2}{P/I + Cr} \right] \quad (5.10)$$

$$Vs = P \frac{(P/I)^2}{P/I + Cr} \quad (5.11)$$

onde Pi representa a parcela da precipitação que infiltra, Vs representa o volume escoado superficialmente e Cr o fator que representa o escoamento superficial. Quando maior o valor de Cr , menor o escoamento superficial.

Substituindo os termos de $I(t)$, $T(t)$ e $E(t)$ na equação (5.1), observa-se que a evapotranspiração real introduz uma não-linearidade na equação. A equação da evapotranspiração na forma linear é a seguinte (TUCCI, 1998):

$$E = F(S) \cong F(S_t) + \left(\frac{dF}{dS} \right)^t (S - S_t) \quad (5.12)$$

onde:

$$F(S_t) = d = \left[1 - e^{\left(\alpha \frac{S_t}{S_{MAX}} \right)} \right] \left(1 + \alpha \frac{S_t}{S_{MAX}} \right) \quad (5.13)$$

$$\left(\frac{dF}{dS} \right)^t (S - S_t) = eS = \left\{ \frac{\alpha EVT}{S_{MAX}} e^{\left(-\alpha \frac{S_t}{S_{MAX}} \right)} \right\} S \quad (5.14)$$

Com todos os termos lineares a equação diferencial (5.1) toma a seguinte forma:

$$\frac{dS}{dt} + rS = m \quad (5.15)$$

onde r e m variam conforme a precipitação seja maior ou menor que a infiltração. A solução da equação para o intervalo $t, t+1$ é a seguinte:

$$S(t+1) = \frac{m}{r} (1 - e^{-r\Delta t}) + S(t)e^{-r\Delta t} \quad (5.16)$$

Se $P > I$, $r = c-b+e$ e $m = a-d$, o volume escoado superficialmente é obtido algebricamente trabalhando-se com as equações (5.16), (5.6) e a equação (5.17) a seguir:

$$V_S = \left\{ P - \frac{I(t) + I(t+1)}{2} \right\} \Delta t \quad (5.17)$$

onde a infiltração $I(t)$ é obtida através da equação (5.6) em função de $S(t+1)$ estimado

pela da equação (5.16).

Se $P < I$ $r = c + e$ e $m = d$, o volume escoado superficialmente é determinado pelas equações (5.10) e (5.11). O volume percolado é estimado com base no balanço hídrico, ou seja:

$$S(t + I) = S(t) + Vi - Vp \quad (5.18)$$

onde Vi é o volume infiltrado e Vp o volume percolado. Sendo

$$Vi = [I(t) + I(t + I)]\Delta t/2 \quad (5.19)$$

$$Vp = S(t) - S(t + I) + Vi \quad (5.20)$$

Determinados os volumes escoados, infiltrado e percolados o IPHMEN calcula o escoamento superficial e subterrâneo. Ambos os escoamentos são determinados pelo modelo de reservatório linear simples. As equações para a propagação destes escoamentos são representadas a seguir:

$$Qs(t + I) = Qs(t) e^{(-\Delta t/Ks)} + Vs_{t+1}[1 - e^{(-\Delta t/Ks)}] \quad (5.21)$$

$$Qb(t + I) = Qb(t) e^{(-\Delta t/Kb)} + Vp_{t+1}[1 - e^{(-\Delta t/Kb)}] \quad (5.22)$$

$$Q(t + I) = Qs(t + I) + Qb(t + I) \quad (5.23)$$

onde Ks e Kb representam o tempo de esvaziamento do reservatório superficial e subterrâneo respectivamente. O valor de Ks deve ser em unidade de mês. Para bacias com tempo de traslado menor do que 5 dias, este valor é muito pequeno TUCCI (1998). O valor de Kb pode ser facilmente estimado com base em dados da bacia, ou estimado com dados de bacias semelhantes.

O modelo IPHMEN ainda possui uma rotina de otimização opcional. Esta


rotina otimiza os parâmetros através da minimização da função erro absoluto e erro relativo.

6. ESTUDO DE CASO

6.1 BACIA HIDROGRÁFICA

O estudo de caso foi desenvolvido para bacia hidrográfica do rio Jangada ou, mais especificamente, no trecho entre a nascente do rio até o posto fluviométrico Jangada. O rio Jangada é um afluente do rio Iguaçu pela margem esquerda, localizado próximo às cidades de União da Vitória (PR) e Porto União (SC), entre os paralelos $26^{\circ} 20'$ e $26^{\circ} 40'$ de latitude sul e os meridianos $51^{\circ} 30'$ e $51^{\circ} 10'$ de longitude oeste (figura 6.1). Outras informações sobre a bacia do rio Jangada e bacias adjacentes podem ser encontradas em MINE (1998) e CASTANHARO (2003).

FIGURA 6.1 – BACIA DO RIO JANGADA



A escolha pela bacia do rio Jangada foi condicionada a três fatores preponderantes:

- i) as dimensões da bacia: a área de drenagem deste a nascente até a seção de observação de Jangada é de 1055 Km², uma bacia pequena, considerada ideal para a aplicação de um modelo como o IPHMEN, um modelo concentrado. A opção por bacias com áreas maiores que a bacia escolhida não seria justificável em termos de comparação dos resultados do IPHMEN com os resultados das RNA. Os resultados do IPHMEN poderiam ser distorcidos uma vez que bacias de grandes dimensões são melhor representadas por modelos distribuídos, que consideram no processo de transformação da chuva em vazão questões como a variabilidade da precipitação em termos espacial e temporal.
- ii) a densidade dos postos de observação: a rede de monitoramento das variáveis hidrológicas na área de estudo é representada por um número de cinco postos pluviométricos dentro da bacia hidrográfica: Jangada (2651003), Serraria São Sebastião (2651010), Matos Costa (2651011), Faxinal dos Ribeiros (2651024), Rio Farias (2651027); e por dois postos pluviométricos próximos: Iratim (2651026) e Rio São João (2651030). E por um posto fluviométrico: Jangada (65370000), atualmente operando por telemetria (figura 6.2).
- iii) qualidade e extensão dos dados observados: as séries de dados dos postos dentro e próximos à área de estudo apresentam um pequeno número de falhas e número grande de registros. O período dos registros existentes em cada posto pode ser observada na figura esquemática 6.3.

6.2 DADOS

Os dados utilizados no estudo são função dos dados de entrada de um e outro modelo em estudo. O IPHMEN, como definido anteriormente, é um modelo conceitual concentrado. As variáveis de entrada deste modelo são: precipitação, evapotranspiração potencial e vazão média mensal num instante anterior, onde precipitação e evapotranspiração potencial ou são representados por uma única estação ou em termos médios. As RNA são modelos empíricos. Este tipo de modelo permite qualquer combinação das variáveis de entrada, ou seja, neste caso poder-se-ia definir, por exemplo, cada posto da bacia como uma entrada independente. No entanto, como o objetivo geral deste trabalho é confrontar os resultados de uma RNA com os resultados de um modelo conceitual, no caso, o IPHMEN, é coerente que os dados utilizados para calibrar um e outro modelo sejam semelhantes. Nestas circunstâncias, os dados utilizados neste trabalho são: a precipitação média, a evapotranspiração potencial e a vazão média mensal num instante anterior.


6.2.1 Precipitação Média

A bacia do rio Jangada possui sete postos pluviométricos, cinco destes dentro da bacia e dois próximos. Não obrigatoriamente todos os postos devem ser utilizados para calcular a precipitação média. É previsto, antes mesmo do cálculo da precipitação média, que postos pluviométricos com séries pequenas ou com dados inconsistentes possam ser desconsiderados. A análise quanto aos períodos das séries pode ser feita através da figura 6.3. Todos os postos apresentam em comum os períodos entre 1975 e 2000. No entanto, numa análise mais detalhada do posto Rio São João (2651030), observou-se a existência de um grande número de falhas. Sendo assim este posto não foi utilizado no cálculo da precipitação média e a análise da consistência dos dados foi feita a partir de todos os outros postos. Estes postos foram selecionados no período que inicia em março/76 e termina em julho/94. No total são 221 meses de observação com apenas 28 falhas distribuídas entre os seis postos. As falhas foram preenchidas através

do Método de ponderação regional que pode ser visto com mais detalhes em TUCCI (1993). A precipitação média e o desvio padrão médio para os dados selecionados são respectivamente 148,1 mm/mês e 33,2 mm/mês.


No estudo quanto à consistência dos dados pluviométricos fez-se a eliminação de dados duplicados, inspeção visual e verificação do comportamento global através da curva dupla-acumulativa ou dupla-massa (figura 6.4). Observa-se nesta figura que todos os postos com exceção do posto Matos Costa (2651011) e Iratim (2651026) apresentaram uma boa consistência.

FIGURA 6.4 – CURVA DUPLA-ACUMULATIVA



O posto de Matos Costa (2651011) apresenta um alinhamento paralelo superior. O posto de Iratim (2651026) um alinhamento paralelo inferior. No caso destes postos este comportamento está associado a um regime pluviométrico diferente ou à presença de eventos extremos e não os caracteriza como postos com dados inconsistentes. Sendo assim todos os postos foram considerados no cálculo da precipitação média.

A precipitação média é calculada utilizando-se o polígono de Thiessen. A figura 6.5, a seguir, apresenta estes polígonos.

FIGURA 6.5 – POLÍGONO DE *THIESSEN*

Os coeficientes de *Thiessen* utilizados são apresentados na tabela 6.1 a seguir.

TABELA 6.1 – COEFICIENTES DE *THIESSEN*

POSTO	JANGADA (2651003)	SERRARIA S. S. (2651010)	MATOS COSTA (2651011)	FAXINAL (2651020)	IRATIM (2651026)	RIO FARIAS (2651027)
COEFICIENTE	0.119	0.206	0.208	0.143	0.122	0.201


6.2.2 Evapotranspiração potencial

A evapotranspiração potencial pode ser obtida através da observação diária dos volumes evapotranspirados ou através de métodos indiretos baseados em variáveis meteorológicas. As observações diárias são feitas através de equipamentos específicos como o lisímetro (TUCCI, 1993) e valem apenas para pequenas áreas homogêneas. Através dos métodos indiretos, a evapotranspiração potencial é calculada a partir de informações meteorológicas como insolação, temperatura, umidade do ar e velocidade do vento. No entanto a bacia do rio Jangada não possui estação meteorológica com observações de temperatura, velocidade do vento, umidade e outras variáveis que possibilitem o cálculo da evapotranspiração potencial. Neste caso, determinou-se uma estação próxima, localizada numa região com características semelhantes e com informações compatíveis com as séries de precipitação. A estação meteorológica escolhida foi Teixeira Soares (02550025), localizada no município de mesmo nome. As principais informações desta estação são a velocidade do vento, a umidade relativa, a temperatura e o número de horas de insolação durante o dia. Estes registros têm início em março/76 e término em julho/96 com apenas duas falhas, janeiro e fevereiro de 1990. Estas falhas foram preenchidas com a média simples da evapotranspiração calculada para estes mesmos meses.

A evapotranspiração utilizada neste trabalho foi calculada através do método combinado ou de Penman. O método de Penman é recomendado por MÜLLER (1995) para bacias localizadas no estado do Paraná. Detalhes sobre este método podem ser encontrados em MÜLLER (1995), TUCCI (1993) e SANTOS (2001).

As séries de evapotranspiração calculadas, ano a ano, são apresentadas graficamente na figura 6.6 a seguir


FIGURA 6.6 - EVAPOTRANSPIRAÇÃO POTENCIAL



6.2.3 Vazão

A série de vazões utilizadas se refere à estação fluviométrica Jangada (65370000) com observações desde 1945. A avaliação quanto à qualidade dos dados também foi feita em termos da verificação da dualidade dos dados registrados e de inspeção visual. Além disto, verificou-se qualitativamente a reposta da bacia em função dos eventos pluviométricos. Outra análise, simples, foi observar o hietograma e hidrograma representados na figura 6.7. O objetivo foi verificar se o aumento dos volumes precipitados representava um aumento dos volumes escoados.

FIGURA 6.7 – HIDROGRAMA DE CHEIA



As precipitações em cada posto, as precipitações médias, as evapotranspirações potenciais e as vazões médias mensais são apresentados no apêndice I.

7. APLICAÇÃO DOS MODELOS

O objetivo de um modelo qualquer é avaliar quais as respostas ou o comportamento de um sistema a partir de diversos estímulos. O objetivo de um modelo chuva vazão é avaliar qual a resposta de uma bacia hidrográfica em termos de vazão a partir de um evento de precipitação aleatório. Os principais estímulos de um modelo chuva-vazão são precipitação, evapotranspiração e vazão um instante anterior. A relação entre precipitação e vazão depende das características da bacia. Em modelos conceituais, como o modelo IPHMEN, as características da bacia são representadas por parâmetros e equações que procuram representar os vários processos hidrológicos envolvidos. Aplicar um modelo destes a uma bacia consiste em ajustar os parâmetros do modelo conforme as características desta bacia. Em modelos empíricos a relação entre precipitação e vazão é determinada pelo ajuste de funções matemáticas arbitrárias. O número de parâmetros depende da função específica que se pretende utilizar. As RNA são funções específicas. Aplicar uma RNA na modelagem do processo de transformação da precipitação em vazão consiste em ajustar os pesos e vieses da RNA. Neste caso o ajuste dos pesos e vieses é feito através de técnicas de otimização e não guardam nenhuma relação com as características físicas da bacia.

O ajuste dos parâmetros de um modelo qualquer, independentemente de ser conceitual ou empírico, pode ser dividido em duas etapas. Na primeira etapa, os parâmetros são modificados passo a passo. O objetivo a cada passo é ajustar, ao máximo, as repostas do modelo à resposta do sistema observada anteriormente. Esta etapa é conhecida por etapa de calibração do modelo. A segunda etapa é a etapa de validação. O objetivo é verificar se os parâmetros ajustados na primeira etapa são capazes de responder corretamente a estímulos diferentes daqueles utilizados durante a calibração.

7.1 REDES NEURAIS ARTIFICIAIS - RNA

Uma RNA é uma ferramenta matemática idealizada a partir do funcionamento do cérebro humano com a capacidade de identificar a relação entre variáveis de entrada e saída. Na prática a utilização desta ferramenta recebe o mesmo enfoque de modelos de regressão. Num modelo de regressão uma curva qualquer é ajustada a uma amostra de dados. A curva escolhida depende das características do problema estudado. As curvas mais comuns são linear, logarítmica, exponencial, potencial, polinomial e linear múltipla. A opção por uma curva exponencial, por exemplo, na solução de um problema, significa em determinar a curva exponencial particular de uma família de curvas que minimize os erros entre os dados observados e os dados obtidos a partir desta mesma curva. Os parâmetros desta curva particular são tidos como os parâmetros ótimos. Na prática os parâmetros ótimos são obtidos através de técnicas de otimização. Uma RNA é uma forma alternativa da solução deste mesmo tipo de problema, ou seja, para uma RNA determinada, os pesos e *vieses* da RNA, são ajustados, passo a passo, com o mesmo objetivo de minimizar os erros entre os valores observados e os valores calculados pela RNA. No entanto, as RNA apresentam características particulares quanto à forma funcional. Toda RNA é uma função. A forma funcional de uma RNA é determinada pela sua arquitetura, ou seja, RNA com arquiteturas diferentes significam ajustes de funções distintas, tão distintas quanto o ajuste de funções lineares ou exponenciais num problema de regressão.

7.1.1 Modelos Propostos

O problema de ajustar uma RNA na solução de um problema chuva-vazão é um problema particular do ajuste de uma função a uma amostra de dados. O processo chuva-vazão é um processo não linear e a forma funcional para o ajuste destes dados é desconhecida. Neste caso, aplicar uma RNA não significará apenas escolher uma RNA

qualquer e ajustar seus pesos e vieses à amostra de dados observados, mas sim investigar, variando a arquitetura da RNA, uma forma funcional mais próxima do comportamento dos dados observados.

As RNA utilizadas neste trabalho são do tipo MLP com três camadas, uma camada de entrada, uma intermediária e uma camada de saída. Todos os neurônios da camada intermediária possuem uma função de transferência do tipo sigmóide. A função de transferência na camada de saída é a função linear.

A metodologia adotada na investigação da arquitetura da RNA foi a de variar o número de neurônios na camada de entrada e o número de neurônios da camada intermediária. Foram criados seis modelos distintos. Cada modelo expressa a relação entre um conjunto de entrada e a saída. A saída é sempre a vazão. As entradas variam conforme a tabela 7.1 a seguir.

TABELA 7.1 – MODELOS PROPOSTOS

MODELO	ENTRADAS	SAÍDAS
1	$P^2(t) \text{ EVT}^2(t)$	$Q^3(t)$
2	$P(t) \text{ EVT}(t) \text{ Q}(t-1)$	$Q(t)$
3	$P(t-1) P(t) \text{ EVT}(t-1) \text{ EVT}(t)$	$Q(t)$
4	$P(t-1) P(t) \text{ EVT}(t-1) \text{ EVT}(t) \text{ Q}(t-1)$	$Q(t)$
5	$P(t-2) P(t-1) P(t) \text{ EVT}(t-2) \text{ EVT}(t-1) \text{ EVT}(t)$	$Q(t)$
6	$P(t-2) P(t-1) P(t) \text{ EVT}(t-2) \text{ EVT}(t-1) \text{ EVT}(t) \text{ Q}(t-2) \text{ Q}(t-1)$	$Q(t)$

NOTA: 1) P – precipitação média mensal (mm/mês), 2) EVT – evapotranspiração potencial (mm/mês) e 3) Q – vazão média mensal (m^3/s)

Para cada modelo foi criada uma RNA com 3, 5, 8 e 10 neurônios na camada intermediária totalizando 24 RNA. A opção em variar a arquitetura não apenas em termos da camada intermediária, mas também em relação à camada de entrada possibilita, além de novas formas funcionais, a avaliação da sensibilidade das RNA em função das variáveis de entrada.

A proposta de criar modelos e variar o número de neurônios na camada intermediária segue os mesmos moldes do trabalho de LIMA e FERREIRA FILHO (2003). No entanto as variáveis de entrada para cada um dos modelos utilizados por por estes autores são distintas das variáveis utilizadas aqui neste trabalho.

7.1.2 Treinamento

Definido todas as RNA, a próxima etapa é o treinamento da RNA. Treinar uma RNA significa ajustar ou calibrar os pesos e vieses da RNA. “Treinar” é um termo particular das RNA análogo ao termo “calibrar”. Este termo segue a mesma idéia de que as RNA possuem capacidade de aprendizado semelhante ao cérebro humano e que, para ela aprender, precisa ser ensinada, treinada.

Todas as 24 RNA foram treinadas utilizando a técnica de otimização de Levenberg-Maquardt. A motivação pela utilização do Levenberg-Maquardt no treinamento das RNA se justifica por ser esta uma ótima técnica para aproximação de relações não-lineares, por ser rápida e por ser uma técnica já utilizada por outros autores como LIMA e FERREIRA FILHO (2003) e SPERB et al. (1999) no treinamento de RNA com propósitos semelhantes e que apresentaram bons resultados.

O algoritmo Levenberg-Maquardt é uma “extensão” da técnica de otimização de Newton-Raphson com a particularidade de que as primeiras e as segundas derivadas da função objetivo são calculadas em termos do Jacobiano da função erro e de que cada elemento desta matriz, um a um, é calculado utilizando o *backpropagation*. Esta técnica possui dois parâmetros, μ e β , que devem ser definidos antes do início do processo de treinamento. Os valores adotados para μ e β são os mesmos utilizados por HAGAN e MENHAI (2004) e valem respectivamente 0,1 e 10. Estes valores foram adotados para todas as RNA.

Na prática o treinamento das RNA consiste em, a partir de um conjunto de entradas e saídas conhecidas, apresentar as entradas à RNA, calcular uma saída e comparar a saída calculada com a saída desejada. Os pesos e vieses da RNA são ajustados através do algoritmo de treinamento Levenberg-Maquardt que calcula o ajuste dos pesos e vieses em cada conexão a partir do erro entre a saída calculada e a saída conhecida. Este processo foi realizado em modo *batch*.

Além da forma funcional da RNA foram considerados durante o processo de

treinamento a influência do número de *epochs*, da inicialização dos pesos e da extensão das séries de dados.

Epochs – durante o treinamento, os pesos e *vieses* das RNA são ajustados até que o algoritmo de treinamento alcance algum critério de parada. Os principais critérios de parada são o número de *epochs* e o erro mínimo. Como descrito na revisão bibliográfica o número de *epochs* representa o número de vezes que uma amostra de dados é apresentada à RNA e os pesos e *vieses* atualizados. ANMALA et al. (2000) fizeram uma análise sobre a influência do número de *epochs*, no entanto não fizeram nenhuma recomendação em especial. Sabe-se que, no caso de um número excessivo de *epochs*, as RNA memorizam os dados da amostra e não generalizam o problema proposto (*overfitting*). Isto posto e sabendo que o algoritmo de treinamento Levenberg-Maquardt é um algoritmo de convergência rápida as RNA aqui pré-estabelecidas, 24 RNA, foram treinadas arbitrariamente com 30, 60 e 90 *epochs*. O erro mínimo não foi utilizado como critério de parada.

Inicialização dos pesos - Matematicamente, o objetivo do algoritmo de treinamento é alcançar o ponto mínimo de uma superfície geométrica. A combinação dos pesos e *vieses* iniciais representam um ponto desta superfície. A cada iteração este ponto muda de posição em direção ao ponto de mínimo. No entanto, o processo de otimização dos pesos de uma RNA envolve superfícies com mais de três dimensões, com a presença de mínimos locais. Se os pesos e *vieses* iniciais estiverem próximos de um mínimo local, fatalmente a solução do problema recairá sobre este mínimo. Sendo assim, uma RNA em particular não pode ser treinada uma única vez e, sim, terminado um primeiro treinamento esta RNA deve ter seus pesos reinicializados e ser treinada novamente. Os pesos e *vieses* de todas as RNA foram inicializados aleatoriamente no intervalo $[-1, 1]$. Cada RNA foi inicializada seis vezes.

Extensão das séries de dados – a extensão das séries de dados esta


relacionada com a quantidade de dados utilizados para o treinamento e validação das RNA. Acredita-se que quanto maior a quantidade de dados melhor a generalização do problema proposto ANMALA et al. (2000). TOKAR e JOHNSON (1999) relacionaram a quantidade de dados utilizado no treinamento com o número de entradas de uma RNA em particular e afirmam que o aumento do número de entradas deve ser seguido do aumento do banco de dados. ELSHORBAGY et al. (2000) utilizaram apenas 50 dados para treinamento e validação na previsão da vazão anual. SAJIKUMAR E THANDAVESWARA (1999) utilizaram 98 dados na previsão de vazão mensal, 60 para treinamento e 48 para validação. LIMA E FERREIRA FILHO (2003) utilizaram 456 dados na solução de um problema chuva-vazão mensal. Os dados foram separados em seis conjuntos de entrada e saída. O primeiro conjunto com 60 dados para treinamento e 396 para validação. O segundo conjunto com 120 dados para treinamento e 336 para validação. A cada novo conjunto aumentou-se em 60 dados o conjunto de treinamento e diminui-se em 60 dados o conjunto de validação. O último conjunto utilizou 360 para treinamento e 96 para validação.

A mesma metodologia adotada por LIMA E FERREIRA (2003) foi adotada aqui para avaliar a influência da extensão das séries de dados no treinamento da RNA. O número de dados disponíveis é de 221. Estes dados foram separados em 3 conjuntos de dados com 60, 120 e 180 dados de treinamento e 161, 101 e 41 dados de validação respectivamente. Cada um dos conjuntos de dados foi separado numa planilha Excel.

O método utilizado para avaliar a influência de cada um destes elementos no treinamento das RNA segue o diagrama da figura 7.1.

Determinada uma RNA esta é treinada utilizando os três conjuntos de entrada. Antes do início do treinamento todas as entradas foram normalizadas entre 0,1 e 0,9 utilizando a equação (4.47) proposta por SAJIKUMAR E THANDAVESWARA (1999).

FIGURA 7.1 – MÉTODO DE TREINAMENTO



Considerando a primeira entrada, a RNA é inicializada e treinada 30, 60 e 90 *epochs*. Ao final de cada treinamento, com os pesos e *vieses* ajustados, a RNA é simulada gerando três respostas. Estas repostas são armazenadas, os pesos e *vieses* da RNA são reinicializados e a RNA novamente treinada 30, 60 e 90 *epochs* gerando 3 novas respostas. A RNA é inicializada 6 vezes e para cada inicialização treina-se a RNA 30, 60 e 90 *epochs*. Isto significa 18 repostas cada vez que uma RNA é treinada utilizando uma entrada particular. Como a RNA é treinada para todas as entradas são 54 repostas para cada RNA. Sendo 24 RNA, são 1296 repostas ao final do processo de treinamento. Cada resposta é o resultado de uma combinação diferente entre o número de entradas da RNA (modelo), o número de neurônios na camada intermediária, o número de *epochs*, inicialização dos pesos e da extensão das séries de dados.

O treinamento de uma RNA a partir do conjunto de entrada 1 significa que, independente do número neurônios na camada de entrada cada uma das variáveis entradas possui 60 dados. A RNA é treinada utilizando estes 60 dados e a validação é feita utilizando os 161 dados restantes. Os treinamentos utilizando os conjuntos de entradas 2 e 3 seguem a mesma regra, no caso, são 120 e 180 dados para treinamento e 101 e 41 dados para validação, respectivamente. Em todas as simulações as repostas foram calculadas a partir dos dados de treinamento e validação.

Todo o processo de treinamento foi desenvolvido no *software* MATLAB. O MATLAB possui uma biblioteca de funções específicas para criar, treinar e simular RNA (HANSELMAN e LITTLEFIELD, 1999). Para avaliar a influência dos elementos propostos no treinamento da RNA foi elaborado um algoritmo no próprio MATLAB que cria as RNA, manipula os dados conforme a metodologia proposta, treina, simula, calcula as estatísticas dos resultados e armazena todas as respostas num arquivo de saída. As estatísticas consideradas para a avaliação da performance de cada RNA foram (SPIGEL, 1993):

i) coeficiente de correlação

$$R = \frac{N \sum (Q_0 Q_c) - \sum Q_0 \sum Q_c}{\sqrt{[N \sum Q_0^2 - (\sum Q_0)^2][N \sum Q_c^2 - (\sum Q_c)^2]}} \quad (7.1)$$

onde Q_0 é a vazão observada e Q_c é a vazão calculada

ii) raiz do erro médio quadrático (*root mean square error – RMSE*)

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_o - Q_c)^2}{N}} \quad (7.2)$$

iii) diferença percentual entre os volumes escoados e os volumes calculados pela RNA.

$$DV = \left(\frac{\sum Q_o - \sum Q_c}{\sum Q_o} \right) \cdot 100 \quad (7.3)$$

A diferença percentual de volume na forma como está descrita na equação 7.3 significa que valores positivos para esta diferença representarão minimização das vazões, conseqüentemente, valores negativos representarão maximização. As diferenças de volumes também são apresentadas no arquivo de saída.

7.2 IPHMEN

O IPHMEN é um modelo que a partir de uma interpretação matemática do ciclo hidrológico define a relação entre chuva e vazão na escala mensal. Para determinar esta relação o IPHMEN possui sete parâmetros entre eles três relacionados com os parâmetros da equação de Horton, a , b , e c , dois relacionados ao escoamento superficial e sub-superficial, Ks e Kb , respectivamente, e mais dois relacionados com a evapotranspiração e com a parcela da precipitação que infiltra, α e Cr respectivamente. A aplicação do IPHMEN consiste, primeiramente, no ajuste destes parâmetros aos dados observados na bacia hidrográfica. A primeira parte deste processo é o ajuste propriamente dito. A segunda é a validação. Ao final do processo de validação o modelo estará habilitado a simulações.

Para o ajuste dos parâmetros do IPHMEN há duas alternativas, a primeira é a utilização da rotina de otimização dos parâmetros e a segunda é o ajuste por tentativa e erro. A rotina de otimização dos parâmetros é opcional e faz parte do algoritmo do modelo IPHMEN. A opção por uma ou outra alternativa é muito subjetiva, isto ocorre porque na prática a utilização das técnicas de otimização em grande parte recaem na necessidade de um refinamento no ajuste por tentativa e erro. Neste caso, alguns

hidrólogos com certa prática com o modelo preferem eliminar a necessidade de otimizar primeiramente os parâmetros e ajustar desde o início por tentativa e erro. Outro adendo quanto à utilização da otimização é de que por ser um processo matemático, o resultado deste processo pode, em alguns casos, afastar o valor dos parâmetros daqueles possíveis quando relacionados com as características da bacia. GALVEZ et al. (2001) fizeram a opção no ajuste dos parâmetros pela técnica de otimização automática. Aqui neste trabalho faz-se a opção pelo ajuste por tentativa e erro.

O modelo IPHMEN foi calibrado três vezes, uma para cada conjunto de dados. Os conjuntos de dados são os mesmos conjuntos utilizados para treinar as RNA, ou seja, o primeiro conjunto com 60 dados, o segundo com 120 e o terceiro com 180 dados. Esta metodologia foi adotada para poder confrontar os resultados entre as RNA e o modelo IPHMEN. Quando uma RNA foi treinada, por exemplo, com 60 dados é simulado neste instante que há apenas 60 dados para treinamento e que a RNA deverá identificar a relação entre chuva e vazão a partir destes mesmos dados. O mesmo deve ocorrer na calibração do IPHMEN, os parâmetros deverão ser ajustados tentando aproximar ao máximo o hidrograma observado do hidrograma calculado, simulando que não se conheça os eventos futuros. A consideração de eventos futuros pode, em certo instante, melhorar os resultados da validação e prejudicar o confronto dos resultados. Este enfoque caracteriza uma situação real em que um pequeno ou um grande número de dados pode prejudicar a calibração de um modelo conceitual. Este enfoque também torna o confronto dos resultados mais verdadeira.

Para ajustar o primeiro conjunto de dados foram necessários 107 tentativas, para o segundo 77 tentativas e para o terceiro 35. Os parâmetros ajustados a cada conjunto de dados são apresentados na tabela 7.2.

Após a calibração fez-se a simulação para validação dos parâmetros. Da mesma maneira que para as RNA, utilizaram-se para a validação os dados completos, por exemplo, para a entrada 1, 60 dados, utilizaram-se os 161 dados na validação e da mesma forma procedeu-se para os outros dois casos.

TABELA 7.2 – PARÂMETROS AJUSTADOS DO MODELO IPHMEN

ENTRADA	TENTATIVAS	A	B	c	Ks	Kb	Cr	α
1-60	107	317,5	-2,7	0,39	0,4	2,0	0,8	5,2
1-120	77	216	-3,4	0,18	0,46	2,0	0,65	4,3
1-160	35	313	-3,2	0,25	0,39	2,0	0,67	4,4

8. RESULTADOS E DISCUSSÕES

8.1 REDES NEURAIS ARTIFICIAIS - RNA

Todos os resultados obtidos durante o processo de treinamento e validação são apresentados no apêndice II. A metodologia adotada na nomenclatura das RNA segue a seguinte regra. Todas as RNA são identificadas pela letra ‘R’. O primeiro número após a letra ‘R’ refere-se ao modelo utilizado; este número varia de um a seis conforme a tabela 7.1. Ele identifica o número de entradas e quais são as entradas. O número seguinte refere-se ao número de neurônios na camada intermediária. O número 1, por exemplo, significa que a RNA possui três neurônios na camada intermediária, o número 2, cinco neurônios, os números 3 e 4, oito e dez neurônios respectivamente. A combinação entre o número de entradas e o número de neurônios na camada intermediária representa as 24 RNA criadas. Os próximos seis caracteres representam a combinação entre o número da inicialização, o número de *epochs* e a entrada utilizada. O primeiro caractere depois do número que identifica o número de neurônios na camada intermediária é uma letra. Esta letra representa a inicialização. A primeira inicialização é representada pela letra ‘A’ e a última pela letra ‘F’. A inicialização ‘A’, por exemplo, não significa um conjunto de valores particulares e sim, significa, a primeira inicialização para uma RNA em particular. Duas RNA com um primeiro conjunto de pesos e *vieses*, inicialização ‘A’, não apresentam os mesmos valores até mesmo por que as RNA são diferentes, número de pesos e *vieses* diferentes. Os valores dos pesos e *vieses* foram determinados aleatoriamente no intervalo $[-1,1]$. Os próximos dois caracteres representam o número de *epochs*. Estes caracteres assumem os valores 30, 60 ou 90. Por fim, os últimos três caracteres representam as entradas utilizadas no treinamento. A letra ‘E’ refere-se à palavra ‘entrada’, os dois números que seguem a letra ‘E’ referem-se ao número de entradas conforme a tabela 7.1 e a extensão da série. Se este último caráter for 1 então a RNA

foi treinada utilizando 60 dados, se o número for 2 ou 3 então a RNA foi treinada utilizando 120 e 180 dados respectivamente.

Dos 1296 resultados armazenados durante o treinamento foram selecionados 108 resultados para análise. Estes resultados são apresentados nas tabelas 8.1 a 8.6 a seguir. Cada uma das tabelas apresenta os melhores resultados, respectivamente, para as inicializações A, B, C, D, E e F. São 18 resultados a cada inicialização. A regra estabelecida na seleção dos melhores resultados foi, determinado um modelo e uma entrada, por exemplo, modelo 1 e entrada 1, selecionar o modelo com melhor desempenho.

Cada um dos modelos utilizados (tabela 7.1) é representado por quatro RNA as quais, fixado o conjunto de entrada, são treinadas 30, 60 e 90 *epochs*. Isto significa 12 resultados possíveis para cada modelo. A seleção do melhor resultado para cada modelo é feita entre estes 12 resultados. Para o modelo 1 e a entrada 1, tabela 8.1, o melhor resultado foi registrado para a RNA com três neurônios na camada intermediária treinada 90 *epochs*. O processo de seleção dos melhores resultados foi feita de maneira independente para cada uma das seis inicializações.

O critério utilizado na seleção de cada um dos modelos foi avaliar a capacidade de generalização da RNA através do coeficiente de correlação entre os dados calculados e observados para o período de validação. O RMSE na tabela de resultados indica a performance relativa de diferentes modelos para um mesmo período de calibração e verificação (LIMA e FERREIRA FILHO, 2003), e não foi utilizado como critério de comparação. Quando uma mesma RNA apresentou o mesmo desempenho para 30, 60 e 90 *epochs* foi considerado a melhor RNA aquela com o menor número de *epochs* no treinamento.

Os períodos menores de validação para os modelos 2, 3, 4, 5 e 6 estão relacionados com as variáveis de entrada destes mesmos modelos. Nos modelos 2, 3 e 4 há variáveis de entrada de um mês anterior ($t-1$). Isto significou na organização ou reordenação dos dados em diminuir a extensão da série em um mês, no caso, 220 meses. Nos modelos 5 e 6 há variáveis de entrada de dois meses anteriores ($t-2$, $t-1$).

Isto significa diminuir a extensão da série em dois meses, ou seja, 219 meses.

TABELA 8.1 – MODELOS SELECIONADOS NA INICIALIZAÇÃO A

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	90	1-60	79.43	9.6	0.1	61-221	83.03	12.67	3.28
2	8	30		86.61	7.91	-0.13		84.37	12.19	1.39
3	3	30		93.39	5.66	0	61-220	84.39	12.1	0.89
4	3	30		93.39	5.66	0		84.41	12.08	0.99
5	3	30		93.53	6.37	10.9	61-219	86.76	11.77	-8.3
6	8	30		97.37	3.6	0.43		83.57	12.43	2.53
1	3	90	1-120	88.9	10.63	0.01	121-221	75.3	11.9	4.22
2	3	30		92.81	8.64	0		83.93	9.78	5.33
3	3	60		96.13	6.4	0	121-220	83.31	10.69	3.06
4	3	90		95.73	6.71	0		86.92	8.95	4.55
5	3	90		96.29	6.25	0	121-219	86.42	9.17	6.61
6	8	60		96.71	5.9	0		86.82	9.1	6.05
1	5	30	1-180	88.04	10.33	0.03	181-221	70.68	13.34	2.2
2	3	30		61.31	9.53	0.28		78.86	10.23	5.25
3	10	90		97.74	4.61	0	181-220	86.58	8.56	8.79
4	8	30		95.05	6.78	0.01		88.67	8.11	7.15
5	10	30		94.97	5.84	0	181-219	85.15	9.53	4.31
6	3	60		95.38	6.55	0		86.48	9.22	8.54

TABELA 8.2 – MODELOS SELECIONADOS NA INICIALIZAÇÃO B

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	90	1-60	79.37	9.62	0.04	61-221	82.12	13.03	3.6
2	10	90		84.06	8.57	0.03		90.34	9.84	-0.17
3	3	30		93.39	5.66	0	61-220	84.39	12.1	0.89
4	3	30		94.65	5.11	-0.05		83.26	12.53	3.03
5	3	30		93.66	5.54	0	61-219	84.96	11.91	0.87
6	10	30		97.16	3.74	0.19		82.34	12.91	-4.05
1	8	30	1-120	90.41	9.92	-0.09	121-221	74	13.5	-0.73
2	3	30		94.5	7.59	0		86.08	9.16	3.49
3	5	30		96.43	6.15	0.04	121-220	84.07	10.39	3.9
4	3	30		96.56	6.04	-0.02		84.94	9.8	4.14
5	3	30		96.56	6.03	0.01	121-219	87.01	9.01	3.2
6	5	30		96.8	5.22	-0.28		86.67	9.13	4.16
1	8	30	1-180	88.47	10.18	-0.28	181-221	71.36	13.23	1.41
2	5	30		92.71	8.18	-0.07		80.12	10.54	2.53
3	5	90		94.83	6.92	0.1	181-220	86.35	8.94	6.57
4	8	90		96.95	5.35	0		89.84	8.68	1.28
5	5	30		95.16	6.71	0.01	181-219	84.98	9.69	8.96
6	3	60		95.79	6.26	-0.21		84.74	9.78	7.02

TABELA 8.3 – MODELOS SELECIONADOS NA INICIALIZAÇÃO C

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	90	1-60	79.43	9.6	0.01	61-221	82.98	12.69	3.22
2	8	90		85.87	8.11	0		90.35	10.43	3.67
3	8	90		94.99	4.95	0	61-220	85.58	11.87	-0.32
4	5	60		96.25	4.29	0		86.11	11.49	-0.82
5	3	30		93.66	5.54	0	61-219	84.96	11.91	0.87
6	3	90		97.47	3.54	0		87.74	10.46	5.86
1	10	30	1-120	90.28	9.98	-0.07	121-221	74.07	13.1	0.43
2	8	30		95.02	7.23	0.04		84.43	9.65	0.49
3	10	30		96.35	6.22	-0.49	121-220	84.59	10.03	2.35
4	5	30		95.91	6.6	-1.96		86.22	9.16	2.2
5	3	30		96.12	6.4	0	121-219	87.61	8.79	5.91
6	3	60		97.2	5.45	0		85.87	9.35	5.86
1	3	30	1-180	88.15	10.29	-0.08	181-221	71.67	12.75	1.02
2	5	30		93.9	7.5	0.34		85.35	8.78	8.96
3	10	30		95.99	6.13	-1.86	181-220	87.34	8.32	8.77
4	5	30		95.53	6.41	0.46		89.18	7.84	3.35
5	5	60		94.73	6.99	0	181-219	85.7	9.42	9.51
6	8	30		96.11	6.03	-0.15		87.4	9.23	7.93

TABELA 8.4 – MODELOS SELECIONADOS NA INICIALIZAÇÃO D

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	90	1-60	79.43	9.6	0	61-221	82.94	12.7	3.24
2	3	30		84.12	8.56	-0.28		88.58	10.74	1.6
3	10	90		96.27	4.3	-1.35	61-220	82.19	12.84	1.26
4	3	30		93.39	5.66	0		84.44	12.08	0.99
5	5	30		97.16	3.74	0.01	61-219	85.5	12.41	-6.09
6	3	30		94.41	5.21	0		85.91	11.61	1.8
1	3	30	1-120	89.07	10.55	0.15	121-221	74.98	12.07	3.87
2	3	30		92.74	8.68	0		83.65	9.87	5.5
3	3	60		95.88	6.6	0	121-220	86.99	8.96	4.8
4	5	30		96.72	5.9	0		87.25	8.9	1.92
5	3	30		96.63	5.97	0	121-219	86.37	9.38	4.13
6	5	60		97.05	5.6	0		87.45	8.88	4.54
1	10	30	1-180	89.42	9.79	-3.04	181-221	69.1	13.19	-3.37
2	5	60		93.21	7.9	0		84	9.15	3.62
3	8	30		94.43	7.18	0.02	181-220	86.38	8.87	7.6
4	5	60		94.91	6.87	0		89	7.72	4.73
5	3	90		95.01	6.8	-0.01	181-219	86.72	8.94	7.23
6	3	30		94.78	6.96	0		85.88	9.39	9.38

TABELA 8.5 – MODELOS SELECIONADOS NA INICIALIZAÇÃO E

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	30	1-60	80.76	9.32	-0.19	61-221	81.62	13.19	5.28
2	10	30		87.92	7.54	-0.02		86.44	11.85	3.78
3	10	60		94.37	5.24	0	61-220	83.8	12.3	-1.09
4	5	30		95.52	4.69	0.77		81.03	13.21	0.7
5	10	30		93.65	5.56	-0.48	61-219	85.39	11.83	1.28
6	3	30		95.85	4.51	0		82.07	13.22	5.14
1	3	30	1-120	90.26	9.99	0	121-221	69.3	15.68	-1.05
2	3	60		92.65	8.74	0		83.54	9.88	5.16
3	5	30		95.71	6.73	-0.03	121-220	86.73	9.05	4.75
4	3	30		95.91	6.57	0.44		86.31	9.24	5.19
5	3	30		96.61	5.99	-0.25	121-219	86.59	9.21	3.85
6	8	30		97.3	5.37	1.56		86.15	9.57	8.92
1	8	30	1-180	89.44	9.75	-0.1	181-221	72	12.72	1.37
2	8	60		93.7	7.62	0		84.45	9.1	3.33
3	5	90		94.04	7.42	0.01	181-220	85.5	9.04	7.09
4	8	30		96	6.11	-0.81		88.12	8.8	5.9
5	5	30		97.27	5.07	-0.02	181-219	85.49	10.18	4.58
6	3	30		95.26	6.72	3.79		88.4	8.53	11.53

TABELA 8.6 – MODELOS SELECIONADOS NA INICIALIZAÇÃO F

MODELO	ARQUITETURA	EPOCHS	PERIODO	R	RMSE	DV (%)	PERIODO	R	RMSE	DV (%)
1	3	90	1-60	79.43	9.6	0.01	61-221	82.98	12.69	3.22
2	3	90		84.52	8.46	0		87.91	11.43	4.06
3	3	30		93.62	5.57	-0.19	61-220	85.05	12.47	-6.96
4	5	30		93.69	5.54	-0.87		83.86	12.28	-0.77
5	3	30		96.26	4.29	0.11	61-219	84.84	12.2	2.31
6	3	30		95.09	4.9	0		85.85	11.58	-0.95
1	3	30	1-120	89.18	10.51	0.96	121-221	76.41	11.69	4.37
2	3	30		94.41	7.65	-0.15		85.66	9.27	2.85
3	5	30		95.77	6.69	1.19	121-220	86.78	9.03	6.03
4	3	30		96.12	6.41	0.2		88.61	8.43	5.55
5	5	30		97.52	5.13	0	121-219	85.45	9.66	9.52
6	5	30		96.49	6.09	0		86.65	9.14	6.57
1	8	30	1-180	89.11	9.9	-0.02	181-221	71.26	13.12	-1.26
2	5	60		93.29	7.86	0		84.1	9.14	3.97
3	5	90		94.05	7.42	0	181-220	85.5	9.04	7.09
4	8	90		96.58	5.66	-0.02		89.32	7.75	1.01
5	10	30		96.59	5.65	-0.21	181-219	86.75	9.14	8.64
6	5	30		94.78	6.96	0		85.88	9.39	9.38


8.1.1 – Análises específicas

A partir dos 108 melhores resultados selecionados, apresentados na tabelas 8.1 a 8.6, foram feitas cinco análises distintas relacionadas com os objetivos específicos:

a. Determinar para qual número de *epochs* os modelos treinados obtiveram os melhores resultados

Independentemente da combinação entre os dados de entrada, extensão das séries de dados, arquitetura da camada intermediária e número de inicializações, todas as RNA foram treinadas 30, 60 e 90 *epochs*. Não se sabe, *a priori*, para que faixa de valores do número de *epochs* obter-se-ão os melhores resultados. Nas tabelas 8.1 a 8.6 observam-se bons modelos treinados com 30, 60 e 90 *epochs*. Nestas circunstâncias, o número de *epochs* definido como aquele que resulta em melhores resultados no treinamento será o número de *epochs* mais freqüente entre os melhores modelos selecionados. O resultado desta análise de freqüência é apresentado na figura 8.1.

FIGURA 8.1 – FREQUÊNCIA DO NÚMERO DE *EPOCHS* ENTRE OS MODELOS SELECIONADOS



A figura 8.1 mostra que dos 108 modelos selecionados 72 destes modelos, cerca de 67%, obtiveram o melhor desempenho quando foram treinados apenas 30 *epochs*. Para estes mesmos modelos quando o treinamento foi maior, 60 ou 90 *epochs*, os modelos aproximaram a sua forma funcional de pontos particulares da amostra de dados utilizada no treinamento (*overfitting*) e não generalizaram o problema proposto. Um exemplo deste comportamento é o resultado para o modelo 2, ‘R23A30E11’, na tabela de resultados (ver apêndice II). Para 30 *epochs*, o coeficiente de correlação na validação foi igual a 84,37%. Com o aumento do número de *epochs* o modelo perdeu em generalização do problema e o coeficiente de correlação diminuiu para 76,99% e 76,59% respectivamente para 60 e 90 *epochs*.

b. Verificar se há alguma relação entre o número de *epochs* e extensão das séries de dados.

O número de *epochs* também foi avaliado em função dos conjuntos de entrada. Neste caso fez-se uma análise de frequência do número de *epochs* para cada conjunto de entrada. O resultado é apresentado na figura 8.2.


A figura 8.2 mostra que os diferentes conjuntos de entrada utilizados no treinamento não influenciam no número de *epochs* de treinamento. Para todas as entradas os melhores resultados foram alcançados pelos modelos treinados 30 *epochs*.

c. Avaliar a relação entre o número de pesos e vieses da RNA e o número de *epochs*.

Outra análise quanto ao número de *epochs* é avaliar qual a relação entre o número de *epochs* com o número de pesos e vieses da RNA. Os pesos estão presentes em todas as conexões entre neurônios. Os vieses estão presentes em todos os neurônios da camada intermediária e da camada de saída. Para determinar qual o número de total de pesos e vieses de uma RNA basta conhecer o número de conexões, o número de neurônios na camada intermediária e o número de neurônios na camada de saída. O

número total de pesos e *vieses* para cada uma das 24 RNA é apresentado na tabela 8.7 a seguir.

FIGURA 8.2 – FREQUÊNCIA DO NÚMERO DE *EPOCHS* ENTRE OS MODELOS SELECIONADOS CONSIDERANDO OS DIFERENTES CONJUNTOS DE ENTRADA



A RNA mais simples das 24 RNA pré-estabelecidas possui um número total de 13 pesos e *vieses*. A RNA mais complexa, possui um número total de 101 pesos e *vieses*. Para avaliar a relação do número de *epochs*, com o número de pesos e *vieses* das RNA dividiu-se o número de pesos e *vieses* em sete intervalos de classe. Para cada intervalo foram computados, entre os modelos que obtiveram os melhores resultados, as suas frequências. Esta análise foi distinta para cada número de *epochs*. O resultado desta análise é apresentado na tabela 8.8.

TABELA 8.7 – NÚMERO DE PESOS E *VIESES* DAS RNA

RNA	Nº DE PESOS E <i>VIESES</i>	RNA	Nº DE PESOS E <i>VIESES</i>
R11	13	R41	22
R12	21	R42	36
R13	33	R43	57
R14	41	R44	71
R21	16	R51	25
R22	26	R52	41
R23	41	R53	65
R24	51	R54	81
R31	19	R61	31
R32	31	R62	51
R33	49	R63	81
R34	61	R64	101

TABELA 8.8 – FREQUÊNCIA DOS MELHORES RESULTADOS EM FUNÇÃO DO NÚMERO DE PESOS E *VIESES* E O NÚMERO DE *EPOCHS*

INTERVALO DE CLASSE	30	60	90	TOTAL
0-15	5	0	6	11
16-30	26	5	4	35
31-45	24	7	6	37
46-60	7	1	4	12
61-75	2	0	2	4
76-90	7	1	0	8
91-105	1	0	0	1
TOTAL	72	14	22	108

A tabela 8.8 mostra que o número de *epochs* não está relacionado com o número de pesos e vieses da RNA. Independentemente do número de *epochs*, os melhores resultados foram mais frequentes para as RNA com números de pesos e vieses na faixa entre 16 e 45. Os resultados nesta faixa representam cerca de 67% de todos os resultados.

d. Avaliar a influência em reinicializar os pesos e vieses da RNA no processo de treinamento.

Para avaliar a influência da inicialização foram adotadas duas metodologias. Na primeira foram selecionados aleatoriamente, no apêndice II, 10 RNA e comparados os resultados obtidos em termos do coeficiente de correlação durante a validação para cada inicialização. O resultado desta análise é apresentado na tabela 8.9.

TABELA 8.9 – INFLUÊNCIA DA INICIALIZAÇÃO NO TREINAMENTO DAS RNA.

RNA	A	B	C	D	E	F
R1130E11	82,13	5,09	80,83	81,73	81,62	80,88
R2130E21	-11,04	88,1	87,25	88,26	-0,46	86,16
R3260E31	79,62	80,04	80,85	80,85	80,86	79,67
R3330E33	85,53	77,34	48,47	86,38	85,41	85,37
R4490E43	85,25	71,36	88	73,67	76	84,67
R5130E51	86,76	84,96	84,96	83,96	75,54	84,84
R5260E53	78,26	83,17	85,7	84	83,78	78,87
R6190E61	70,67	79,84	87,74	85,91	80,94	85,73
R6230E62	86,65	86,67	85,76	85,94	78,27	86,65
R6430E61	67,75	82,34	80,34	76,64	76,54	84,06

A nomenclatura na tabela 8.9 segue a mesma regra que a nomenclatura utilizada no apêndice II com exceção da ausência da letra A, B, C, D, E ou F. Nas colunas seguintes são apresentados os coeficientes de correlação, na validação, para cada inicialização. Observa-se na tabela 8.9 que a inicialização pode influenciar no resultado uma vez que, para algumas RNA, foram registrados coeficientes muito baixos num instante e altos num instante seguinte. No entanto, também foi registrado que a oscilação entre valores dos coeficientes, na maneira descrita, ocorreu um pequeno número de vezes.

Na segunda análise foram selecionados, entre os melhores modelos apresentados nas tabelas 8.1 a 8.6, qual o melhor modelo e sua respectiva arquitetura na camada intermediária, para cada conjunto de entrada, a cada inicialização. O

resultado desta análise é apresentado na tabela 8.10 a seguir. O objetivo é avaliar a influência da inicialização dos pesos e *vieses* na determinação do melhor modelo para cada conjunto de entrada.

TABELA 8.10 – INFLUÊNCIA DA INICIALIZAÇÃO NA DETERMINAÇÃO DO MELHOR MODELO PARA CADA CONJUNTO DE ENTRADA.

INICIALIZAÇÃO	ENTRADA 1		ENTRADA 2		ENTRADA 3	
	MOD ¹	ARQ ²	MOD	ARQ	MOD	ARQ
A	5	3	4	3	4	8
B	2	10	5	3	4	8
C	2	8	5	3	4	5
D	2	3	4	5	4	5
E	2	10	5	3	4	8
F	2	3	4	3	4	8

Nota: 1) MOD – Modelo. 2) ARQ – arquitetura da camada intermediária

Observa-se na tabela 8.10 que novamente a influência da inicialização existe, mas é baixa. Independente da inicialização A, B, C ... ou F as RNA que melhor representaram a relação entre chuva e vazão quando treinadas com a entrada 1 foram aquelas com entradas conforme o modelo 2, com três ou dez neurônios na camada intermediária. Para a entrada 2 os melhores resultados foram obtidos pela RNA com entradas conforme o modelo 4 ou 5 predominando três neurônios na camada intermediária. Para entrada 3 prevaleceu o modelo 4 com oito neurônios na camada intermediária.

A maior parte dos modelos da tabela 8.10 foram treinadas 30 *epochs* e o número de pesos e *vieses* variando entre 15 e 57, resultados coincidentes com os resultados dos itens ‘a’ e ‘c’ vistos acima.

e. Determinar a relação entre o número de entradas da RNA e a extensão das séries de dados.

Nesta última análise o objetivo é avaliar a relação entre o número de entradas do modelo e a extensão das séries de dados utilizadas durante o treinamento.

Conforme a tabela 8.10 tem-se que, para a entrada 1, o modelo 2 apresentou o melhor desempenho. Este modelo apresenta apenas três entradas. Para as entradas 2 e 3 os modelos 4 e 5 obtiveram os melhores resultados. Os modelos 4 e 5 possuem 5 e 6 entradas respectivamente.

Os modelos com maior número de entradas só alcançaram bons resultados quando o número de dados utilizados no treinamento foi aumentado de 60 para 120 e 180 dados, ou seja, a relação entre as variáveis foi mais bem identificada quando o número de dados foi maior. Este mesmo comportamento que correlaciona o número de dados para o treinamento e o número de entradas da RNA já havia sido citado por TOKAR e JOHNSON. (1999).


8.1.2 – Resultados

Entre os melhores modelos pré-selecionados na tabela 8.10, foram eleitos os três melhores modelos, um para cada conjunto de entradas, para análise gráfica dos resultados. Para a entrada 1, por exemplo, o modelo 2 foi aquele que melhor identificou a relação entre chuva e vazão; este é o modelo que se repete o maior número de vezes entre uma inicialização e outra. O melhor entre todos os modelos 2's é o modelo selecionado para análise gráfica. Esta mesma regra também foi adotada na seleção dos melhores modelos treinados com as entradas 2 e 3.

O modelo 2 com melhor desempenho foi aquele treinado na inicialização 'B', ou seja, $Q(t) = f(P(t), EVT(t), Q(t-1))$. O resultado deste modelo é apresentado na figura 8.3. Observa-se na figura 8.3, que durante o treinamento, o modelo 2 representou relativamente bem as vazões baixas, no entanto esta tendência não prevaleceu com o aumento da vazão e uma pequena dispersão ocorreu para as vazões médias. A tendência registrada foi a de minimizar estas vazões. O ponto particular para este modelo é de que a RNA foi treinada utilizando vazões predominantemente mais baixas e durante a validação se portou muito bem na previsão de vazões mais altas. No treinamento, o coeficiente de correlação entre os dados observados e calculados foi de

84,1%. Na validação este coeficiente aumentou para 90,3%. Durante a validação ainda prevalece a tendência registrada no treinamento de minimizar as vazões médias e altas. As diferenças de volumes no treinamento e na validação foram de 0,03 % e -0,17 % respectivamente.

FIGURA 8.3 – MELHOR RESULTADO PARA A ENTRADA 1 (RNA)




Para a entrada 2 é selecionado ou o modelo 4 ou o modelo 5 com melhor desempenho para análise gráfica. No caso, o modelo 4, treinado na inicialização 'F', apresentou o melhor resultado, $Q(t) = f(P(t-1), P(t), EVT(t-1), EVT(t), Q(t-1))$. O resultado deste modelo é apresentado na figura 8.4.

O modelo 4 apresentou um ótimo desempenho durante o processo de treinamento. O coeficiente de correlação foi de 96,1% e a diferença de volumes de 0,2%. Pode-se dizer que, para este modelo, durante o treinamento, tanto as vazões baixas quanto as vazões altas foram bem representadas. Já durante a validação o coeficiente de correlação caiu para 88,6% e o modelo apresentou uma tendência forte

em minimizar as vazões altas. Em consequência disto as diferenças de volumes aumentam consideravelmente chegando a 5,5%.

FIGURA 8.4 - MELHOR RESULTADO PARA A ENTRADA 2 (RNA)




O melhor resultado obtido pelo modelo 4 quando treinado a partir da entrada 3 ocorreu para a inicialização 'B', $Q(t) = f(P(t-1), P(t), EVT(t-1), EVT(t), Q(t-1))$. Entre os modelos selecionados este foi o que apresentou os melhores resultados, sendo eleito o modelo para representação da relação entre chuva e vazão. Os resultados deste modelo é apresentado na figura 8.5. Novamente o modelo 4 obteve um ótimo desempenho durante o treinamento e uma queda de qualidade durante a validação. No entanto, neste caso, na validação, o modelo apresenta um bom comportamento, tanto para vazões baixas quanto para as vazões altas. Os coeficientes de correlação no treinamento e na validação foram respectivamente 96,9% e 89,8%. A diferença de volume foi insignificante no treinamento e de -1,28% na validação. A compensação de volumes é feita ao longo de todo o hidrograma. Isto justifica o alto coeficiente de

correlação e baixo percentual na diferença de volumes observados.

O que se observa, principalmente no treinamento do modelo 4, com 120 e 180 dados é que o aumento do número de dados representou um melhor ajuste dos pesos. Este comportamento também já havia sido comentado por ANMALA et al. (2000).

FIGURA 8.5 - MELHOR RESULTADO PARA A ENTRADA 3 (RNA)




8.2 IPHMEN

Da mesma forma que para as RNA, os resultados para o modelo IPHMEN são apresentados e analisados graficamente. O resultado para a primeira calibração, utilizando somente 60 dados é apresentado na figura 8.6 a seguir.

O modelo IPHMEN treinado utilizando somente 60 dados de entrada simula muitas bem as vazões baixas e minimiza as vazões médias e altas tanto na calibração

quanto na validação. O coeficiente de correlação na calibração e na validação foram 80,7% e 87,4% respectivamente. As diferenças de volumes foram iguais a 5,6% na calibração e 9,38% na validação.

FIGURA 8.6 - RESULTADO PARA A ENTRADA 1 (IPHMEN)




Os resultados quando o IPHMEN foi treinado com 120 dados é apresentado na figura 8.7.

O que se observa na figura 8.7 é que mesmo com uma mudança significativa nos valores dos parâmetros do modelo, os resultados se mantiveram representativos. Na calibração o modelo apresenta um bom comportamento para todas as faixas de vazões. A dispersão dos pontos é aceitável e há compensação de volumes. A diferença de volumes foi igual a 1,30%. O coeficiente de correlação entre os dados observados e calculados foi igual a 91,1%. Na validação a discrepância aumenta, o coeficiente de correlação cai para 76,4%, mas a compensação de volumes continua satisfatória. A

diferença de volumes registrada na validação foi igual a 2,78%.

FIGURA 8.7 - RESULTADO PARA A ENTRADA 2 (IPHMEN)




Os resultados quando o IPHMEN foi treinado com 180 dados é apresentado na figura 8.8.

A figura 8.8 mostra que quando o IPHMEN foi treinado com 180 dados, os resultados registram um pior desempenho. Isto pode estar aliado à subjetividade que existe ao treinar um modelo conceitual. A tentativa de ajustar o hidrograma a um ponto particular do hidrograma observado durante a calibração ou a tentativa por ajuste que compense bem os volumes ao longo de toda a série gerou um bom resultado durante a calibração, mas durante a validação representou uma queda de desempenho.

Durante a calibração é observada uma leve tendência em maximizar as vazões baixas e minimizar as vazões altas. O coeficiente de correlação nesta etapa foi igual a 88,8% e a diferença de volumes de 4,81%. Na validação algumas vazões mais baixas são bem representadas, no entanto em termos gerais o resultado não foi bom e a

dispersão das vazões aumentou consideravelmente. O coeficiente de correlação e a diferença de volumes na validação foram respectivamente iguais a 68,7% e 5,99%.

FIGURA 8.8 - RESULTADO PARA A ENTRADA 3 (IPHMEN)



8.3 CONFRONTO DOS RESULTADOS

No confronto entre os modelos, os resultados são avaliados em termos estatísticos, análise gráfica e estudo do hidrograma calculado pela melhor RNA com os resultados do modelo IPHMEN para cada um dos três conjuntos de entrada utilizados durante o treinamento da RNA e a calibração do IPHMEN. As tabelas 8.11 e 8.12, a seguir, mostram um resumo dos resultados estatísticos.

Independentemente do conjunto de entradas utilizado para treinar as RNA e calibrar o modelo IPHMEN, estatisticamente, as RNA apresentaram os melhores resultados. Os coeficientes de correlação foram maiores e os erros médios quadrático

menores. Em relação à diferença de volumes, em todas as oportunidades, com exceção quando a RNA foi validada utilizando a série com dados de 121 a 221, as RNA apresentaram uma diferença de volumes maior. Estas divergências estatísticas podem ser explicadas através de análises gráficas e estudo dos hidrogramas calculados por ambos os modelos.

TABELA 8.11 – RESUMO DOS RESULTADOS NO TREINAMENTO DAS RNA E CALIBRAÇÃO DO MODELO IPHMEN

ENTRADA	RNA			IPHMEN		
	R	RMSE	DV ¹ (%)	R	RMSE	DV(%)
1-60	84,1	8,57	0,03	80,7	9,79	5,60
1-120	96,1	6,41	0,20	91,1	9,68	1,30
1-180	96,9	5,35	0,00	88,8	10,17	4,81

NOTA: 1) DV – diferença de volumes. Valores positivos significam minimização dos volumes, valores negativos significam maximização dos volumes.


TABELA 8.12 – RESUMO DOS RESULTADOS NA VALIDAÇÃO

ENTRADA	RNA			IPHMEN		
	R	RMSE	DV(%)	R	RMSE	DV(%)
61-221	90,3	9,84	-0,17	87,4	11,21	9,38
121-221	88,6	8,43	5,55	76,4	12,25	2,78
181-221	89,8	8,68	-1,28	68,7	13,94	5,99

Para a entrada 1, ambos os modelos apresentam comportamentos semelhantes. As vazões baixas são bem representadas e as vazões médias apresentam uma pequena dispersão. Este comportamento já havia sido citado anteriormente e apresentados na figuras 8.3 e 8.6. Este comportamento ocorre no treinamento da RNA, na calibração do modelo IPHMEN e na validação de ambos os modelos. No entanto, apesar das semelhanças, os resultados das RNA são melhores. Isto ocorre porque as vazões calculadas pela RNA se aproximam mais dos valores observados. Estatisticamente os coeficientes de correlação para as RNA são maiores e os erros menores. Como as vazões calculadas estão mais próximas das observadas, as diferenças de volumes também são menores para as RNA. As vazões calculadas pelas RNA, mais próximas das vazões observadas, podem ser mais bem visualizadas através da curva de

permanência apresentada na figura 8.9. Pode-se observar na figura 8.9, no trecho mais alto, a maior divergência entre as vazões calculadas e as vazões observadas. Este comportamento para as vazões altas também havia sido citado anteriormente.


FIGURA 8.9 – CURVAS DE PERMANÊNCIA PARA A ENTRADA 1



Para a entrada 2, a semelhança entre resultados dos modelos ocorreu somente durante na fase de treinamento da RNA e a fase de calibração do modelo IPHMEN. Para esta situação, ambos os modelos representaram bem as vazões baixas e as vazões altas, a dispersão das vazões calculadas foi menor, o coeficiente de correlação aumentou e o erro diminuiu. Com as vazões calculadas uniformemente distribuídas, as diferenças de volumes também foram menores. Já na validação o comportamento entre os dois modelos foi diferente. As RNA aproximaram muito bem as vazões baixas e minimizaram as vazões altas. O IPHMEN não aproxima muito bem as vazões,

mas apresenta uma boa dispersão das vazões calculadas. Este comportamento distinto se reflete nas estatísticas. As RNA apresentam um bom coeficiente de correlação por que as vazões baixas calculadas são bem próximas das vazões observadas e em maior número, no entanto, as diferenças de volumes são grandes porque este mesmo modelo minimiza as vazões altas sem compensá-las. O IPHMEN apresenta uma pequena diferença de volumes porque os volumes são compensados ao longo de toda a faixa de vazões, no entanto, o coeficiente de correlação é baixo, pois as vazões calculadas estão muito afastadas das vazões observadas. Estes comportamentos também podem ser observados nas curvas de permanência apresentadas na figura 8.10 a seguir.

FIGURA 8.10 – CURVAS DE PERMANÊNCIA PARA A ENTRADA 2




Na validação, no trecho mais alto, a curva de permanência obtida pelas RNA está abaixo da curva de permanência obtida a partir dos dados observados. A distância acentuada entre as duas curvas de permanência naquele trecho representa a diferença de volume de 5,55%. Isto não ocorre para a curva obtida pelo modelo IPHMEN que aparece em *zig zag* compensando os volumes. Não aparece na figura, mas foi observado que os *zig zags* ocorrem ao longo de toda a curva, os valores das vazões calculadas ficam afastados e o coeficiente de correlação diminui.

Para a entrada 3 o comportamento dos modelos é bem diferente, tanto no treinamento das RNA e calibração do IPHMEN, quanto na validação. No treinamento das RNA, o aumento da quantidade de dados melhorou o seu desempenho. Uma leve tendência da RNA em minimizar as vazões no trecho das vazões médias é corrigida e o coeficiente de correlação aumenta em 0,8%. Para o modelo IPHMEN o aumento de dados representou uma queda no desempenho, a tentativa de ajustar o hidrograma calculado de um ponto particular ou a compensação de volumes aumentou a dispersão das vazões, conseqüentemente os coeficientes de correlação e o erro foram respectivamente menor e maior. As mesmas tendências de um e outro modelo prevaleceram na validação.

A RNA com uma compensação de volumes melhor conseguiu, durante a validação, aumentar o coeficiente de correlação em 1,2%. Enquanto isso o modelo IPHMEN com uma dispersão maior diminui o coeficiente de correlação que antes era de 76,4% para 68,7%. A figura 8.11 mostra que diferentemente da situação anterior, a curva de permanência obtida pelas RNA, na validação, está acima da curva observada, indicando maiores volumes, no caso, 1,28% a mais que o volume registrado. A curva de permanência calculada pelo modelo IPHMEN novamente apresenta-se em *zig zag* no trecho superior, no entanto foi observado que, para baixas vazões, as vazões calculadas estão abaixo das vazões observadas. Isto justifica o fato de as diferenças de volumes aumentarem consideravelmente. A minimização das vazões baixas é mais bem observada na figura 8.8.

FIGURA 8.11 – CURVAS DE PERMANÊNCIA PARA A ENTRADA 3



Observou-se também durante o confronto dos resultados três outras particularidades.

- i) Ambos os modelos não representaram significativamente as vazões altas. Este comportamento foi registrado para todos as melhores RNA e o modelo IPHMEN, tanto no treinamento, calibração quanto na validação.
- ii) Ambos os modelos também não foram capazes de representar um mesmo trecho do hidrograma. Este trecho aparece nas figuras 8.3 e 8.6, na validação, entre o intervalo 100 e 120 e na figura 8.4 e 8.7, também na validação, no intervalo entre 40 e 60. A observação dos dados de precipitação e vazão observadas para este trecho do hidrograma mostrou

que houve uma inconsistência dos dados de vazão o que justifica para as precipitações apresentadas aos modelos, os mesmos não serem capazes de aproximar a vazão calculada da vazão registrada em campo. No entanto, quando esta informação foi utilizada no treinamento da RNA, treinamento com a entrada 3, figura 8.5, no intervalo entre 150 e 180, a RNA ajusta a vazão calculada a vazão observada, no caso, registrada errada. Isto não aconteceu com o modelo IPHMEN que durante a calibração não foi capaz de aproximar o hidrograma calculado do hidrograma observado, figura 8.8.

iii) As RNA e o modelo IPHMEN treinados com a entrada 1 apresentaram coeficientes de correlação e RMSE maiores na validação que no treinamento ou calibração dos modelos. O coeficiente de correlação é explicado como uma coincidência numérica associada à forma de como o hidrograma apareceu no futuro favorecendo uma melhor aproximação das vazões calculadas para ambos os modelos. Já um maior RMSE na validação é consequência das vazões altas calculadas, em ambos os modelos, estarem abaixo das vazões observadas. O RMSE se torna grande por que as discrepâncias entre os valores são grandes (ver figura 8.3 e 8.6).

9. CONCLUSÕES E RECOMENDAÇÕES

O objetivo geral deste trabalho foi modelar o processo de transformação de chuva em vazão numa escala mensal através da utilização de RNA. Isto era justificável uma vez que a relação entre chuva e vazão é altamente não linear e as RNA são ditas aproximadores universais de funções não lineares. No desenvolvimento do trabalho, foi verificado que o treinamento de uma RNA era muito dependente de elementos como o número de entradas, o número de neurônios na camada intermediária, o número de *epochs*, a inicialização dos pesos e vieses e a extensão das séries de dados. Sendo assim foi criado um algoritmo computacional capaz de, durante o treinamento das RNA, considerar a influência de todos estes elementos. O estudo da influência destes elementos fizeram parte dos objetivos específicos deste trabalho.

Foram treinadas 24 RNA que expressaram a combinação entre o número de entradas com o número de neurônios da camada intermediária. O treinamento destas RNA, considerando a influência de todos os elementos, geraram 1296 resultados, entre os quais foram selecionados os três melhores, um para cada conjunto de entrada, 60, 120 ou 180 dados.

Observou-se entre as três RNA selecionadas, que independentemente do conjunto de entrada utilizado, todas as três RNA foram capazes de identificar a relação entre chuva e vazão satisfatoriamente, no entanto, o modelo 4, $Q(t) = f(P(t-1), P(t), EVT(t-1), EVT(t), Q(t-1))$, treinado com 180 dados na inicialização B foi eleito o melhor modelo. No treinamento da RNA o modelo aproximou muito bem as vazões baixas e altas apresentando um coeficiente de correlação igual a 96,9%, um RMSE de 5,35 e uma diferença de volumes insignificante. Na validação o coeficiente de correlação diminuiu para 89,6%, mas o modelo não perdeu em qualidade. A RNA que representa este modelo 4 possui cinco entradas e oito neurônios na camada intermediária. Ela foi treinada 90 *epochs* e possui um número total de pesos e vieses de 57.

Os resultados das três RNA foram confrontados com os resultados

calculados pelo modelo conceitual IPHMEN e, em todas as ocasiões, as RNA apresentaram um melhor desempenho, os coeficientes de correlação alcançados foram maiores e os erros menores. Ambos os modelos também apresentaram comportamentos semelhantes. Quando os modelos foram treinados com o primeiro conjunto de entrada os dois modelos apresentaram coeficiente de correlação e RMSE maiores na validação que no treinamento ou calibração. Naquela ocasião, este comportamento foi associado respectivamente a uma coincidência numérica e as grandes diferenças entre as vazões observadas e calculadas para as vazões mais altas. Ambos os modelos também não foram capazes de prever com precisão as vazões mais altas. Outra semelhança foi registrada em relação a um trecho do hidrograma onde nenhum dos dois modelos conseguiu aproximar a vazão calculada da vazão registrada. Uma avaliação daquele trecho concluiu de que se tratava de um erro no registro de vazões. Este erro não havia sido percebido durante a consistência dos dados, no entanto foi entendido como um ponto positivo uma vez que colabora na análise do hidrograma. Quando as RNA e os modelos IPHMEN foram treinados e calibrados com as entradas 1 e 2 as vazões calculadas por ambos os modelos, na validação, para aquele trecho, apresentaram comportamentos muito semelhantes. Quando este trecho foi utilizado no treinamento, entrada 3, a vazão calculada pela RNA se aproximou da vazão registrada. Naquela situação este comportamento não resultou em erros maiores, mas pode ser um alerta para a importância de uma boa consistência dos dados. Acredita-se, para RNA, que a utilização de dados muito inconsistentes pode prejudicar a identificação da relação entre chuva e vazão em termos de maximizar e minimizar vazões ou, até mesmo, não identificar relação alguma, no entanto esta é apenas uma hipótese e deve ser mais bem avaliado em pesquisas futuras.

Além dos melhores resultados, as RNA também apresentaram como vantagem de ordem prática, a facilidade no ajuste dos pesos e vieses em relação ao parâmetros do modelo IPHMEN. O algoritmo proposto cria e treina 24 RNA gerando 1296 resultados em intervalos de tempo muito pequenos. Para o computador utilizado neste trabalho, um Pentium 1000 MHZ, este intervalo de tempo significou cerca de

cinco minutos. Por outro lado, a calibração do IPHMEN, por tentativa e erro, significou num gasto de seis a sete horas. Soma-se a isto que os parâmetros determinados para o IPHMEN ainda devem passar por um refinamento, uma vez que os mesmos devem ser únicos, pois estão relacionados com as características da bacia hidrográfica. O fato de serem estabelecidos três conjuntos de parâmetros para o modelo IPHMEN não significou uma inconsistência, dado que o objetivo também foi simular uma situação real em que o modelo conceitual é calibrado por tentativa e erro e, nesta situação, não se sabe exatamente quais são os valores dos parâmetros sendo o enfoque principal aproximar as vazões calculadas das vazões observadas.

O bom resultado alcançado pelas RNA está associada à metodologia adotada que, durante o treinamento, considera a influência do número de neurônios na camada de entrada e na camada intermediária, o número de *epochs*, a inicialização dos pesos e vieses e a extensão das séries de dados. Foi observado durante o treinamento que o número de entradas está diretamente correlacionado com a extensão das séries de dados utilizadas no treinamento. Neste caso, o aumento do número de neurônios na camada de entrada deve ser seguido de um aumento de dados utilizados no treinamento. Esta é uma abordagem qualitativa e deve ser mais bem investigada em termos específicos em pesquisas futuras. Verificou-se que o número de *epochs* deve ser baixo e que não se correlaciona com o número total de pesos e vieses da RNA, nem com a extensão das séries de dados. O fato de o número de *epochs* ser pequeno foi uma hipótese levantada anteriormente associada ao algoritmo de treinamento Levenberg Maquardt ser um algoritmo de convergência rápida e o risco de *overfitting* muito alto. Neste trabalho, esta hipótese foi comprovada. Os melhores resultados foram registrados para as RNA treinadas somente 30 *epochs* e com um número total de pesos e vieses variando entre 15 e 57. A inicialização dos pesos e vieses não influenciou efetivamente na determinação dos três melhores resultados, no entanto, verificou-se que inicializar as RNA é importante uma vez que em alguns casos, ainda que em poucos, as RNA direcionaram a solução do problema para um mínimo local.

Os bons resultados obtidos nesta pesquisa estimulam a investigação da

aplicação de RNA em recursos hídricos. No entanto, este é um assunto extenso. Para trabalhos futuros recomenda-se a aplicação da metodologia proposta na modelagem de eventos horários, diários, semanais e anuais, a investigação de outros algoritmos de otimização para RNA, RNA de base radial e temporais e a investigação da influência da normalização dos dados de entrada.

REFERÊNCIAS

ASCE TASK COMMITTEE ON APPLICATIONS OF ARTIFICIAL NEURAL NETWORKS IN HYDROLOGY. Artificial neural networks in hidrology. I: Preliminary concepts. **Journal of Hydrologic Engineering**, Reston: ASCE, v.5, n.2 p. 115-123, Apr. 2000a.

ASCE TASK COMMITTEE ON APPLICATIONS OF ARTIFICIAL NEURAL NETWORKS IN HYDROLOGY. Artificial neural networks in hidrology. I: Preliminary concepts. **Journal of Hydrologic Engineering**, Reston: ASCE, v.5, n.2 p. 124-137, Apr. 2000b.

ANMALA, J.; ZHANG, B.; GOVINDARAJU, R. S. Comparison of ANNs and empirical approaches for predicting watershed runoff. **Journal of Water Resources Planning and Management**, Reston: ASCE, v. 126. n.3, p. 156-166, May/June 2000.

BALLINI, R.; FRANÇA, E.; KADOWAKI, M.; SOARES, S.; ANDRADE, M. **Modelos de redes neurais e Box e Jenkins para previsão de vazões médias mensais**. SIMPOSIO BRASILEIRO DE RECURSOS HÍDRICOS, 12, 1997, Goiana. **Relação de trabalhos**. Goiana: ABRH, 1997. 1CD ROOM.

BARTH, F. T., POMPEU, C. T., FILL, H. D., TUCCI, C. E. M., KELMAN, J., BRAGA JR., B. P. F.. **Modelos para gerenciamento de recursos hídricos**. São Paulo: Nobel: ABRH, 1987.

BEVEN, K. J. **Rainfall-runoff modelling: the primer**. Chichester: John Wiley & Sons Ltd, 2001.

BRONSON, R. **Pesquisa Operacional**. São Paulo: McGraw-Hill do Brasil, 1985.

CAMPOLO, M.; ANDREUSSI, P.; SOLDATI, A. River flood forecasting with a neural network model. **Water Resoureces Research**, Washington: AGU, v.35, n. 34, p. 1191-1198, Apr. 1999.

CASTANHARO, G. **Aplicação de modelos hidrodinâmicos no contexto de previsão de aflúências de reservatórios**. Curitiba, 2003. 206 f. Dissertação (Mestrado) – UFPR.

ELSHORBAGY, A. SIMONOVIC, S. P.; PANU, U. S. Performance evaluantion of artificial neural networks for runoff prediction. **Journal of Hydrologic Engineering**, Reston, v.5, n.4, p.424-427, Oct. 2000.

FERNANDES, L. G. L.; NAVAUX, P. O. A.; PORTUGUAL, M. S. Previsão de Séries de Tempo: Redes neurais artificiais e modelos estruturais. **Pesquisa e Planejamento Econômico**, PPE: v. 26, n. 2, p. 253-276, Ago. 1996.

GALVEZ, J. J. O.; PINTO, C. A. L.; PARRAGA, E. O. **Analisis hidrometeorologico y aplicación del modelo de simulacion IPH-MEN em la cuenca del Rio Pachitea**. In: ENCUESTRO DE LAS AGUA, 3., 2001, Santiago-Chile. Disponível em: <http://www.aguaboliviana.org/situacionaguaX/IIIEncAguas/contenido/trabajos_rojo/TC-145.htm> Acesso em: 28 abr 2004

GALVÃO, C O..(Org), VALENÇA, M. J. S., VIEIRA, V. P. P. B., DINIZ, L. S., LACERDA, E. G. M. de, CARVALHO, A. C. P. L. F., LUDERMIR, T. B. **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: Ed. Universidade/UFRGS/ABRH, 1999.

GORNI, A.A., Redes Neurais Artificiais uma abordagem revolucionária em inteligência artificial, **Micro Sistemas**, [SI]: n.133, nov. dez.1993.

HAGAN, M. T.; MENHAJ, M.B. Training feedforward networks with the Marquardt algorithm. **IEEE**. Disponível em < <http://ieeexplore.ieee.org/iel4/72/7801/00329697.pdf?isNumber=7801&prod=JNL&arnumber=329697&arSt=989&ared=993&arAuthor=Hagan%2C+M.T.%3B+Menhaj%2C+M.B.> > Acesso em: 20 abr. 2004.

HANSELMAN, D., LITTLEFIELD, B. **Matlab 5 Versão do Estudante – Guia do Usuário**. São Paulo: Editora Makron Books Ltda, 1999.

HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. New York: Macmillan College Publishing Company, 1994.

HSU, K. L.; GUPTA, H. V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. **Water Resources Research**. v. 31, n. 10, p. 2517-2530, Oct. 1995.

HU, T. S.; LAM, K. C.; NG, S. T. River flow time series prediction with a range-dependent neural network. **Hydrological Sciences Journal**, v. 46, n. 5, p. 729-745, Oct 2001.

JAIN, S. K.; DAS, A.; SRIVASTAVA D.K. Application of ANN for reservoir inflow prediction and operation. **Journal of Water Resources Planning and Manangement**, Reston: ASCE, v. 125, n.5, p.263-271, Sep./Oct. 1999.

KADOWAKI, M.; ANDRADE, M.G. **Previsão de vazões mensais utilizando redes neurais multicamadas com algortimo backpropagation**. SIMPÓSIO BRASILEIRO DE REDES NEURAI, 1997, Goiana.

LIMA, C.H.R.; FERRERIA FILHO, W. M.; Análise de modelos de redes neurais aplicados ao processo chuva-deflúvio no semi-árido. In:SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15., 2003, Curitiba. **Relação de trabalhos**. Curitiba: ABRH, 2003. 1 CD ROOM.

LIN, G; CHEN, L. A non-linear rainfall-runoff model using radial basis function network. **Journal of Hydrology**, London: Elsevier, v. 289, n. 1-4,p. 1-8, Apr. 2004.

MACHADO, F.W., SANTOS, I., PERREIRA FILHO, D. L. B., MINE, M. R. M., **Avaliação do ajuste e extrapolação de curvas de descarga através de redes neurais**. Artigo técnico a ser apresentado no XX Congresso Nacional del Agua – CONAGUA e III Simposio de Recursos Hidricos del Cono Sur, Mendoza, mai, 2005.

MATLAB. **Neural network toolbox documetantion**. Disponível em:<<http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/nnet.shtml?BB=1>> Acesso em: 18 fev. 2004.

MINE, M. R.M. **Método determinístico para minimizar o conflito entre gerar energia e controlar cheias**. Porto Alegre: IPH/UFRGS, 1998. 146 p. (e anexos com 115 p.) Tese (Doutorado), Universidade Federal do Rio Grande do Sul

MULLER, A. **Uma previsão de redes neurais artificiais na previsão do mercado acionário**. Florianópolis, 1996 Dissertação (Mestrado) - UFSC Disponível em: <<http://www.eps.ufsc.br/disserta96/mueller/index/>> Acesso: 03 mai 2004.

MULLER, I.I. **Métodos de avaliação da evaporação e evapotranspiração: análise comparativa para o Estado do Paraná**. Curitiba, 1995. 171 f. Dissertação (Mestrado) - CEHPAR, UFPR.

NEELAKANTAN, T. R.; PUNDARIKANTHAN, N. V. Neural network-based simulation-optimization model for reservoir operation. **Journal of Water Resources Planning and Management**, Reston: ASCE, v. 126, n.2, p. 57-64, Mar/Apr. 2000

RAMOS, A. M., GALVÃO, C. O., Estabilidade de redes neurais em modelagem hidrometeorológicas. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 14., 2001, Aracajú. **Relação de trabalhos**. Aracajú: ABRH, 2001. 1 CD ROOM.

RAMOS, F., OCCHIPINTI, A. G., VILLA NOVA, A. V., REICHARDT, K., MAGALHÃES, P. C. DE, CLEARY, R. W.. **Engenharia Hidrológica**. Rio de Janeiro: ABRH: Editora de UFRJ, 1989.

RAJURKAR, M. P.; KOTHYARI, U. C.; CHAUBE, U. C. Artificial neural networks for daily rainfall-runoff modelling. **Hydrological Sciences Journal**, IAHS: v. 47, n.6, p. 865-877, Dec 2002.

RAJURKAR, M. P.; KOTHYARI, U. C.; CHAUBE, U. C. Modeling of daily rainfall-runoff relationship with artificial neural network. **Journal of Hydrology**, London: Elsevier, v. 285, n. 1-4, p. 96-113, Jan. 2004.

RAUDKIVI, A. J.. **Hydrology : an advanced introduction to hydrological processes and Modeling**. New York: Pergamon, 1979.

SAJIKUMAR, N.; THANDAVESWARA, B.S. A non-linear rainfall-runoff model using artificial neural network, **Journal of Hidrology**, London: Elsevier, v. 216, n. 1-2, p. 32-55, Mar. 1999.

SANTOS, I., FILL, H. D., SUGAI, M. R. V. B., BUBA, H., KISHI, R. T., MARONE, E., LAUTERT, L. F. **Hidrometria aplicada**. Curitiba: Instituto de Tecnologia para o Desenvolvimento, 2001

SANTOS, I. **Modelagem geobiohidrológica como ferramenta no planejamento ambiental: Estudo da bacia hidrográfica do Rio Pequeno, São José dos Pinhais – Pr**. Curitiba, 2001. 93 f. Dissertação (Mestrado) – UFPR.

SARMENTO, F. J., Modelagem de séries hidrológicas através de redes de neurônios. **RBRH - Revista Brasileira de Recursos Hídricos**, Porto Alegre, v.1, n.2, p.19-31, jul/dez 1996.

SPERB, R. M.; MODRO, N. R.; MARCONDES, P.; FOES, P. A. BARCIA, R. M.; PACHECO, R. C. S.; TAVARES, G. **Prevent: prototipo de um sistema de previsao de enchentes baseado em redes neurais**. SIMPOSIO BRASILEIRO DE RECURSOS HÍDRICOS, 13., 1999, Belo Horizonte. **Relação de trabalhos**. Belo Horizonte: ABRH, 1999. 1CD ROOM.

SPIEGEL, M. R. **Estadística**. 3 ed. São Paulo: Makron Books, 1993.

STANFORD UNIVERSITY. Stanford Computer Science Education – CSE. **Eric Roberts' Sophomore College 2000**. Disponível em <<http://www-cse.stanford.edu/classes/sophomore-college/projects-00/neural-networks/index.html>> Acesso em: 03 mai 2004.

TAFNER, M. A., XEREZ M. de, RODRIQUES FILHO, I. W. **Redes neurais, introdução e princípios de neurocomputação**. Blumenau: Editora Eko, 1996.

TOKAR, A. S.; JOHNSON, P. A. Rainfall-runoff modeling using artificial neural networks . **Journal of Hydrologic Engineering**, Reston: ASCE, v.4, n.3, p.232-239, Jul. 1999.

TOKAR, A. S.; MARKUS, M. Precipitation – runoff modelling using artificial neural networks and conceptual models. . **Journal of Hydrologic Engineering**, Reston: ASCE, v.5, n.2, p.156-161, Apr. 2000.

THIRUMALAIAH, K.; DEO, M. River stage forecasting using artificial neural networks. **Journal of Hydrologic Engineering**, Reston: ASCE, v.3, n.1, p.001-026, Jan. 1998.

THIRUMALAIAH, K.; DEO, M. Hydrological forecasting using neural networks. **Journal of Hydrologic Engineering**, Reston: ASCE, v.5, n.2, p.180-189, Apr. 2000.

TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. Porto Alegre: Ed. da Universidade: ABRH: EDUSP, 1993.

TUCCI, C. E. M. **Modelos hidrológicos**. Porto Alegre: Ed. da Universidade: ABRH, 1998. 669p

WASHITONG UNIVERSITY IN ST. LOUIS. Computer Science And Engineering –CSE Disponível em: <http://www.cs.wustl.edu/~sg/CS527_SP02/lecture7.html> Acesso: 01 jun 2004.

**APÊNDICE 1 – PRECIPITAÇÃO MÉDIA,
EVAPOTRANSPIRAÇÃO POTENCIAL E VAZÃO MÉDIA MENSAL**

n	JANGADA 2651003	SERRARIA S.S. 2651010	MATOS COSTA 2651011	FAXINAL 2651024	IRATIM 2651026	RIO FARIAS 2651027	MÉDIA THIESSEN	EVT (mm/mês)	VAZÃO (m³/s)
1	131.2	154.2	75	148.9	96.2	113.2	118.8	115.83	12.96
2	88.8	83.8	83	67.1	79.2	92	82.8	90.4	11.82
3	172.8	218.1	137.2	220.6	193.9	208.9	191.2	71.44	25.71
4	121.8	120.5	129.9	120.8	181.3	133.5	132.6	67.33	44.45
5	114.6	141.1	90.3	162.8	156.4	127.6	129.5	67.64	23.28
6	106.2	157.7	126.8	148.4	126.6	143.9	137.1	96.05	41.51
7	77.7	120	70.4	96.4	178.6	87.8	101.8	90.83	21.64
8	192.2	207.2	164	227.4	190.2	199.4	195.5	124.44	23.38
9	118.1	194.6	152.5	200.6	101.1	175.3	162.1	147.42	36.12
10	158	183	241.4	147.8	210	150.8	183.8	140.17	19.29
11	309.4	198.8	224	186.6	234.5	179.4	215.7	124.3	27.26
12	212.2	268.9	192.8	206.2	197.7	255	225.6	156.93	52.43
13	242.2	301.1	239	241.4	262.5	251.1	257.6	118.54	35.01
14	73.4	92	49	72	115.8	70.1	76.4	88.87	18.60
15	18.2	51.4	21.9	49.6	66.3	49.7	42.5	85.82	7.65
16	121.2	163	110.2	143.4	128.3	164.1	140.1	66.35	17.83
17	93.2	85.5	51.8	77.6	94.9	76.8	77.6	87.13	15.89
18	167	202.7	140.7	199	200.4	180.4	180.1	88.78	29.32
19	87.8	82.1	91	92	60.6	80.6	83.0	111.38	19.20
20	239.6	259.2	279.8	237.6	205.6	233.9	246.2	142.32	52.21
21	123.2	134.4	128.4	154.4	204.3	146.5	145.5	119.72	25.68
22	124	159.8	166.8	135.8	158.2	170.1	155.3	152.51	25.57
23	122.4	184.5	42.4	130.6	93.6	157	123.0	163.75	9.09
24	89.8	63.7	113.1	97.2	102.8	73	88.4	147.3	6.02
25	155.8	224.4	195	250	180.7	188.6	201.0	132.51	14.87
26	0	0	7.6	0	0.6	0	1.7	120.74	4.67
27	66.5	48.6	12.6	45.4	79.9	51.4	47.1	98.38	2.85
28	59.3	51.2	58.6	79.5	105.7	43.9	62.9	72.97	3.98
29	177.9	215.5	198.8	184.2	198.5	219.7	201.6	69.57	23.26
30	55	74	63.6	75.2	91.2	71.1	71.2	90.33	11.33
31	132.7	166	142.6	116	106.5	170.3	143.5	114.99	21.22
32	77.8	89.6	79	90.4	107.9	89.2	88.2	157.61	9.25
33	200.5	216.6	235.6	209.4	143.9	184.2	202.0	138.35	22.50
34	161.6	104.6	161	135.4	91.2	105	125.9	151.68	15.33
35	32.3	9.9	13.2	9.8	25.8	70.4	27.3	167.81	5.98
36	86.6	128.5	86.6	79.6	114.4	109.8	102.2	139.04	4.22
37	113.6	114.8	112	146.8	139.8	102.1	119.0	132.33	9.80
38	182.6	213.4	122.8	209.4	144.1	193.5	177.7	91.29	21.43
39	317.5	312.8	309.6	327	255.2	347	314.3	72.21	73.46
40	36.1	46.6	29.5	44	25.8	25.6	34.6	67.45	16.87
41	78.8	112.3	92	98.6	110.6	103.6	100.1	69.16	13.74
42	110.1	105.2	106.2	107.6	103.8	101.6	105.3	95.87	20.11
43	159.7	152.8	156.8	136.6	175.4	144	153.0	103.69	22.18
44	376.2	364.4	355.2	405	351.8	343	363.5	129.7	73.80
45	201.5	211.1	119.4	210.8	182.2	173.2	179.5	143.37	65.52
46	233.8	230	187.4	181.8	188.2	218.2	207.0	129.75	31.87
47	187.4	148.8	128.2	140.4	112.1	146.8	142.9	157.35	19.26
48	171.3	156.6	134.2	232.6	265.8	162.8	179.0	130.97	15.26
49	183.7	257.9	149	226.6	324	224.8	223.1	144.01	47.29
50	72.6	76	81.4	74.8	58.5	93.3	77.8	97.41	12.49
51	159.9	156.5	90	135	139.8	171.4	140.8	76.59	23.30
52	76.8	73.5	50.2	69.8	93.8	85	73.2	67.7	11.61
53	159	146.3	138.5	153.4	112.8	116.4	137.0	69.42	24.51
54	152.2	170	143.4	166.4	149	176.6	160.4	81.37	34.55
55	156.5	163.3	140.6	145.8	91.2	154.6	144.6	89.3	36.67

continua

* Os itens em destaque referem-se a falhas devidamente preenchidas

continuação

n	JANGADA 2651003	SERRARIA S.S. 2651010	MATOS COSTA 2651011	FAXINAL 2651024	IRATIM 2651026	RIO FARIAS 2651027	MÉDIA THIESSEN	EVT (mm/mês)	VAZÃO (m³/s)
56	130.1	138.3	128.6	127	148.8	138.2	134.8	119.03	17.02
57	87.3	104.7	103	99.6	118.9	85	99.2	136.72	22.51
58	307.7	308.8	255.7	258.8	378.3	255	287.8	131.57	37.44
59	122.3	264.8	71.4	173.2	196.8	111.2	155.1	137.85	31.54
60	106.5	182.7	125	147.8	151.7	179.6	152.1	131.01	28.12
61	94.4	99	21.8	46.2	97.5	69.2	68.6	129.13	11.21
62	191.3	157.9	162.2	149	199.7	160	166.9	98.23	13.19
63	51.2	40.8	53.4	32.7	73.4	45.2	48.3	81.15	8.94
64	137.7	96.4	103.8	117	130.6	103	111.2	66	12.52
65	21.8	18.1	22	18	24	21	20.6	77.22	6.11
66	115.2	113.2	106.2	86.2	116.9	139.4	113.7	98.17	8.50
67	86.4	96	77.6	89	91.2	77.4	85.6	120.51	9.96
68	149.7	126	117.2	120.1	129.4	127.6	126.8	116.75	15.38
69	156.5	146.8	131.4	121.7	149.8	179.4	147.9	146.35	23.10
70	167.5	168.7	129.1	128	188	145.6	152.0	131.15	26.69
71	98.3	40.2	76	36	55.5	58.6	59.5	159.29	7.74
72	253.2	310.1	288.2	265	231.6	260.2	272.4	125.69	30.36
73	55.8	105.9	61.2	66	96.7	85.2	79.5	111.36	12.49
74	28.3	28.5	20.8	23.4	44.7	26.8	27.8	99.38	5.32
75	152.7	228.2	159	127.4	165.6	136.2	164.1	85.37	9.14
76	296.5	256	299.6	201.6	262.7	195.2	250.4	54.1	37.48
77	226.7	199.5	228.2	205.6	215.5	220.8	215.6	71.61	69.22
78	146.4	202.1	193.2	188	171.2	146.6	176.5	88.87	30.72
79	39.6	47.3	30.1	30.4	42.6	38.2	37.9	112.65	14.41
80	253.8	281.8	200.8	256.8	273.1	265.8	253.5	124.44	42.10
81	410.3	365.2	402	375.8	390.9	350.6	379.6	111.43	95.95
82	143.1	119.9	107.6	116.2	182	163.2	135.7	141.51	36.79
83	255.8	238.8	179.2	197.4	263	225.8	222.6	146.97	32.56
84	212.8	244.3	92.3	269.6	330.9	243.2	222.7	112.54	32.59
85	169.1	195.2	166.2	342.7	86.4	186.8	192.0	114.34	61.47
86	188.4	166.7	126.8	185.8	108.2	192.2	161.5	77.07	31.20
87	406.6	349.6	204.7	334.2	229	383.2	315.7	57.99	89.51
88	178	220.4	76.2	212.6	138.4	219.8	173.9	52.83	64.15
89	766.5	598.3	237.8	556.6	487	581.8	519.9	61.21	183.58
90	36	59.4	12.6	60.2	209.8	51.4	63.7	98.39	37.57
91	251.8	219.9	118.2	185	384.8	214	216.3	82.24	40.72
92	194.1	165.2	59.6	159.8	250.3	191.6	161.4	112.09	32.66
93	176.4	165.2	32	154.2	334.3	172.6	159.2	160.38	35.14
94	172.7	127.2	89.5	79.4	169.5	117.7	121.1	140.12	14.10
95	156.4	154.2	23.3	120.2	273	123.4	130.5	168.1	9.29
96	90.1	60.2	33.9	55.2	263	51.8	80.6	162.26	6.43
97	249.6	198.6	122.3	210.5	322.4	156.6	197.0	107.56	16.51
98	126	142.1	164.9	157.8	194	144.4	153.8	86.2	21.04
99	96.7	75.4	86.2	100	269	116.2	115.4	82.28	19.69
100	203.1	188.1	181.6	202.6	359.1	191.8	212.0	74.04	43.20
101	82.5	68.1	67.1	74.4	151	72.6	81.5	75.91	16.47
102	274.8	203.9	282.5	204.3	350	282.6	262.2	72.44	59.75
103	147.3	118.2	139.4	122.8	233	140.8	145.2	116.6	24.02
104	52.7	68.6	62.9	59.4	142	68.4	73.1	142.1	14.93
105	250.9	303.4	214.7	681.6	341	222	320.7	118.02	40.00
106	157.6	131.9	141	166.4	165.7	122.4	143.9	131.47	23.38
107	67.5	80.2	63.5	113.4	97.7	79	81.8	172.29	8.82
108	289.5	386.5	292.4	292.1	363	253.2	311.8	107.77	41.04
109	80.9	71.9	122.4	59.8	136.4	117.8	98.8	118.65	13.38
110	183.8	146.1	140.9	130.6	195.6	178.8	159.8	89.63	21.66

continua

* Os itens em destaque referem-se a falhas devidamente preenchidas

continuação

n	JANGADA 2651003	SERRARIA S.S. 2651010	MATOS COSTA 2651011	FAXINAL 2651024	IRATIM 2651026	RIO FARIAS 2651027	MÉDIA THIESSEN	EVT (mm/mês)	VAZÃO (m³/s)
111	51.2	56.4	25.3	53	47.4	74.5	51.3	84.38	9.46
112	35.5	56.3	14	26.5	34.4	37.4	34.2	68.47	5.65
113	67.7	61.4	50.5	63.5	72.6	52.8	59.8	72.42	6.26
114	32.8	55.1	20.4	50.1	59.6	64.8	47.0	103.01	4.78
115	81.5	127.6	60.1	133.2	97.8	70.2	93.6	101.23	7.67
116	118.5	136.9	63.1	123.8	136.2	146.8	119.3	141.34	7.14
117	123.9	157.8	55.5	137.9	92.9	113	112.6	175.74	18.88
118	48.2	87.8	42.8	83.9	79.6	94.2	73.4	169.78	3.63
119	116	220.2	79.4	226.6	228.4	167.8	169.7	167.27	6.04
120	212.5	119.8	356.8	157.3	241.9	184.6	213.3	121.72	21.11
121	81.1	74	155.6	50.1	52.6	60.8	83.1	127.11	11.96
122	162	170.7	157.7	167.8	157.4	205.6	171.8	97.84	19.93
123	180.4	221.5	183.1	206.7	206.8	222.8	204.8	72.87	24.77
124	17	16.2	22.8	18.4	22.2	17.6	19.0	74.47	21.09
125	37.7	37.4	10.8	42.3	51.4	41	35.0	63.61	7.16
126	113.3	117.1	140.5	60.3	106.4	115.8	111.7	87.68	9.72
127	148.9	141.6	160.1	139.5	165.2	150.4	150.5	98.34	18.17
128	137	126.5	108.5	129.8	120.2	142.2	126.7	151.19	22.89
129	119.4	255.5	103.1	179.5	187.4	241.2	185.3	141.17	25.39
130	171.2	128	158.1	147.5	120.6	70.8	129.7	130.77	16.25
131	166.1	176	211.8	221.5	174.6	167.6	186.7	159.68	17.81
132	175.7	248.1	216.3	245.7	226	202.8	220.5	121.42	30.34
133	54.1	36.9	54.3	36.5	72.4	41.7	47.8	145.22	10.03
134	94.1	127.8	149.6	127.2	166.4	87.8	124.8	83.13	9.83
135	357.2	326.5	311	353.4	465	336.5	349.4	60.75	77.75
136	165.4	111.9	125.5	117.1	138.9	149.6	132.6	61.09	34.36
137	86.2	100.2	57.4	63.3	101.2	99.3	84.2	80.85	22.65
138	91.4	109.5	61.2	87.9	115.4	100.9	93.1	88.02	15.44
139	48.2	63.7	132.3	53.8	52.6	106.6	81.9	93.74	9.48
140	160.4	158.2	128	160	183.7	261.5	176.2	115.94	22.18
141	197.8	141.2	63.3	127.1	79.2	120.2	117.8	141.79	13.16
142	88.1	124	124.7	133.7	162.2	80.6	117.1	151.38	8.90
143	240	245.9	105	409.1	228.8	282.7	244.3	163.06	20.91
144	184.8	99.4	75.5	112.9	184.4	105.2	118.0	110.43	18.22
145	70.1	81.7	96.6	104.9	95.8	121.4	96.4	140.86	13.44
146	127.7	172.6	110	162.1	151.5	120.3	139.5	80.71	14.79
147	369.7	303.5	270.1	325.9	410.2	331.6	326.0	57.1	78.76
148	124.8	142.1	131.5	153.5	150.8	130.3	138.0	68.18	41.48
149	6.7	8.9	3.2	16.2	7.4	19.7	10.5	77.84	14.91
150	26.9	30.2	25.2	26	28.6	33.5	28.6	103.49	6.92
151	67.2	82.9	89.1	87.2	91.2	111.4	89.6	103.22	7.28
152	181.5	209	103.1	151	197.4	186.5	169.3	130.63	19.87
153	35.5	53.3	41.2	84.7	58	22.3	47.4	167.6	8.61
154	177.5	236	151.2	179.3	167.7	164.6	180.2	147.97	12.32
155	232.7	278.1	225.9	255.4	261.7	122.3	225.0	127.2	27.51
156	195	172.9	99.4	101.5	208	214.4	162.5	114.21	40.21
157	113.6	151	197.2	162.8	135.6	127.3	151.1	124.62	24.91
158	148.4	99.3	54.1	96.1	97.8	90.6	93.3	98.52	18.40
159	130.2	126.1	186.2	111.3	130	128	137.7	74.44	27.78
160	71.7	83.4	68	67.5	82.2	60.4	71.7	57.35	10.25
161	146.8	140.5	139.8	129.2	165.6	153.9	145.1	73.59	18.19
162	106	106.3	86.9	197.2	94.6	71.8	106.8	83.2	18.00
163	304.1	274.3	291.4	277.1	304.2	314.8	293.3	101.64	67.27
164	184.7	189.1	179.6	177.9	221.6	169.4	184.8	136.72	34.29
165	85.6	76.8	90.6	71.2	137	86.6	89.2	153.18	15.66

continua

* Os itens em destaque referem-se a falhas devidamente preenchidas

continuação

n	JANGADA 2651003	SERRARIA S.S. 2651010	MATOS COSTA 2651011	FAXINAL 2651024	IRATIM 2651026	RIO FARIAS 2651027	MÉDIA THIESSEN	EVT (mm/mês)	VAZÃO (m³/s)
166	38.2	53.7	69.6	99.7	76.3	40.9	61.9	149.14	7.32
167	294.1	250.7	305.1	271.6	296.8	317.9	289.0	155.5	41.85
168	190.7	139.2	203.5	121.7	201.3	161.2	168.1	155.5	22.68
169	217.5	223.7	229.6	211.5	228.5	300.3	238.2	123.56	22.30
170	223.4	219.9	140.3	239.8	184.4	177.4	193.5	98.24	36.91
171	183.6	220.8	176.6	239.3	224.9	174.2	200.7	78.31	39.19
172	252.4	246.3	239.8	173.2	140.4	214.9	215.7	57.99	97.41
173	196.7	160.3	182.9	31.1	128.4	114	137.5	54.26	42.17
174	231.4	111	173	127	204.4	198.4	169.4	81.25	48.50
175	184.3	175.9	169.7	97.7	113.6	130.9	147.6	97.23	45.85
176	174.1	178.5	197.2	150.7	189.4	133	169.9	128.22	41.56
177	261.3	146.7	311.7	154.3	203.6	307.9	234.9	130.33	47.84
178	150	166.8	178.2	170.7	141.9	332.6	197.9	159.24	27.60
179	152.9	154	91	126	122.6	103.3	122.6	163.12	13.63
180	57.5	96.8	27.6	113.8	51.6	22.2	59.6	149.86	11.74
181	86.8	159	105.2	81.4	102.7	125.3	114.3	111.92	6.48
182	201.3	117.3	117.4	232.3	166.2	138.8	153.9	91.62	12.35
183	23.4	40	25.4	43.3	17.2	40.2	32.7	80.66	7.04
184	287.1	228.3	242.4	336.9	276.4	252.7	264.3	63.55	36.70
185	58.5	69	54.9	92.7	82	86.6	73.3	81.36	19.53
186	94.3	104.8	89.5	109.4	126.6	75.6	97.7	85.88	21.81
187	32.2	34.7	26.3	29.6	44.6	48.1	35.8	105.32	8.48
188	175.7	199.3	215.9	114.5	177.5	237.4	192.6	127.49	26.31
189	115.5	160	78.4	173	94.3	121.8	123.7	164.5	19.60
190	233.8	183.1	386.3	199.5	164.5	195.1	233.7	166.67	15.79
191	98.6	158.8	112.6	154.3	168	118.3	134.2	168.98	10.80
192	169.2	194.1	136.8	216.2	163.8	163.4	172.3	139.82	15.18
193	210.2	128.7	211.9	172.5	205	115.2	168.4	110.85	13.63
194	114.5	103.5	118.5	114.4	131.4	115.5	115.2	94.88	14.47
195	472.9	362.9	282.8	382.5	506.4	392.4	385.2	61.59	74.78
196	172.9	169.5	190.6	171.8	172.8	174.5	175.9	64.11	52.78
197	130.1	162.8	128.8	175.3	128.9	143.9	145.5	59.6	59.98
198	132.1	119.8	83.9	153.5	171.7	164.4	133.8	73.14	33.09
199	97.7	114.6	60.1	108.8	123.5	110.6	100.6	91.75	27.21
200	96.2	115.1	85.6	110	94.3	105.4	101.4	125.8	16.84
201	180.1	131.8	113.1	141.9	224.9	192.1	158.4	139.14	21.99
202	164.3	124.2	137.9	126.6	92.9	153.5	134.1	167.54	23.31
203	167.4	336.8	202.6	220.8	251.3	268.3	247.6	151.83	24.17
204	180.6	89.2	98	110.4	162.1	147.3	125.4	107.6	27.57
205	93.7	106.5	119.6	95.4	110.8	54	96.0	127.03	18.01
206	99.7	50.5	65.1	62.5	69.5	47.1	62.7	102.22	11.54
207	247.3	217.2	245.6	212.1	219.6	219.5	226.5	77.44	31.79
208	112.4	84.2	30.9	85.9	113.8	88.1	81.0	58.15	32.83
209	145.2	132.4	67.5	143.6	125.2	124.6	119.4	73.61	22.21
210	9.7	5.7	14.5	19.4	1.1	3.1	8.9	97.7	14.07
211	283.8	318.9	221	270.3	222.1	254.3	262.3	83.52	37.70
212	161.6	205.8	102.7	170.7	142.8	168.1	158.6	132.17	61.83
213	146.6	111.7	46	90.8	92.1	155.9	105.6	176.85	14.47
214	163.4	153.9	204.5	102.7	109	165.8	155.0	164.5	19.60
215	106.8	52.2	117.6	118.4	38	60	81.6	144.08	7.30
216	273.8	199.5	135.1	177.3	183.2	197.5	189.2	121.05	24.60
217	48.4	104.4	59.4	78.7	2.8	92.5	69.8	126.62	11.13
218	126.4	169.7	63	173.8	63.3	155.8	127.0	93.24	16.46
219	171.4	167.9	135.9	226.6	126.7	176.1	166.5	74.15	31.04
220	185.7	182	83.5	165	188	159.1	155.5	60.33	48.46
221	199.5	167.4	172.1	191.1	187.5	234.2	191.3	78.72	60.87

conclusão

* Os itens em destaque referem-se a falhas devidamente preenchidas

APÊNDICE 2 – RESULTADOS REDES NEURAIS

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1	R11A30E11	79.37	9.62	0.02	82.13	13.03	3.58
2	R11A60E11	79.42	9.61	0.01	82.85	12.74	3.29
3	R11A90E11	79.43	9.6	0.1	83.03	12.67	3.28
4	R11A30E12	88.85	10.65	0.02	75.19	11.96	4.21
5	R11A60E12	88.89	10.64	0.01	75.28	11.92	4.21
6	R11A90E12	88.9	10.63	0.01	75.30	11.9	4.22
7	R11A30E13	87.12	10.7	0.02	68.82	13.16	2.27
8	R11A60E13	87.48	10.56	-0.02	69.72	13.22	0.77
9	R11A90E13	87.89	10.39	-0.22	69.26	13.48	-0.38
10	R12A30E11	81.99	9.05	0	74.52	15.16	5.26
11	R12A60E11	82	9.05	0	75.31	14.99	5.4
12	R12A90E11	82	9.05	0	75.32	14.99	5.4
13	R12A30E12	91.08	9.59	-0.27	71.82	15.51	-2.3
14	R12A60E12	91.31	9.47	0	71.36	15.32	-1.06
15	R12A90E12	91.4	9.42	0	71.21	15.33	-0.77
16	R12A30E13	88.04	10.33	0.03	70.68	13.34	2.2
17	R12A60E13	88.7	10.06	0.01	68.64	13.96	2.78
18	R12A90E13	88.74	10.05	0	68.29	14.12	3.15
19	R13A30E11	86.54	7.92	-0.04	72.07	15.66	3.19
20	R13A60E11	86.96	7.8	0.03	74.6	15.12	4.48
21	R13A90E11	87.58	7.63	0.01	68.5	17.14	5
22	R13A30E12	92.38	8.89	0.53	72.16	14.31	-1.59
23	R13A60E12	93.64	8.15	0.02	66.71	15.85	-2.17
24	R13A90E12	93.67	8.13	-0.31	66.42	15.69	-1.96
25	R13A30E13	89.81	9.58	0.04	62.31	14.53	1.39
26	R13A60E13	90.04	9.48	-0.01	61.58	14.87	1.23
27	R13A90E13	90.07	9.47	0	61.65	14.93	1.27
28	R14A30E11	85.58	8.18	0.68	72.26	15.86	6.07
29	R14A60E11	86.96	7.81	0.17	71.26	15.97	4.22
30	R14A90E11	88.55	7.36	-1.98	66	17.06	4.35
31	R14A30E12	91.78	9.22	1.39	73.64	13.49	-1.36
32	R14A60E12	92.98	8.55	0	70.35	14.13	1.9
33	R14A90E12	93.43	8.28	0.01	64.85	15.05	1.86
34	R14A30E13	89.56	9.7	-0.5	69.32	12.94	-0.11
35	R14A60E13	89.85	9.57	0.58	67.12	13.07	2.64
36	R14A90E13	90.47	9.28	0	68.3	14.55	-2.46
37	R21A30E21	-24.03	15.83	0	-11.04	22.65	9.05
38	R21A60E21	-24.03	15.83	0	-11.04	22.65	9.05
39	R21A90E21	-24.03	15.83	0	-11.04	22.65	9.05
40	R21A30E22	92.81	8.64	0	83.93	9.78	5.33
41	R21A60E22	92.82	8.64	0	83.09	10.08	6.62
42	R21A90E22	92.82	8.64	0	83.08	10.08	6.61
43	R21A30E23	91.31	9.53	0.28	78.86	10.23	5.25
44	R21A60E23	91.43	8.84	0	78.67	10.82	6.24
45	R21A90E23	91.43	8.84	0	78.67	10.82	6.24
46	R22A30E21	86.63	7.91	-0.14	84.24	12.31	1.83
47	R22A60E21	92.4	6.06	-0.32	72.64	15.68	8.55
48	R22A90E21	93.63	5.56	-0.01	69.4	16.52	7.34
49	R22A30E22	93.88	8	-0.88	82.16	11.01	-0.07
50	R22A60E22	94.88	7.34	-0.07	77.05	12.36	-2.15
51	R22A90E22	95.19	7.11	-0.02	75.85	12.95	-4.66
52	R22A30E23	93.45	7.77	-0.44	76.21	11.99	1.73
53	R22A60E23	93.91	7.5	0	74.62	12.79	0.21
54	R22A90E23	93.94	7.48	-0.03	73.94	13.01	-0.4

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
55	R23A30E21	86.61	7.91	-0.13	84.37	12.19	1.39
56	R23A60E21	91.93	6.23	-0.14	76.99	14.43	4.62
57	R23A90E21	93.52	5.61	-0.02	76.59	14.59	2.93
58	R23A30E22	95.65	6.78	0.64	80.2	10.97	-2.42
59	R23A60E22	96.52	6.07	-0.02	80.06	11.09	-3.43
60	R23A90E22	96.6	6.01	-0.01	79.84	11.15	-3.09
61	R23A30E23	94.69	7.07	-2.8	75.67	11.47	-0.03
62	R23A60E23	95.36	6.57	-0.23	77.59	11.25	3.28
63	R23A90E23	95.45	6.51	0	76.85	10.97	5.64
64	R24A30E21	84.92	8.36	0.03	72.48	15.58	5
65	R24A60E21	85.17	8.3	0	72.27	15.63	5.26
66	R24A90E21	91.49	6.52	-1.74	64.68	17.31	8.04
67	R24A30E22	96.3	6.26	-0.49	82.34	10.3	-0.35
68	R24A60E22	96.75	5.87	-0.01	78.68	11.22	-3.59
69	R24A90E22	97.04	5.61	-0.08	75.11	12.64	-5.55
70	R24A30E23	93.18	7.92	-0.47	77.75	11.24	1.96
71	R24A60E23	95.42	6.52	-0.01	76.35	11.13	4.42
72	R24A90E23	95.65	6.37	-0.01	78.37	10.54	4.8
73	R31A30E31	93.39	5.66	0	84.39	12.1	0.89
74	R31A60E31	93.39	5.66	0	84.39	12.1	0.89
75	R31A90E31	93.39	5.66	0	84.39	12.1	0.89
76	R31A30E32	96.13	6.4	0.02	83.29	10.68	3.1
77	R31A60E32	96.13	6.4	0	83.31	10.69	3.06
78	R31A90E32	96.13	6.4	0	83.31	10.69	3.06
79	R31A30E33	94	7.45	0	85.64	8.99	8.13
80	R31A60E33	94	7.45	0	85.64	8.99	8.13
81	R31A90E33	94	7.45	0	85.64	8.99	8.13
82	R32A30E31	96.33	4.25	-0.6	82.85	12.69	5.35
83	R32A60E31	96.92	3.9	0	79.62	14.19	4.09
84	R32A90E31	96.95	3.88	0	78.62	14.6	4.6
85	R32A30E32	97.34	5.32	0.23	82.29	11.56	2.22
86	R32A60E32	97.47	5.19	0.01	82.12	12.27	0.63
87	R32A90E32	97.69	4.96	0	80.62	13.64	0.1
88	R32A30E33	94.16	7.35	-0.77	85.99	8.77	7.06
89	R32A60E33	94.18	7.34	0	86.02	8.82	7.59
90	R32A90E33	94.18	7.34	0	86.01	8.82	7.54
91	R33A30E31	95.88	4.5	-0.06	78.78	13.87	0.56
92	R33A60E31	96.56	4.12	0	73.42	15.3	2.2
93	R33A90E31	97.73	3.35	0.03	64.67	17.44	10.35
94	R33A30E32	96.65	5.97	0.72	82.9	10.64	5.21
95	R33A60E32	96.94	5.71	0.25	77.56	12.53	5.02
96	R33A90E32	97.51	5.15	-0.04	62.4	19.24	7.7
97	R33A30E33	95.08	6.76	0.12	85.53	8.84	8.49
98	R33A60E33	96.06	6.06	0.01	83.46	9.39	6.83
99	R33A90E33	96.11	6.02	-0.03	83.67	9.37	6.83
100	R34A30E31	96.28	4.28	-0.11	79.89	13.57	-2.68
101	R34A60E31	98.28	2.92	0	69.26	16.38	7.16
102	R34A90E31	98.46	2.77	0.01	65.08	17.33	6.24
103	R34A30E32	96.76	5.86	-0.12	82.24	11.03	2.97
104	R34A60E32	97.26	5.4	0.06	79.35	11.9	4.19
105	R34A90E32	97.57	5.08	0	80.4	11.17	3.86
106	R34A30E33	95.95	6.15	1.06	83.21	9.81	14
107	R34A60E33	97.61	4.75	-0.36	84.82	9.2	7.28
108	R34A90E33	97.74	4.61	0	86.58	8.56	8.79

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
109	R41A30E41	93.39	5.66	0	84.44	12.08	0.99
110	R41A60E41	94.04	5.38	-0.01	74.48	16.13	-7.14
111	R41A90E41	94.06	5.38	0	54.29	28.3	-23.99
112	R41A30E42	95.54	7.69	-3.48	86.56	8.97	0.73
113	R41A60E42	95.72	6.72	-0.02	86.9	8.97	4.75
114	R41A90E42	95.73	6.71	0	86.92	8.95	4.55
115	R41A30E43	-11.15	21.82	0	-12.79	16.39	1.25
116	R41A60E43	-11.15	21.82	0	-12.79	16.39	1.25
117	R41A90E43	-11.15	21.82	0	-12.79	16.39	1.25
118	R42A30E41	93.76	5.5	0	84.31	12.18	1.19
119	R42A60E41	93.77	5.5	0	84.32	12.18	1.12
120	R42A90E41	93.78	5.5	0	84.32	12.18	1.1
121	R42A30E42	95.93	6.56	-0.09	85.72	9.59	3.32
122	R42A60E42	96.12	6.41	0	81.44	11.25	2.05
123	R42A90E42	96.12	6.41	0	81.53	11.21	2.05
124	R42A30E43	94.11	7.38	0.01	83.58	9.73	6.07
125	R42A60E43	94.2	7.32	-0.02	83.44	9.77	5.74
126	R42A90E43	94.24	7.3	-0.01	83.43	9.77	5.64
127	R43A30E41	94.7	5.16	-3.46	82.03	12.9	-2.78
128	R43A60E41	97.58	3.46	0.04	84.73	12.02	3.84
129	R43A90E41	99.47	1.63	-0.21	67.6	17.38	-0.71
130	R43A30E42	96.68	5.93	0.04	86.19	9.15	2.45
131	R43A60E42	96.75	5.87	0.04	85.83	9.25	1.96
132	R43A90E42	97.09	5.56	-0.01	86.88	8.98	2.66
133	R43A30E43	95.05	6.78	-0.01	88.67	8.11	7.15
134	R43A60E43	95.14	6.72	0	83.86	10.58	12.53
135	R43A90E43	95.14	6.72	0	84.53	10.21	11.74
136	R44A30E41	97.7	3.37	0.13	72.35	15.8	7.52
137	R44A60E41	97.9	3.23	0.03	75.89	14.86	1.65
138	R44A90E41	98.06	3.11	0	76.06	14.83	1.17
139	R44A30E42	96.61	6	0.64	84.19	10.31	2.65
140	R44A60E42	98.09	4.52	0.02	81.98	10.98	4.17
141	R44A90E42	98.62	3.84	0	80.34	11	5.29
142	R44A30E43	94.74	6.98	-0.23	83.43	10.38	4.58
143	R44A60E43	95.33	6.59	-0.21	79.92	13.99	1.5
144	R44A90E43	96.28	5.9	-0.56	85.25	9.72	3.86
145	R51A30E51	93.53	6.37	-10.9	86.76	11.77	-8.3
146	R51A60E51	93.66	5.54	0	84.96	11.91	0.87
147	R51A90E51	93.66	5.54	0	84.96	11.91	0.87
148	R51A30E52	96.29	6.26	0	64.89	15.77	14.25
149	R51A60E52	96.29	6.26	0	86.15	9.27	6.89
150	R51A90E52	96.29	6.25	0	86.42	9.17	6.61
151	R51A30E53	94.62	7.06	0.01	85.7	9.32	8.45
152	R51A60E53	94.62	7.06	0	85.7	9.31	8.43
153	R51A90E53	94.62	7.06	0	85.7	9.31	8.43
154	R52A30E51	95.75	4.56	0	81.23	13.24	-1.57
155	R52A60E51	95.85	4.51	-0.01	81.28	13.21	-1.21
156	R52A90E51	96	4.43	-0.01	81.21	13.25	-1.05
157	R52A30E52	97.42	5.24	0	85.85	9.87	4.16
158	R52A60E52	97.42	5.24	0	85.85	9.86	4.13
159	R52A90E52	97.42	5.24	0	85.85	9.86	4.13
160	R52A30E53	95.91	6.18	0.03	82.66	10.27	7.73
161	R52A60E53	96.8	5.47	0.12	78.26	12.04	5.88
162	R52A90E53	97.33	5.01	0	68.05	14.34	12.64

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
163	R53A30E51	95.26	4.81	-0.01	80.98	14.16	-6.25
164	R53A60E51	96.03	4.41	-0.02	80.89	14.31	-5.42
165	R53A90E51	96.06	4.39	0	80.81	14.33	-5.72
166	R53A30E52	97.71	4.94	0	78.55	12.02	1.32
167	R53A60E52	97.71	4.93	0	78.63	11.98	0.94
168	R53A90E52	97.75	4.89	0.28	79.08	11.86	1.59
169	R53A30E53	96.13	6.01	-0.19	84.94	9.59	8.23
170	R53A60E53	97.24	5.09	-0.06	83.42	10.03	5.63
171	R53A90E53	97.54	4.81	-0.11	84.56	9.87	5.6
172	R54A30E51	98.87	2.39	0.95	72.23	16.23	11.45
173	R54A60E51	99.33	1.83	-0.04	75.58	15.23	5.67
174	R54A90E51	99.56	1.48	-0.12	73.95	15.78	6.77
175	R54A30E52	96.71	5.9	-0.07	87.14	8.94	5.39
176	R54A60E52	96.78	5.84	-0.01	85.16	9.53	4.26
177	R54A90E52	96.78	5.84	0	85.15	9.53	4.31
178	R54A30E53	94.97	6.83	0.01	86.32	9.39	9.46
179	R54A60E53	95.95	6.15	0.01	82.38	10.72	12.89
180	R54A90E53	96.07	6.05	0	75.22	12.84	10.86
181	R61A30E61	94.77	5.05	0.25	67.68	16.77	6.3
182	R61A60E61	95.02	4.93	0.01	66.23	19.24	12.3
183	R61A90E61	95.05	4.91	0.01	70.67	25.47	7.2
184	R61A30E62	96.98	5.66	0.01	84.66	9.83	6.57
185	R61A60E62	96.98	5.66	0	84.75	9.8	6.53
186	R61A90E62	98.27	4.32	0.05	83.07	10.44	5.24
187	R61A30E63	95.38	6.55	0.02	86.42	9.25	8.54
188	R61A60E63	95.38	6.55	0	86.48	9.22	8.54
189	R61A90E63	95.39	6.55	0.01	86.44	9.22	8.48
190	R62A30E61	96.47	4.17	0	80.38	13.52	2.36
191	R62A60E61	96.51	4.14	0	79.85	13.71	2.4
192	R62A90E61	96.51	4.14	0	79.84	13.71	2.41
193	R62A30E62	96.49	6.09	0	86.65	9.14	6.57
194	R62A60E62	97.71	4.93	0	83.13	10.46	6.74
195	R62A90E62	97.71	4.93	0	83.13	10.46	6.74
196	R62A30E63	96.13	6.01	0	78.93	16.15	-1.91
197	R62A60E63	96.14	6.01	0	79.2	15.77	-1.43
198	R62A90E63	96.14	6.01	0	79.22	15.75	-1.4
199	R63A30E61	97.37	3.6	0.43	83.57	12.43	2.53
200	R63A60E61	99.4	1.73	0.05	73.16	16.34	1.29
201	R63A90E61	99.84	0.89	0.04	73.19	18.3	-5.31
202	R63A30E62	96.64	5.96	-0.01	86.69	9.14	6.2
203	R63A60E62	96.71	5.9	0	86.82	9.1	6.05
204	R63A90E62	96.99	5.65	-0.05	86.47	9.12	3.8
205	R63A30E63	97.02	5.29	-0.77	77.38	20.25	-4.21
206	R63A60E63	98.54	3.71	0	69.77	23.67	-17.27
207	R63A90E63	98.55	3.7	0	69.48	23.56	-16.91
208	R64A30E61	99.24	1.94	-0.07	67.75	19.51	11.94
209	R64A60E61	99.53	1.54	0	66.86	20.06	10.88
210	R64A90E61	99.54	1.51	0	66.72	20.64	12.69
211	R64A30E62	97.76	4.88	-0.48	80.46	12.16	7.37
212	R64A60E62	98.13	4.47	-0.05	83.12	11.05	4.47
213	R64A90E62	98.15	4.44	0	82.58	11.16	3.7
214	R64A30E63	95.14	6.72	-0.02	85.34	9.67	8.62
215	R64A60E63	96.86	5.42	-0.04	71.27	27.64	-3.99

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
216	R64A90E63	96.94	5.36	0.01	71.46	21.88	2.97
217	R11B30E11	22.17	15.42	0	5.09	23.15	8.51
218	R11B60E11	77.21	10.21	3.85	71.86	16.41	9.12
219	R11B90E11	79.37	9.62	0.04	82.12	13.03	3.6
220	R11B30E12	91.23	9.51	-0.12	71.76	15.07	-1.3
221	R11B60E12	91.33	9.45	-0.01	71.41	15.23	-0.93
222	R11B90E12	91.47	9.38	0	71.02	15.3	-0.39
223	R11B30E13	87.29	10.63	0.33	69.31	13.18	1.92
224	R11B60E13	87.4	10.59	0.04	69.31	13.23	1.19
225	R11B90E13	87.44	10.57	0.04	69.33	13.27	0.93
226	R12B30E11	84.58	8.43	0.09	63.65	17.6	10.77
227	R12B60E11	87.71	7.59	-0.01	36.01	40.13	-12.43
228	R12B90E11	87.96	7.52	0.01	29.75	55.05	-20.67
229	R12B30E12	91.28	9.48	0	72.28	15	-1.6
230	R12B60E12	92.59	8.77	0	69.12	16.69	-4.66
231	R12B90E12	92.62	8.75	0	69.12	16.74	-4.8
232	R12B30E13	89.81	9.59	-0.35	65.94	13.8	1.54
233	R12B60E13	90.23	9.39	0	61.83	14.55	3.41
234	R12B90E13	90.3	9.36	0	61.57	14.62	3.66
235	R13B30E11	81.7	9.12	-0.42	78.12	14.3	5.66
236	R13B60E11	81.87	9.08	0	73.76	15.43	6.88
237	R13B90E11	83.02	8.81	0	73.49	15.49	8.3
238	R13B30E12	90.41	9.92	-0.9	74	13.5	-0.73
239	R13B60E12	91.14	9.55	0.02	73.53	13.76	-2.25
240	R13B90E12	91.55	9.34	0	72.38	14.11	-3.08
241	R13B30E13	88.47	10.18	-0.25	71.36	13.23	-1.41
242	R13B60E13	89.95	9.52	-0.05	64.42	14.06	2
243	R13B90E13	90.55	9.25	0	63.1	14.06	5
244	R14B30E11	86.36	7.97	-0.9	72.61	15.57	5.95
245	R14B60E11	87.51	7.65	-0.01	59.68	18.64	11.08
246	R14B90E11	87.54	7.64	0.01	67.81	16.73	7.23
247	R14B30E12	92.01	9.09	-0.26	70.06	15.83	-2.85
248	R14B60E12	92.38	8.89	-0.02	66.85	17.39	-2.25
249	R14B90E12	92.45	8.85	0.02	66.46	17.49	-1.89
250	R14B30E13	88.82	10.02	-1.39	69.79	13.71	3.04
251	R14B60E13	89.25	9.83	0.11	69.04	13.99	2.89
252	R14B90E13	89.83	9.57	0.4	69.89	13.74	3.76
253	R21B30E21	83.69	8.67	0.06	88.1	11.07	1.31
254	R21B60E21	83.81	8.64	-1.36	88.73	10.72	-0.12
255	R21B90E21	83.91	8.61	0.01	89	10.49	1.69
256	R21B30E22	94.5	7.59	0	86.08	9.16	3.49
257	R21B60E22	94.54	7.57	0	85.65	9.3	3.48
258	R21B90E22	94.54	7.57	0	85.65	9.3	3.48
259	R21B30E23	91.81	8.65	0.03	77.27	11.57	4.57
260	R21B60E23	91.91	8.6	-0.01	77.61	11.45	4.12
261	R21B90E23	91.95	8.58	-0.05	77.68	11.42	4.02
262	R22B30E21	89.25	7.15	-0.39	76.13	14.73	4.7
263	R22B60E21	93.81	5.48	-0.01	71.53	16	9.62
264	R22B90E21	94.1	5.36	-0.01	70.62	16.24	9.97
265	R22B30E22	94.99	7.26	-0.29	84.29	9.62	0.48
266	R22B60E22	95.12	7.17	-1.56	84.23	9.61	-1.31
267	R22B90E22	96.15	6.38	0.05	79.64	10.87	-2.24
268	R22B30E23	92.71	8.18	-0.07	80.12	10.54	2.53
269	R22B60E23	93.77	7.58	-0.18	74.39	13.02	0.47
270	R22B90E23	93.96	7.47	0	73.05	13.19	-0.62

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
271	R23B30E21	93.47	5.63	0.07	70.83	16.39	13.62
272	R23B60E21	94.24	5.29	0.01	67.25	17.11	11.39
273	R23B90E21	94.83	5.03	0	62.68	18.65	12.86
274	R23B30E22	96.04	6.47	-0.28	77.69	11.77	-4.33
275	R23B60E22	96.23	6.31	-0.01	76.05	12.44	-5.1
276	R23B90E22	96.28	6.27	0	75.9	12.47	-5.39
277	R23B30E23	93.39	7.82	-1.93	76.35	11.48	1.3
278	R23B60E23	93.99	7.45	-0.03	73.3	12.51	4.28
279	R23B90E23	94.07	7.4	0	71.83	15.78	0.32
280	R24B30E21	83.87	8.62	0.03	87.79	10.93	2.08
281	R24B60E21	83.99	8.59	0.02	89.61	10.18	0.15
282	R24B90E21	84.06	8.57	0.03	90.34	9.84	-0.17
283	R24B30E22	95.78	6.67	0.22	79.62	11.17	-4.02
284	R24B60E22	96.66	5.95	-0.23	78.59	11.76	-4.29
285	R24B90E22	97.15	5.5	0	77.91	12.41	-4.51
286	R24B30E23	95.39	6.55	0.16	77.94	10.65	5.11
287	R24B60E23	96.09	6.04	-0.03	72.38	11.95	7.69
288	R24B90E23	96.32	5.86	0	71.76	11.94	6.44
289	R31B30E31	93.39	5.66	0	84.39	12.1	0.89
290	R31B60E31	93.39	5.66	0	84.39	12.1	0.89
291	R31B90E31	93.39	5.66	0	84.39	12.1	0.89
292	R31B30E32	96.93	5.71	0	78.37	12.23	-0.9
293	R31B60E32	96.93	5.71	0	78.35	12.24	-0.95
294	R31B90E32	96.93	5.71	0	78.33	12.25	-0.98
295	R31B30E33	94.16	7.35	-0.21	85.41	8.99	8.36
296	R31B60E33	94.49	7.14	0	82.16	9.88	7.29
297	R31B90E33	94.6	7.07	0	81.06	10.14	7.43
298	R32B30E31	95.46	4.71	-0.03	79.69	13.65	0.31
299	R32B60E31	96.49	4.16	0.01	80.04	13.98	10.05
300	R32B90E31	97.07	3.8	0	80.75	13.37	3.64
301	R32B30E32	96.43	6.15	0.04	84.07	10.39	3.9
302	R32B60E32	96.52	6.08	0.06	83.04	10.7	4.28
303	R32B90E32	97.02	5.63	0	78.77	15.5	1.58
304	R32B30E33	94.52	7.12	-0.01	85.95	9.47	9.03
305	R32B60E33	94.72	6.99	0.04	85.64	9.27	6.88
306	R32B90E33	94.83	6.92	0.1	86.35	8.94	6.57
307	R33B30E31	98.21	2.98	-0.06	75.39	16.56	-1.65
308	R33B60E31	98.56	2.68	0	74.84	17.15	-0.2
309	R33B90E31	98.56	2.68	0	74.61	17.02	0.7
310	R33B30E32	97.22	5.44	0	83.35	10.68	6.34
311	R33B60E32	97.52	5.14	0.26	81.2	11.22	4.7
312	R33B90E32	97.68	4.97	0.02	78.9	12.28	3.75
313	R33B30E33	95.88	6.2	-0.59	77.34	11.37	15.2
314	R33B60E33	96.99	5.32	0	75.15	12.23	17.27
315	R33B90E33	97.07	5.24	-0.01	80.9	11.35	9.48
316	R34B30E31	94.44	5.21	-0.39	82.22	12.82	0.17
317	R34B60E31	94.82	5.03	-0.02	81.52	13.06	0.33
318	R34B90E31	97.08	3.8	0.25	82.18	12.83	-0.18
319	R34B30E32	97.09	5.56	0.02	81.83	11.59	0.27
320	R34B60E32	97.66	5	0.1	80.93	12.73	-2.4
321	R34B90E32	97.93	4.69	0	80.81	12.62	-1.84
322	R34B30E33	94.24	7.3	-0.08	85.67	9.08	6.09
323	R34B60E33	95.34	6.58	0.31	82.46	9.87	9.91
324	R34B90E33	96.27	5.9	-0.07	82.19	9.92	8.65

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
325	R41B30E41	94.65	5.11	-0.05	83.26	12.53	3.03
326	R41B60E41	95.61	4.64	0.46	75.15	15.84	7.98
327	R41B90E41	95.94	4.47	-0.09	73.3	17.6	11.9
328	R41B30E42	96.56	6.04	-0.02	84.94	9.8	4.14
329	R41B60E42	96.73	5.89	0	74.05	13.9	-1.71
330	R41B90E42	96.73	5.89	0	72.63	14.43	-2.17
331	R41B30E43	94.09	7.39	-0.03	84.05	9.89	6.83
332	R41B60E43	94.19	7.33	-0.19	83.1	10.35	6.47
333	R41B90E43	96.14	6.01	0	82.17	10.52	1.69
334	R42B30E41	94.8	5.05	0.18	80.45	13.38	0.78
335	R42B60E41	96.18	4.34	0.08	80.68	13.34	-1.42
336	R42B90E41	96.99	3.86	0.01	85.37	11.91	-0.68
337	R42B30E42	96.69	5.93	-0.6	82.14	10.54	0.81
338	R42B60E42	96.86	5.77	0.02	82.46	10.28	1.18
339	R42B90E42	96.86	5.77	0	81.11	10.68	0.64
340	R42B30E43	94.9	6.88	0	81.55	10.06	7.88
341	R42B60E43	94.92	6.87	-0.01	81.08	10.2	7.58
342	R42B90E43	94.93	6.86	0	80.79	10.3	7.43
343	R43B30E41	95.96	4.45	0.06	80.75	13.3	0.65
344	R43B60E41	98.52	2.72	-0.82	78.66	14.07	7.32
345	R43B90E41	99.15	2.06	0	70.05	17.27	12.22
346	R43B30E42	97.7	4.95	-0.01	82.39	10.24	1.79
347	R43B60E42	98.26	4.31	0.1	86.1	9.12	2.44
348	R43B90E42	98.91	3.42	0.04	74.29	14.18	-2.05
349	R43B30E43	95.66	6.35	0.02	85.74	8.96	5.67
350	R43B60E43	96.94	5.36	0	89.42	8.8	-1.02
351	R43B90E43	96.95	5.35	0	89.84	8.68	-1.28
352	R44B30E41	96.45	4.18	-0.1	73.64	15.34	2.44
353	R44B60E41	96.88	3.93	-0.47	74.43	15.3	0.74
354	R44B90E41	98.06	3.1	0	78.09	14.29	1.95
355	R44B30E42	97.21	5.46	0.36	83.24	10.39	1.21
356	R44B60E42	98.04	4.58	-0.04	79.99	11.29	-5.2
357	R44B90E42	98.27	4.3	-0.06	78.1	12.14	-3.84
358	R44B30E43	96.27	5.91	-0.9	87.9	8.31	6.18
359	R44B60E43	97.41	4.94	-0.1	83.69	10.43	-0.51
360	R44B90E43	97.62	4.74	0.64	71.36	15.41	-1.42
361	R51B30E51	93.66	5.54	0	84.96	11.91	0.87
362	R51B60E51	93.66	5.54	0	84.96	11.91	0.87
363	R51B90E51	93.66	5.54	0	84.96	11.91	0.87
364	R51B30E52	96.56	6.03	0.01	87.01	9.01	3.2
365	R51B60E52	96.72	5.89	-0.07	85.45	9.58	3.35
366	R51B90E52	96.73	5.88	0	85.08	9.7	3.43
367	R51B30E53	95.06	6.77	-0.36	84.23	9.7	7.32
368	R51B60E53	95.24	6.65	0	83.59	9.93	6.96
369	R51B90E53	95.24	6.65	0	82.07	10.42	6.24
370	R52B30E51	96.12	4.36	-0.01	70.42	17.19	3.49
371	R52B60E51	96.12	4.36	0	68.47	18.09	4.61
372	R52B90E51	96.12	4.36	0	68.05	18.28	4.81
373	R52B30E52	98.1	4.51	0.1	28.06	41.67	-21.06
374	R52B60E52	98.15	4.44	0	51.68	22.82	-8.92
375	R52B90E52	98.33	4.22	-0.03	52.39	23.93	-11.57
376	R52B30E53	95.16	6.71	0.01	84.98	9.69	8.96
377	R52B60E53	95.56	6.43	0	83.17	10.27	9.39
378	R52B90E53	95.56	6.43	0	83.11	10.3	9.39

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
379	R53B30E51	99.51	1.57	-0.18	74.37	17.17	-12.89
380	R53B60E51	99.99	0.17	-0.03	56.95	22.46	-8.57
381	R53B90E51	100	0.07	0	55.55	22.7	-9.89
382	R53B30E52	97.46	5.2	0.24	80.77	11.25	9.21
383	R53B60E52	97.53	5.12	0.06	68.82	14.91	13.58
384	R53B90E52	97.58	5.07	0	70.29	14.33	11.03
385	R53B30E53	95.5	6.47	0.05	75.41	12.57	14.4
386	R53B60E53	95.59	6.4	0.02	76.09	12.26	14.04
387	R53B90E53	95.6	6.4	0	76.2	12.22	14.05
388	R54B30E51	92.98	6.02	-0.2	83.65	12.79	2.82
389	R54B60E51	99.39	1.74	-0.17	74.58	15.53	11.26
390	R54B90E51	100	0	0	66.2	18.37	20.48
391	R54B30E52	98.43	4.1	-0.85	81.55	10.7	1.45
392	R54B60E52	99.06	3.17	0.04	73.16	13.35	0.98
393	R54B90E52	99.1	3.1	-0.02	75.4	12.72	1.32
394	R54B30E53	96.72	5.55	0.03	79.32	11.24	16.7
395	R54B60E53	97.69	4.66	0.04	74.84	11.94	14.32
396	R54B90E53	97.94	4.4	-0.21	72.79	12.85	16.87
397	R61B30E61	96.46	4.17	0	80.38	13.52	2.14
398	R61B60E61	96.51	4.14	0	79.85	13.71	2.4
399	R61B90E61	96.51	4.14	0	79.84	13.71	2.41
400	R61B30E62	97.06	5.59	-0.02	84.67	10.1	3.7
401	R61B60E62	97.07	5.57	-0.2	84.75	10.05	3.65
402	R61B90E62	97.08	5.56	0	83.79	10.26	2.56
403	R61B30E63	95.5	6.47	-0.25	83.85	10.14	6.31
404	R61B60E63	95.79	6.26	-0.21	84.74	9.78	7.02
405	R61B90E63	95.86	6.21	-0.08	84.1	9.96	6.51
406	R62B30E61	96.44	4.18	-0.07	80.6	13.43	1.8
407	R62B60E61	96.51	4.14	0	79.85	13.71	2.42
408	R62B90E61	96.51	4.14	0	79.84	13.71	2.41
409	R62B30E62	96.8	5.82	-0.28	86.67	9.13	4.16
410	R62B60E62	97.01	5.63	-0.08	86.56	9.17	3.71
411	R62B90E62	97.09	5.55	0	86.44	9.24	3.99
412	R62B30E63	95.43	6.52	-0.02	79.45	17.51	-0.89
413	R62B60E63	96.14	6.01	0	79.18	15.8	-1.48
414	R62B90E63	96.14	6.01	0	79.2	15.78	-1.44
415	R63B30E61	99.27	1.91	-0.17	74.77	15.17	-1.65
416	R63B60E61	99.82	0.96	0.32	64.82	18.19	1.08
417	R63B90E61	100	0	0	57.55	19.68	-1.69
418	R63B30E62	97.92	4.7	-0.23	78.72	11.35	3.11
419	R63B60E62	98.14	4.45	-0.02	77.24	11.98	4.65
420	R63B90E62	98.2	4.38	-0.07	76.21	12.42	6.36
421	R63B30E63	95.96	6.14	-0.48	84.08	11.72	2.58
422	R63B60E63	98.36	3.93	-0.17	59.08	20.8	-10.76
423	R63B90E63	98.57	3.67	0.08	61.35	20.58	-10.41
424	R64B30E61	97.16	3.74	0.19	82.34	12.91	-4.05
425	R64B60E61	99.78	1.04	-0.19	76.07	15.5	-3.96
426	R64B90E61	99.99	0.27	0	75.69	15.58	-1.53
427	R64B30E62	98.88	3.46	-0.31	78.72	11.66	-0.46
428	R64B60E62	99.61	2.05	0.03	70.58	14.81	-5.96
429	R64B90E62	99.82	1.4	0	62.05	18.58	-12.34
430	R64B30E63	96.97	5.35	0.75	84.41	10.62	9.03
431	R64B60E63	98.86	3.28	-0.16	78.27	13.84	7.65
432	R64B90E63	99.12	2.89	0.02	77.34	13.96	9.28

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
433	R11C30E11	79.26	9.64	0.02	80.83	13.5	3.98
434	R11C60E11	79.4	9.61	0.01	82.52	12.87	3.42
435	R11C90E11	79.43	9.6	0.01	82.98	12.69	3.22
436	R11C30E12	89.54	10.34	0	73.88	12.36	2.65
437	R11C60E12	89.54	10.34	0	73.88	12.36	2.63
438	R11C90E12	89.54	10.34	0	73.87	12.36	2.62
439	R11C30E13	88.15	10.29	-0.08	71.67	12.75	1.02
440	R11C60E13	89.7	9.63	-0.04	65.19	14.09	2.48
441	R11C90E13	89.97	9.51	0	61.74	15.33	4.22
442	R12C30E11	87.02	7.79	0.63	72.87	15.49	3.74
443	R12C60E11	88.91	7.23	0.06	68.84	16.74	8.57
444	R12C90E11	89.07	7.19	0	68.76	16.84	7.65
445	R12C30E12	90.81	9.72	0.17	71.71	15.25	-1.49
446	R12C60E12	91.31	9.47	-0.01	71.63	15.55	-2.85
447	R12C90E12	91.44	9.4	-0.01	71.64	15.59	-2.41
448	R12C30E13	88.66	10.09	-0.58	71.19	12.59	-0.13
449	R12C60E13	89.88	9.55	0.07	62.16	14.63	1.53
450	R12C90E13	90.03	9.48	0.1	61.89	14.44	2.35
451	R13C30E11	87.54	7.64	0.78	71.89	15.84	9.69
452	R13C60E11	88.48	7.37	-0.16	67.38	16.74	7.71
453	R13C90E11	93.33	5.68	0	67.91	17.02	15.53
454	R13C30E12	91.59	9.32	-0.01	67.3	17.04	-1.98
455	R13C60E12	93.21	8.42	-0.24	67.92	16.57	-1.56
456	R13C90E12	93.94	7.96	0	66.57	17.18	-0.44
457	R13C30E13	90.05	9.47	0.07	62.54	14.26	2.77
458	R13C60E13	90.28	9.37	0	61.4	14.62	3.55
459	R13C90E13	90.29	9.37	0	61.48	14.61	3.5
460	R14C30E11	81.77	9.11	-0.24	78.65	14.07	4.8
461	R14C60E11	84.58	8.44	-1.03	77.16	14.32	2.26
462	R14C90E11	85.98	8.1	-2.61	75.21	14.86	0.31
463	R14C30E12	90.28	9.98	-0.07	74.07	13.1	0.43
464	R14C60E12	91.12	9.56	-0.08	73.53	13.63	-2.21
465	R14C90E12	91.39	9.42	-0.1	72.92	14	-2.98
466	R14C30E13	89.27	9.83	-1	70.8	13.18	-1.72
467	R14C60E13	89.89	9.55	-0.03	65.97	13.81	1.85
468	R14C90E13	90.25	9.38	0	63.72	14.28	3.32
469	R21C30E21	85.37	8.25	-1.12	87.25	11.51	3.01
470	R21C60E21	90.37	6.78	0	75.07	15.26	1.83
471	R21C90E21	90.4	6.77	0	72.58	16.14	1.43
472	R21C30E22	95.07	7.2	-0.04	83.15	10.07	0.58
473	R21C60E22	95.07	7.2	-0.01	83.02	10.12	0.72
474	R21C90E22	95.07	7.2	0	82.98	10.13	0.78
475	R21C30E23	94.14	7.36	0.09	81.77	9.93	1.61
476	R21C60E23	94.14	7.36	0	81.76	9.94	1.51
477	R21C90E23	94.14	7.36	0	81.76	9.94	1.51
478	R22C30E21	88.72	7.3	-0.28	84.08	12.49	5
479	R22C60E21	92.99	5.82	0.04	73.23	15.53	8.54
480	R22C90E21	93.54	5.6	0.02	71.12	16.03	5.54
481	R22C30E22	94.22	7.79	1.85	82.23	10.84	5.12
482	R22C60E22	94.52	7.58	0.01	81.66	11.12	4.06
483	R22C90E22	94.53	7.58	0	81.49	11.17	4.15
484	R22C30E23	93.9	7.5	0.34	85.35	8.78	3.96
485	R22C60E23	94.49	7.14	0.02	85.14	8.79	1.66
486	R22C90E23	94.68	7.02	0	84.05	9.12	3.02

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
487	R23C30E21	85.58	8.19	-0.23	89.75	10.86	3.89
488	R23C60E21	85.73	8.15	-0.12	90.03	10.74	4.08
489	R23C90E21	85.87	8.11	0	90.35	10.43	3.67
490	R23C30E22	95.02	7.23	0.04	84.43	9.65	0.49
491	R23C60E22	95.4	6.96	0.07	81.24	10.64	0.24
492	R23C90E22	95.8	6.66	-0.04	80.66	10.96	1.46
493	R23C30E23	93.35	7.83	0.2	84.24	9.1	3.72
494	R23C60E23	94.06	7.4	0	84.96	8.9	3.09
495	R23C90E23	94.19	7.33	0.06	85.21	8.76	2.59
496	R24C30E21	88.37	7.42	-0.16	81.92	13.17	4.87
497	R24C60E21	94.27	5.28	-0.46	71.33	15.86	5.96
498	R24C90E21	95.45	4.72	0.18	69.11	16.41	7.59
499	R24C30E22	94.25	7.78	-2.22	81.42	11.06	-0.98
500	R24C60E22	94.95	7.29	-0.24	70.06	26.92	-16.47
501	R24C90E22	95.04	7.22	-0.05	69.02	31.78	-20.53
502	R24C30E23	94.07	7.44	0	80.5	10.22	0.96
503	R24C60E23	95.1	6.74	0.28	75.03	13.34	-1.13
504	R24C90E23	95.47	6.49	-0.11	76.09	12.27	-0.35
505	R31C30E31	95	4.95	0.01	79.65	13.71	-0.45
506	R31C60E31	95	4.94	0	79.67	13.7	-0.42
507	R31C90E31	95.3	4.8	-0.17	80.66	13.32	-0.89
508	R31C30E32	96.83	5.8	0.03	82.85	11.5	4.19
509	R31C60E32	96.83	5.8	0	82.86	11.5	4.13
510	R31C90E32	96.83	5.8	0	82.87	11.49	4.13
511	R31C30E33	94.76	6.97	0	84.33	9.71	10.43
512	R31C60E33	94.84	6.92	-0.01	84.26	9.7	10.48
513	R31C90E33	94.87	6.9	0.02	84.4	9.66	10.52
514	R32C30E31	95.62	4.64	-0.33	80.16	13.48	-0.48
515	R32C60E31	95.85	4.51	0	80.85	13.25	-0.47
516	R32C90E31	95.85	4.51	0	80.85	13.25	-0.46
517	R32C30E32	96.77	5.86	0.49	82.52	10.33	6.26
518	R32C60E32	96.95	5.69	-0.06	81.17	10.63	6.63
519	R32C90E32	97.02	5.63	0	80.58	10.78	6.79
520	R32C30E33	95.36	6.57	0.08	83.8	11.61	12.95
521	R32C60E33	96.8	5.48	0.07	78.22	12.51	14.67
522	R32C90E33	96.82	5.46	0	65.13	20.43	17.58
523	R33C30E31	94.95	4.97	-0.02	73.6	21.11	-10.97
524	R33C60E31	94.98	4.95	0	80.2	18.6	-10.92
525	R33C90E31	94.99	4.95	0	85.58	11.87	-0.32
526	R33C30E32	97.45	5.21	0.05	82.38	10.64	2.63
527	R33C60E32	97.82	4.83	-0.16	82.39	10.77	2.78
528	R33C90E32	97.85	4.79	-0.01	81.69	11.24	2.56
529	R33C30E33	96.17	5.98	-0.04	48.47	24.67	-6.94
530	R33C60E33	96.72	5.55	0.07	51.73	20.86	-3.45
531	R33C90E33	97.09	5.23	0.03	51.26	20.6	0.97
532	R34C30E31	97.74	3.35	-0.6	79.86	13.79	2.85
533	R34C60E31	99.12	2.1	0.16	70.36	17.83	5.47
534	R34C90E31	99.84	0.9	0.08	50.67	26.09	15.19
535	R34C30E32	96.35	6.22	-0.49	84.59	10.03	2.35
536	R34C60E32	97.3	5.36	-0.13	81.74	11.07	1.86
537	R34C90E32	97.8	4.91	3.12	81.3	11.83	4.57
538	R34C30E33	95.99	6.13	-1.86	87.34	8.32	8.77
539	R34C60E33	97.71	4.65	1.18	86.35	8.97	9.73
540	R34C90E33	98.24	4.07	0.01	78.92	11.13	4.92

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
541	R41C30E41	96.12	4.36	0	81.3	13.11	-0.27
542	R41C60E41	96.12	4.36	0	81.31	13.11	-0.33
543	R41C90E41	96.12	4.36	0	81.31	13.11	-0.33
544	R41C30E42	96.87	5.78	-0.2	84.59	10.64	6.45
545	R41C60E42	96.96	5.68	0	84.98	10.51	6.19
546	R41C90E42	96.96	5.68	0	84.96	10.52	6.17
547	R41C30E43	94.14	7.36	-0.15	84.01	9.81	6.89
548	R41C60E43	95.62	6.4	0.24	89.13	7.78	2.96
549	R41C90E43	96.14	6.01	0	82.18	10.52	1.69
550	R42C30E41	96.25	4.29	-0.01	85.9	11.53	-0.68
551	R42C60E41	96.25	4.29	0	86.11	11.45	-0.82
552	R42C90E41	96.25	4.29	0	86.04	11.48	-0.97
553	R42C30E42	95.91	6.6	-1.96	86.22	9.16	2.2
554	R42C60E42	96.86	5.77	-0.23	71.12	14.91	-4.53
555	R42C90E42	97.42	5.24	0.02	66.2	15.64	-4.43
556	R42C30E43	95.59	6.41	0.46	89.18	7.84	3.35
557	R42C60E43	96	6.11	-0.02	87.16	8.56	2.02
558	R42C90E43	96.36	5.84	0	80.33	11.2	1.14
559	R43C30E41	96.44	4.21	1.62	78.34	14.08	4.21
560	R43C60E41	98.54	2.7	-0.2	69.53	16.5	7.57
561	R43C90E41	99.62	1.38	-0.02	58.73	20.06	12.03
562	R43C30E42	97.49	5.17	-0.16	75.98	13.4	-2.79
563	R43C60E42	97.62	5.03	0	73.57	13.88	-2.42
564	R43C90E42	98.12	4.48	0.09	73.91	13.55	-2.16
565	R43C30E43	96.04	6.08	-0.1	87.09	8.33	3.01
566	R43C60E43	97.3	5.04	-0.02	88.46	7.98	7.95
567	R43C90E43	97.3	5.04	0	88.49	7.97	8.01
568	R44C30E41	97.18	3.73	-0.37	80.23	13.5	3.87
569	R44C60E41	99.95	0.51	0.02	71.48	17.48	10.96
570	R44C90E41	99.99	0.16	0	69.8	18.52	9.51
571	R44C30E42	98.2	4.38	0.08	76.5	11.79	4.06
572	R44C60E42	98.45	4.07	0	72.53	12.69	4.78
573	R44C90E42	98.47	4.05	0	79.44	11.18	9.38
574	R44C30E43	97.87	4.48	-0.4	86.88	8.99	0.56
575	R44C60E43	98.77	3.41	0.03	87.77	8.79	2.04
576	R44C90E43	98.9	3.22	-0.04	88	8.65	1.3
577	R51C30E51	93.66	5.54	0	84.96	11.91	0.87
578	R51C60E51	93.66	5.54	0	84.96	11.91	0.87
579	R51C90E51	93.66	5.54	0	84.96	11.91	0.87
580	R51C30E52	96.12	6.4	0	87.61	8.79	5.91
581	R51C60E52	96.12	6.4	0	87.61	8.79	5.91
582	R51C90E52	96.12	6.4	0	87.61	8.79	5.91
583	R51C30E53	94.59	7.08	0	85.69	9.36	8.89
584	R51C60E53	94.59	7.08	0	85.69	9.36	8.89
585	R51C90E53	94.59	7.08	0	85.69	9.36	8.89
586	R52C30E51	98.29	2.93	-0.32	77.94	14.24	1.68
587	R52C60E51	98.51	2.72	-0.03	77.82	14.17	0.72
588	R52C90E51	98.52	2.71	0	77.64	14.23	1.17
589	R52C30E52	97.72	4.93	-0.06	84.68	9.92	0.39
590	R52C60E52	97.94	4.69	-0.21	83.6	10.18	0.23
591	R52C90E52	98.82	3.56	0	66.51	18.34	-6.06
592	R52C30E53	94.72	6.99	0	85.68	9.43	9.52
593	R52C60E53	94.73	6.99	0	85.7	9.42	9.51
594	R52C90E53	94.73	6.99	0	85.7	9.42	9.52

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
595	R53C30E51	98.98	2.25	-0.12	70.06	16.42	-4.07
596	R53C60E51	99.36	1.78	0.12	64.67	18.49	-2.61
597	R53C90E51	99.83	0.93	0	54.5	23.72	-9.73
598	R53C30E52	98.6	3.89	-1.1	81.99	11.19	-0.85
599	R53C60E52	99.1	3.11	-0.02	81.78	11.68	1.95
600	R53C90E52	99.18	2.96	-0.05	80.37	12.55	0.35
601	R53C30E53	97.7	4.65	-0.05	76.3	11.96	15.42
602	R53C60E53	98.08	4.31	2.71	82.75	10.45	14.32
603	R53C90E53	98.24	4.07	0	82.39	10.44	9.63
604	R54C30E51	97.59	3.45	-0.24	84.78	12.14	-1.98
605	R54C60E51	98.41	2.81	-0.08	82.46	15.76	-4.59
606	R54C90E51	98.69	2.56	0.91	78.17	16.57	-13.79
607	R54C30E52	99.18	2.97	-0.03	77.33	11.8	7.65
608	R54C60E52	99.29	2.76	0	79.18	11.45	4.39
609	R54C90E52	99.38	2.58	0	80.35	10.98	2.83
610	R54C30E53	97.42	4.93	0.22	84.17	10.16	9.47
611	R54C60E53	97.99	4.36	0.01	82.07	10.64	11.64
612	R54C90E53	98.03	4.31	0.02	81.29	10.81	11.95
613	R61C30E61	95.89	4.49	-0.04	86.53	12.35	-10.66
614	R61C60E61	96.51	4.14	-0.09	86.8	11.32	-5.09
615	R61C90E61	97.47	3.54	0	87.74	10.87	-3.09
616	R61C30E62	97.07	5.57	0	82.82	10.46	7.94
617	R61C60E62	97.2	5.45	0	85.87	9.35	5.86
618	R61C90E62	97.2	5.44	0	85.84	9.35	5.74
619	R61C30E63	94.78	6.96	0	85.88	9.39	9.38
620	R61C60E63	94.83	6.92	0	80.57	10.99	5.49
621	R61C90E63	94.83	6.92	0	77.35	12.07	4.37
622	R62C30E61	94.46	5.19	-0.1	86.89	11.2	0.63
623	R62C60E61	96.6	4.09	0	86.02	11.62	-5.05
624	R62C90E61	97.9	3.23	-0.01	74.73	17.77	-17.27
625	R62C30E62	97.04	5.6	-0.1	85.76	9.53	6.19
626	R62C60E62	97.15	5.5	-0.23	85.71	9.53	5.12
627	R62C90E62	97.83	4.8	0	75.58	13.19	-2.39
628	R62C30E63	94.78	6.96	0	85.88	9.39	9.38
629	R62C60E63	94.78	6.96	0	85.88	9.39	9.38
630	R62C90E63	94.78	6.96	0	85.88	9.39	9.38
631	R63C30E61	96.56	4.11	0	81.3	13.26	5.06
632	R63C60E61	96.58	4.1	0	81.55	13.18	5.11
633	R63C90E61	96.58	4.1	0	81.59	13.17	5.28
634	R63C30E62	97.58	5.08	-1.17	85.55	9.49	3.16
635	R63C60E62	99.11	3.08	-0.02	79.48	12.71	2.8
636	R63C90E62	99.25	2.83	-0.03	70.7	19.31	-7.06
637	R63C30E63	96.11	6.03	-0.15	87.4	9.23	7.93
638	R63C60E63	98.17	4.15	-0.09	77.81	18.36	-4.98
639	R63C90E63	98.43	3.85	-0.08	77.2	19.33	-6.84
640	R64C30E61	100	0	0	80.34	13.8	-3.35
641	R64C60E61	100	0	0	80.34	13.8	-3.35
642	R64C90E61	100	0	0	80.34	13.8	-3.35
643	R64C30E62	98.21	4.37	-0.07	82.59	10.66	0.92
644	R64C60E62	99.48	2.36	0	60.39	22.21	-11.7
645	R64C90E62	99.58	2.13	0	55.22	24.87	-12.51
646	R64C30E63	97.15	5.17	0	84.89	10.02	10.39
647	R64C60E63	97.16	5.17	0	84.85	10.04	10.43
648	R64C90E63	97.16	5.16	0	84.84	10.07	10.36

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
649	R11D30E11	79.34	9.62	0.07	81.73	13.18	3.78
650	R11D60E11	79.41	9.61	0.04	82.75	12.78	3.35
651	R11D90E11	79.43	9.6	0	82.94	12.7	3.24
652	R11D30E12	89.07	10.55	0.15	74.98	12.07	3.87
653	R11D60E12	89.44	10.38	-0.01	74.71	12.07	3.24
654	R11D90E12	89.58	10.32	0	73.67	12.43	3.22
655	R11D30E13	87.11	10.7	0.02	68.75	13.17	2.2
656	R11D60E13	87.14	10.69	0	68.97	13.06	2.25
657	R11D90E13	87.14	10.69	0	69.05	13.01	2.27
658	R12D30E11	82.65	8.9	-0.07	75.86	14.68	3.36
659	R12D60E11	85.24	8.27	-0.15	76	14.72	-0.05
660	R12D90E11	85.3	8.25	-0.22	75.87	14.82	-0.67
661	R12D30E12	90.8	9.73	-0.2	72.52	15.02	-2.37
662	R12D60E12	91.96	9.12	-0.01	68.97	16.32	-3.89
663	R12D90E12	91.97	9.12	-0.02	69	16.25	-3.8
664	R12D30E13	89.84	9.57	0.01	64.84	13.68	1.41
665	R12D60E13	91.34	8.87	-0.02	60.62	14.57	3.04
666	R12D90E13	91.46	8.81	-0.01	58.27	15.15	2.62
667	R13D30E11	83.45	8.71	0.03	77.3	14.33	5.03
668	R13D60E11	83.54	8.69	0.13	77.54	14.27	4.45
669	R13D90E11	83.56	8.68	0	77.17	14.36	4.29
670	R13D30E12	90.78	9.74	0.02	71.44	14.41	-1.66
671	R13D60E12	91.08	9.58	-0.83	70.79	15.5	-3.37
672	R13D90E12	92.67	8.72	-0.09	69.36	18.09	-0.9
673	R13D30E13	89.56	9.72	0.95	68.42	13.08	0.55
674	R13D60E13	89.96	9.51	0	66.82	13.56	1.35
675	R13D90E13	90.01	9.49	0.01	65.54	13.8	1.77
676	R14D30E11	80.84	9.31	0.25	76.62	14.79	6.7
677	R14D60E11	84.43	8.48	0.12	74.52	15.11	5.32
678	R14D90E11	86.34	7.98	0.26	73.03	15.41	5.04
679	R14D30E12	89.99	10.14	-0.29	73.2	13.35	0.5
680	R14D60E12	91.95	9.12	0.2	71.71	15.04	-3.77
681	R14D90E12	93.41	8.29	0.17	70.58	13.46	3.99
682	R14D30E13	89.42	9.79	-3.04	69.1	13.19	-3.37
683	R14D60E13	90.16	9.42	0.04	66.68	13.86	3.36
684	R14D90E13	92.19	8.44	0.03	57.91	15.94	4.07
685	R21D30E21	83.69	8.66	0.04	88.26	10.99	1.25
686	R21D60E21	84.12	8.56	-0.28	88.58	10.74	1.6
687	R21D90E21	86.82	7.85	-0.06	80.46	13.49	1.95
688	R21D30E22	92.74	8.68	0	83.65	9.87	5.5
689	R21D60E22	92.74	8.68	0	83.65	9.87	5.51
690	R21D90E22	92.74	8.68	0	83.65	9.87	5.51
691	R21D30E23	91.63	8.74	0	78.41	10.99	6.2
692	R21D60E23	91.63	8.74	0	78.33	11.02	6.2
693	R21D90E23	91.64	8.73	0	78.25	11.04	6.21
694	R22D30E21	88.73	7.31	0.17	80.2	13.46	-2.33
695	R22D60E21	89.33	7.12	0.03	80.32	13.47	-3.38
696	R22D90E21	89.64	7.02	-0.33	79.61	13.71	-4.55
697	R22D30E22	93.88	8	0	81.46	11.14	1.66
698	R22D60E22	94.42	7.65	0.01	81.37	11.17	3.82
699	R22D90E22	94.45	7.63	0	80.94	11.31	4.02
700	R22D30E23	93.21	7.9	0	83.99	9.15	3.62
701	R22D60E23	93.21	7.9	0	84	9.15	3.62
702	R22D90E23	93.21	7.9	0	84	9.15	3.62

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
703	R23D30E21	86.37	7.98	0.03	84.53	12.24	3.08
704	R23D60E21	86.6	7.92	0	84.79	11.94	1.17
705	R23D90E21	86.6	7.92	0	84.72	11.97	0.93
706	R23D30E22	94.17	7.81	-0.02	76.66	16.65	-4.77
707	R23D60E22	94.22	7.78	0	74.65	16.73	-3.11
708	R23D90E22	96.08	6.44	-0.36	76.75	17.05	-9.19
709	R23D30E23	92.71	8.18	-0.72	80.18	10.65	2.72
710	R23D60E23	94.71	7.02	-1.65	79.99	10.01	0.69
711	R23D90E23	95.82	6.25	0.03	72.4	11.78	5
712	R24D30E21	94.87	5.03	1.81	70.45	16.26	2.86
713	R24D60E21	96.29	4.27	-0.05	59.43	21.37	-10.95
714	R24D90E21	96.78	3.98	-0.03	50.81	23.96	-13.24
715	R24D30E22	95.24	7.1	-1.47	77.54	13.06	-1.63
716	R24D60E22	96.94	5.7	-0.02	80.47	11.54	1.81
717	R24D90E22	97.67	4.98	0	76.21	21.52	-13.74
718	R24D30E23	95.74	6.3	-0.01	77.57	10.61	8.36
719	R24D60E23	96.18	5.97	0.63	78.69	10.3	5.94
720	R24D90E23	96.26	5.91	0	77.45	10.57	5.09
721	R31D30E31	95.66	4.61	0	80.44	13.41	0.4
722	R31D60E31	95.85	4.51	0	80.85	13.25	-0.46
723	R31D90E31	95.85	4.51	0	80.85	13.25	-0.46
724	R31D30E32	95.86	6.61	-0.02	86.77	9.03	5.22
725	R31D60E32	95.88	6.6	0	86.99	8.96	4.8
726	R31D90E32	95.88	6.6	0	86.99	8.96	4.8
727	R31D30E33	94.3	7.27	1.04	86.8	8.58	9.13
728	R31D60E33	94.59	7.08	0	87.36	8.27	7.08
729	R31D90E33	94.6	7.08	0	87.28	8.31	7.18
730	R32D30E31	95.79	4.55	-0.16	80.64	13.32	-0.66
731	R32D60E31	95.85	4.51	0	80.85	13.25	-0.46
732	R32D90E31	95.85	4.51	0	80.85	13.25	-0.46
733	R32D30E32	96.12	6.41	0.09	83.94	9.97	5.55
734	R32D60E32	96.17	6.37	0.29	84.45	9.85	5.83
735	R32D90E32	96.17	6.36	0.01	84.48	9.82	5.55
736	R32D30E33	94.14	7.36	0	72.63	23.52	-7.99
737	R32D60E33	94.53	7.12	-0.01	72.96	23.07	-7.58
738	R32D90E33	94.6	7.07	0	81.21	11.99	4.92
739	R33D30E31	95.14	4.88	0.09	79.59	13.72	-0.17
740	R33D60E31	96.31	4.26	0.06	66.76	17.19	-1.47
741	R33D90E31	96.96	3.87	0	76.23	14.98	-4.11
742	R33D30E32	96.18	6.36	0.14	84.81	9.89	3.63
743	R33D60E32	97.23	5.43	0	80.63	11.73	1.52
744	R33D90E32	97.23	5.42	0	80.87	11.63	1.66
745	R33D30E33	94.43	7.18	0.02	86.38	8.87	7.6
746	R33D60E33	94.49	7.14	0	86.37	8.9	7.86
747	R33D90E33	94.49	7.14	0	86.37	8.9	7.87
748	R34D30E31	94.85	5.01	-0.1	81.75	12.98	0.91
749	R34D60E31	95.07	4.91	-0.03	81.19	13.18	0.53
750	R34D90E31	96.27	4.3	-1.35	82.19	12.84	1.26
751	R34D30E32	97.45	5.22	0.57	80.86	10.97	5.56
752	R34D60E32	97.74	4.91	-0.1	78.92	11.46	5.09
753	R34D90E32	98.15	4.44	0	78.29	11.68	3.89
754	R34D30E33	95.71	6.32	-0.14	81.29	10.26	6.9
755	R34D60E33	96.28	5.9	0.02	76.68	11.71	5.98
756	R34D90E33	96.83	5.45	0.01	74.83	12.14	4.11

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
757	R41D30E41	93.39	5.66	0	84.44	12.08	0.99
758	R41D60E41	93.39	5.66	0	84.44	12.08	0.99
759	R41D90E41	93.39	5.66	0	84.44	12.08	0.99
760	R41D30E42	95.95	6.54	-0.05	85.8	9.51	3.41
761	R41D60E42	96.11	6.41	-0.03	81.79	11.15	1.86
762	R41D90E42	96.12	6.41	0	81.54	11.21	2.05
763	R41D30E43	94	7.44	0.02	85.1	9.12	6.96
764	R41D60E43	94.97	6.83	-0.04	88.92	7.75	4.88
765	R41D90E43	94.98	6.83	0	88.85	7.78	4.93
766	R42D30E41	95.47	4.71	0.2	80.77	13.3	0.37
767	R42D60E41	96.55	4.12	-0.14	82.02	12.89	-0.18
768	R42D90E41	96.82	3.96	0	81.92	12.91	-0.13
769	R42D30E42	96.72	5.9	0	87.25	8.9	1.92
770	R42D60E42	96.72	5.9	0	87.22	8.91	2.03
771	R42D90E42	96.72	5.9	0	87.21	8.91	2.07
772	R42D30E43	94.9	6.88	-0.02	88.77	7.82	4.43
773	R42D60E43	94.91	6.87	0	89	7.72	4.73
774	R42D90E43	94.91	6.87	0	89	7.73	4.73
775	R43D30E41	96.95	3.88	0.09	73.78	15.48	3.37
776	R43D60E41	97.36	3.61	0.02	70.48	16.37	2.82
777	R43D90E41	97.57	3.47	0.02	69.14	16.69	2.6
778	R43D30E42	97.13	5.52	0.5	75.68	13.84	0.8
779	R43D60E42	97.72	4.93	0	74.68	14.5	0.99
780	R43D90E42	97.77	4.88	0	72.83	15.76	0.72
781	R43D30E43	95.4	6.54	0.21	81.15	13.21	3.2
782	R43D60E43	97.08	5.29	2.9	73.46	13.33	6.93
783	R43D90E43	97.48	4.86	0	72.79	13.77	2.78
784	R44D30E41	95.79	4.54	0.18	82.92	12.62	2.97
785	R44D60E41	97.7	3.38	-0.1	83.26	12.63	6.98
786	R44D90E41	98.92	2.32	0	71.83	19.45	8.1
787	R44D30E42	97.64	5.02	-0.12	78.59	11.59	6
788	R44D60E42	98.21	4.37	-0.1	70.5	14.21	6.12
789	R44D90E42	98.37	4.18	0	60.32	17.58	6.95
790	R44D30E43	96.73	5.54	-1.02	84.34	10.69	1.74
791	R44D60E43	97.76	4.59	0.56	80.73	11.86	3.98
792	R44D90E43	98.31	3.99	0	73.67	13.29	-0.79
793	R51D30E51	94.31	5.26	0	83.96	12.26	1.43
794	R51D60E51	94.31	5.26	0	83.98	12.25	1.17
795	R51D90E51	94.44	5.2	0	83.7	12.36	2.05
796	R51D30E52	96.63	5.97	0	86.37	9.38	4.13
797	R51D60E52	96.63	5.97	0	86.37	9.38	4.13
798	R51D90E52	96.63	5.97	0	86.37	9.38	4.13
799	R51D30E53	94.87	6.9	0	86.13	9.29	8.74
800	R51D60E53	94.89	6.89	-0.02	86.48	9.13	8.41
801	R51D90E53	95.01	6.8	-0.01	86.72	8.94	7.23
802	R52D30E51	97.16	3.74	0.01	85.5	12.41	-6.09
803	R52D60E51	97.24	3.69	-0.01	86	16.48	-12.16
804	R52D90E51	97.24	3.69	0	85.08	20.15	-13.51
805	R52D30E52	97.78	4.86	0.02	76.13	14.49	2.58
806	R52D60E52	97.8	4.84	0	75.85	14.93	1.42
807	R52D90E52	97.8	4.84	0	75.64	15.02	1.28
808	R52D30E53	95.72	6.32	0.01	83.86	10.23	9.43
809	R52D60E53	95.86	6.21	-0.1	84	10.15	7.61
810	R52D90E53	96.19	5.96	0	81.06	11.52	5.04

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
811	R53D30E51	94.97	4.96	-0.02	83.52	12.41	1.25
812	R53D60E51	99.14	2.07	-0.05	77.7	14.97	-0.81
813	R53D90E51	99.97	0.4	-0.02	71.49	19.87	-12.77
814	R53D30E52	98.12	4.47	-0.02	79.19	14.31	-3.18
815	R53D60E52	98.23	4.35	0	75.84	16.3	-5.28
816	R53D90E52	98.28	4.28	0	78.33	14.66	-2.77
817	R53D30E53	96.48	5.74	-0.08	67.87	14.6	13.51
818	R53D60E53	96.69	5.56	0	63.17	16.26	14.95
819	R53D90E53	96.73	5.53	0	62.05	16.57	15.24
820	R54D30E51	96.45	4.18	0	81.88	12.98	3.27
821	R54D60E51	97.31	3.64	0.38	77.96	14.35	2.16
822	R54D90E51	97.96	3.17	0	73.37	16.21	2.9
823	R54D30E52	98.55	3.94	-0.82	83.49	10.46	0.1
824	R54D60E52	98.88	3.46	-0.02	74.5	16.26	-8.92
825	R54D90E52	98.93	3.39	-0.11	72	17.62	-10.22
826	R54D30E53	97.03	5.28	-0.33	83.76	10.45	5.91
827	R54D60E53	97.85	4.5	-0.33	81.49	11.4	9.14
828	R54D90E53	98.1	4.23	-0.03	76.08	13.46	12.4
829	R61D30E61	94.41	5.21	0	85.91	11.61	1.8
830	R61D60E61	94.41	5.21	0	85.91	11.61	1.8
831	R61D90E61	94.41	5.21	0	85.91	11.61	1.8
832	R61D30E62	96.49	6.09	-0.04	86.66	9.13	6.52
833	R61D60E62	96.49	6.09	0	86.65	9.14	6.57
834	R61D90E62	96.49	6.09	0	86.65	9.14	6.57
835	R61D30E63	94.78	6.96	0	85.88	9.39	9.38
836	R61D60E63	94.78	6.96	0	85.88	9.39	9.38
837	R61D90E63	94.78	6.96	0	85.88	9.39	9.38
838	R62D30E61	94.92	4.98	0	85.33	11.82	2.12
839	R62D60E61	94.92	4.98	0	85.33	11.83	2.12
840	R62D90E61	95.21	4.84	-0.04	83.43	12.46	-0.05
841	R62D30E62	96.96	5.68	0.01	85.94	9.4	5
842	R62D60E62	97.05	5.6	0	87.45	8.88	4.54
843	R62D90E62	97.05	5.6	0	87.45	8.88	4.57
844	R62D30E63	94.87	6.9	-0.01	85.85	9.63	10.89
845	R62D60E63	95.17	6.7	0.03	84.31	10.21	10.85
846	R62D90E63	95.18	6.69	0	82.37	11.12	12.14
847	R63D30E61	98.24	2.96	0.43	84.05	12.25	2.73
848	R63D60E61	99.44	1.67	-0.04	74.06	15.39	7.68
849	R63D90E61	99.71	1.2	-0.03	75.32	15.74	4.62
850	R63D30E62	98.39	4.16	0.49	84.61	9.61	2.88
851	R63D60E62	98.54	3.95	0.04	57.86	19.3	-10.93
852	R63D90E62	99.06	3.17	-0.07	55.15	20.59	-7.79
853	R63D30E63	95.84	6.27	-2.58	84.81	11.84	2.39
854	R63D60E63	97.8	4.55	-0.05	70.81	27.38	-17.76
855	R63D90E63	97.91	4.43	0	71.32	27.2	-18.14
856	R64D30E61	97.94	3.2	0.32	76.64	14.55	1.14
857	R64D60E61	98.93	2.31	0	50.83	21.03	19.43
858	R64D90E61	98.93	2.31	0	44.78	22.63	23.34
859	R64D30E62	98.05	4.56	-0.38	84.8	9.79	1.85
860	R64D60E62	98.39	4.14	-0.29	81.96	10.69	0.61
861	R64D90E62	99.43	2.48	-0.06	77.59	12.06	-0.67
862	R64D30E63	95.31	6.61	0.01	84.45	9.99	10.57
863	R64D60E63	95.53	6.45	-0.14	82.47	10.79	12.7
864	R64D90E63	95.91	6.18	-0.04	85.25	9.44	3.71

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
865	R11E30E11	80.76	9.32	-0.19	81.62	13.19	5.28
866	R11E60E11	82.3	8.98	0.15	73.96	15.41	7.53
867	R11E90E11	82.91	8.84	-0.66	73.41	15.55	9.66
868	R11E30E12	90.26	9.99	0	69.3	15.68	-1.05
869	R11E60E12	90.26	9.99	0	69.3	15.68	-1.04
870	R11E90E12	90.26	9.99	0	69.3	15.68	-1.04
871	R11E30E13	87.13	10.7	0.28	68.88	13.09	2.5
872	R11E60E13	87.14	10.69	0	68.99	13.04	2.26
873	R11E90E13	87.14	10.69	0	69.06	13.01	2.28
874	R12E30E11	82.54	8.93	-1.33	75.49	14.87	5.17
875	R12E60E11	84.28	8.52	-1.38	77.21	14.38	3.86
876	R12E90E11	86.52	7.93	0.07	72.75	15.47	4.55
877	R12E30E12	90.31	9.97	0.01	69.3	15.64	-0.58
878	R12E60E12	90.38	9.93	0	69.15	15.7	-0.43
879	R12E90E12	90.39	9.93	0	69.15	15.71	-0.41
880	R12E30E13	88.01	10.35	-0.72	70.77	13.07	-0.01
881	R12E60E13	89.68	9.64	-0.1	65.46	14.09	2.07
882	R12E90E13	90.27	9.38	0.03	62.01	14.64	3.93
883	R13E30E11	89.29	7.13	-1.29	68.49	16.65	4.34
884	R13E60E11	91.84	6.25	-0.09	73.07	16.19	1.8
885	R13E90E11	91.96	6.21	0	73.31	16.4	2.1
886	R13E30E12	92.7	8.71	-0.03	67.45	16.89	-5.69
887	R13E60E12	92.78	8.66	-0.01	67.47	16.72	-5.2
888	R13E90E12	92.81	8.64	-0.01	67.57	16.64	-5.01
889	R13E30E13	89.44	9.75	-0.1	72	12.72	1.37
890	R13E60E13	90.31	9.36	0.06	69.58	13.15	1.49
891	R13E90E13	91.41	8.83	0	65.12	13.46	2.31
892	R14E30E11	91.14	6.51	-0.02	75.33	15.17	8.09
893	R14E60E11	93.04	5.8	0.07	70.82	17.49	5.35
894	R14E90E11	94	5.39	0.02	66.32	17.39	8.92
895	R14E30E12	91.51	9.36	-0.03	66.93	17.21	-2.67
896	R14E60E12	91.63	9.3	0.02	66.3	17.32	-2.19
897	R14E90E12	91.72	9.25	0	65.67	17.51	-2.42
898	R14E30E13	90.07	9.47	-1.17	64.14	13.93	1.88
899	R14E60E13	90.52	9.26	-0.69	61.18	14.88	4.43
900	R14E90E13	90.94	9.06	-0.01	59.69	14.9	6.11
901	R21E30E21	-4.71	15.83	0	-0.46	22.65	9.05
902	R21E60E21	-4.71	15.83	0	-0.46	22.65	9.05
903	R21E90E21	-4.71	15.83	0	-0.46	22.65	9.05
904	R21E30E22	92.65	8.74	0	83.54	9.88	5.16
905	R21E60E22	92.65	8.74	0	83.54	9.88	5.16
906	R21E90E22	92.65	8.74	0	83.54	9.88	5.16
907	R21E30E23	91.43	8.84	-0.04	78.68	10.81	6.17
908	R21E60E23	91.43	8.84	0	78.67	10.82	6.24
909	R21E90E23	91.43	8.84	0	78.67	10.82	6.24
910	R22E30E21	93.05	5.81	0.95	73.28	15.5	6.23
911	R22E60E21	94.29	5.27	-0.03	57.21	21.69	0.87
912	R22E90E21	94.33	5.25	0	57.82	26.07	-6.29
913	R22E30E22	94.5	7.6	0.01	83.35	10.05	-0.94
914	R22E60E22	95.22	7.09	0.04	80.66	11.32	-3.08
915	R22E90E22	95.23	7.09	0	80.66	11.32	-3.15
916	R22E30E23	93.9	7.51	0	74.63	13.56	-0.05
917	R22E60E23	94	7.44	0	74.08	13.01	-0.26
918	R22E90E23	94.05	7.42	-0.03	73.25	13.3	-0.83

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
919	R23E30E21	90.87	6.67	-0.97	75.23	14.89	4.67
920	R23E60E21	94.43	5.22	-1.04	71.27	15.89	5.12
921	R23E90E21	96.08	4.39	-0.09	74.19	16.2	-5.03
922	R23E30E22	94.73	7.44	-0.05	79.41	11.39	2.08
923	R23E60E22	95.07	7.2	-0.01	73.62	12.91	-0.04
924	R23E90E22	95.1	7.18	0	72.78	13.16	-0.45
925	R23E30E23	93.53	7.72	0	84.42	9.14	4.71
926	R23E60E23	93.7	7.62	0	84.45	9.1	3.33
927	R23E90E23	93.73	7.6	0	84.38	9.12	3.33
928	R24E30E21	87.92	7.54	-0.02	86.44	11.85	3.78
929	R24E60E21	94.22	5.3	-0.03	78.31	14.01	-0.38
930	R24E90E21	95.25	4.83	-0.12	76.82	14.42	-0.18
931	R24E30E22	95.18	7.12	-0.15	83.03	10.11	0.06
932	R24E60E22	95.99	6.51	-1.1	80.34	11.73	-2.6
933	R24E90E22	96.84	5.79	-0.01	80.19	12.74	-5.6
934	R24E30E23	94.75	6.98	-0.2	81.25	10.05	2.43
935	R24E60E23	95.52	6.45	0.01	79.33	10.41	5.41
936	R24E90E23	95.64	6.37	0	78.92	10.41	7.46
937	R31E30E31	94.99	4.95	0.03	79.71	13.68	-0.37
938	R31E60E31	95	4.94	0	79.67	13.7	-0.42
939	R31E90E31	95	4.94	0	79.67	13.7	-0.42
940	R31E30E32	95.63	6.79	0	86.61	9.06	5.18
941	R31E60E32	95.63	6.79	0	86.61	9.06	5.18
942	R31E90E32	95.63	6.79	0	86.61	9.06	5.18
943	R31E30E33	93.86	7.53	0	85.03	9.18	7.1
944	R31E60E33	93.86	7.53	0	85.03	9.18	7.1
945	R31E90E33	93.86	7.53	0	85.03	9.18	7.1
946	R32E30E31	95.83	4.53	-0.05	81.07	13.19	-0.53
947	R32E60E31	95.85	4.51	0	80.86	13.25	-0.46
948	R32E90E31	95.85	4.51	0	80.85	13.25	-0.46
949	R32E30E32	95.67	6.76	-0.04	86.7	9.06	5.44
950	R32E60E32	95.71	6.73	-0.03	86.73	9.05	4.75
951	R32E90E32	95.71	6.73	-0.01	86.68	9.06	4.64
952	R32E30E33	93.95	7.47	-0.4	85.13	9.14	6.85
953	R32E60E33	94.03	7.42	0.01	85.44	9.07	7.09
954	R32E90E33	94.04	7.42	0.01	85.5	9.04	7.09
955	R33E30E31	95.06	4.92	0.16	80.95	13.26	-0.52
956	R33E60E31	97.78	3.32	0.09	73.58	15.44	8
957	R33E90E31	98.1	3.07	0.03	73.53	15.42	6.59
958	R33E30E32	96.99	5.66	0	79.87	11.84	0.07
959	R33E60E32	97.02	5.63	0.01	79.43	11.98	-0.14
960	R33E90E32	97.03	5.62	0	79.18	12.06	-0.31
961	R33E30E33	94.25	7.29	-0.52	85.41	9.18	5.93
962	R33E60E33	95.15	6.71	-0.02	83.72	9.38	6.91
963	R33E90E33	95.37	6.56	-0.07	83.14	9.55	6.62
964	R34E30E31	94.34	5.25	0	83.76	12.31	-1.06
965	R34E60E31	94.37	5.24	0	83.8	12.3	-1.09
966	R34E90E31	94.4	5.22	0	83.81	12.29	-1.02
967	R34E30E32	97.35	5.31	0.17	59.87	18.43	-7.19
968	R34E60E32	97.71	4.94	-0.01	54.6	20.81	-9.96
969	R34E90E32	97.78	4.86	0	51.95	21.96	-10.73
970	R34E30E33	94.56	7.1	0	84.98	9.17	7.28
971	R34E60E33	94.96	6.84	0.77	83.33	9.92	9.7
972	R34E90E33	96.02	6.1	0.38	84.49	9.89	15.07

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
973	R41E30E41	95.18	4.86	-0.03	79.51	13.75	-0.42
974	R41E60E41	95.38	4.76	-0.03	78.38	14.07	-0.4
975	R41E90E41	95.42	4.74	-0.02	78.11	14.14	-0.39
976	R41E30E42	95.91	6.57	0.44	86.31	9.24	5.19
977	R41E60E42	96.44	6.14	0.01	86.18	9.26	4.2
978	R41E90E42	96.45	6.13	0	86.16	9.26	4.23
979	R41E30E43	94.08	7.4	0	84.78	9.29	7.62
980	R41E60E43	94.08	7.39	0	84.77	9.3	7.66
981	R41E90E43	94.08	7.39	0	84.75	9.31	7.69
982	R42E30E41	95.52	4.69	0.77	81.03	13.21	0.7
983	R42E60E41	96.06	4.4	0	79.89	13.58	1.13
984	R42E90E41	96.79	3.98	0	71.66	16.94	11.6
985	R42E30E42	96.37	6.2	-0.01	78.84	13.32	-1.11
986	R42E60E42	96.43	6.15	0	78.41	13.49	-3.39
987	R42E90E42	96.43	6.15	0	78.51	13.41	-3.17
988	R42E30E43	94.17	7.34	0.06	76.58	17.97	-1.56
989	R42E60E43	95.11	6.74	0	76.84	15.48	-2.2
990	R42E90E43	95.11	6.74	0	73.45	14.76	0.95
991	R43E30E41	98.37	2.85	-0.15	64.86	17.66	16.02
992	R43E60E41	99.8	1	-0.34	54.84	20.09	-0.46
993	R43E90E41	99.91	0.65	0	57.66	19.5	-0.1
994	R43E30E42	96.79	5.83	-0.14	71.01	16.45	-4.8
995	R43E60E42	97.46	5.2	0.11	63.9	19.64	-10.51
996	R43E90E42	97.7	4.95	-0.02	60.81	19.26	-7.35
997	R43E30E43	96	6.11	-0.81	88.12	8.8	5.9
998	R43E60E43	96.69	5.57	-0.02	85.74	11.07	3.57
999	R43E90E43	96.74	5.52	-0.02	85.63	11.16	3.47
1000	R44E30E41	95.91	4.48	0	80.38	13.44	-2.2
1001	R44E60E41	96.19	4.33	0	77.41	14.29	-0.36
1002	R44E90E41	96.78	3.99	0.31	72.46	15.64	0.57
1003	R44E30E42	97.88	4.77	-1.51	78.24	11.72	2.53
1004	R44E60E42	99.01	3.26	-0.33	76	12.99	1.85
1005	R44E90E42	99.1	3.1	-0.18	75.12	13.36	4.24
1006	R44E30E43	96.26	5.91	-0.03	84.19	9.75	5.74
1007	R44E60E43	96.56	5.68	-0.06	76.81	17.37	1.2
1008	R44E90E43	96.98	5.32	0.01	76	18.34	0.71
1009	R51E30E51	94.85	5.01	-0.24	75.54	15.46	-4.77
1010	R51E60E51	97.74	3.34	-0.16	65.79	19.3	-9
1011	R51E90E51	97.75	3.33	0	65.12	19.61	-8.99
1012	R51E30E52	96.61	5.99	-0.25	86.59	9.21	3.85
1013	R51E60E52	96.68	5.93	0.14	86.46	9.2	4.28
1014	R51E90E52	97.64	5	0.01	81.49	10.9	7.98
1015	R51E30E53	94.85	6.91	-0.01	82.37	11.79	6.01
1016	R51E60E53	94.85	6.91	0	82.4	11.76	6.04
1017	R51E90E53	94.85	6.91	0	82.4	11.76	6.04
1018	R52E30E51	93.65	5.82	-1.14	83.11	12.84	1.92
1019	R52E60E51	98.88	2.36	-0.05	63.77	29.23	-27.5
1020	R52E90E51	99.17	2.04	-0.07	41.07	78.02	-73.25
1021	R52E30E52	98.31	4.25	0.18	76.75	12.14	5.49
1022	R52E60E52	98.7	3.73	0	75.13	12.41	5.73
1023	R52E90E52	98.74	3.68	0	71.73	14.13	1.76
1024	R52E30E53	97.27	5.07	-0.02	85.49	10.18	4.58
1025	R52E60E53	97.71	4.64	-0.07	83.78	11.17	4.06
1026	R52E90E53	98.05	4.29	0	72.39	20.67	-1.96

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1027	R53E30E51	95.3	4.79	0.4	66.45	17.79	10.74
1028	R53E60E51	96.33	4.25	0.78	51.49	30.52	24.56
1029	R53E90E51	97.37	3.6	0.05	16.59	48.93	30.78
1030	R53E30E52	98.45	4.07	-0.07	84.06	9.77	2.56
1031	R53E60E52	99.03	3.22	-0.08	72.07	14.97	-5.47
1032	R53E90E52	99.03	3.22	0	72.61	14.5	-4.65
1033	R53E30E53	97.19	5.14	-0.43	84.35	10.1	5.21
1034	R53E60E53	98	4.37	0.97	87.52	8.64	6.17
1035	R53E90E53	98.23	4.09	-0.01	86.2	9.33	4.67
1036	R54E30E51	93.65	5.56	-0.48	85.39	11.83	1.28
1037	R54E60E51	94.84	5.02	-0.7	84	12.25	0.19
1038	R54E90E51	95.5	4.69	-0.05	83.53	12.42	-0.21
1039	R54E30E52	98.17	4.42	0.01	84.23	9.81	6.18
1040	R54E60E52	99	3.27	0.84	80.29	11.01	6.82
1041	R54E90E52	99.25	2.83	-0.03	82.1	10.78	2.42
1042	R54E30E53	97.48	4.87	-0.34	77.84	15.06	-0.02
1043	R54E60E53	98.31	4	0.14	77.65	17.87	-1.86
1044	R54E90E53	98.46	3.82	0.47	77.31	18.73	-1.76
1045	R61E30E61	95.85	4.51	0	82.07	13.22	5.14
1046	R61E60E61	95.85	4.51	0	81.48	13.5	5.66
1047	R61E90E61	95.85	4.51	0	80.94	13.77	6.22
1048	R61E30E62	97.05	5.59	0.35	84.83	9.86	7.93
1049	R61E60E62	97.2	5.45	0.01	85.76	9.39	5.84
1050	R61E90E62	97.2	5.44	0	85.85	9.35	5.74
1051	R61E30E63	95.26	6.72	3.79	88.4	8.53	11.53
1052	R61E60E63	95.93	6.16	0	82.02	10.97	10.8
1053	R61E90E63	95.94	6.15	0	82.36	10.96	10.79
1054	R62E30E61	96.48	4.16	0.07	80.67	13.4	1.57
1055	R62E60E61	96.95	3.88	0.37	79.74	13.69	2.36
1056	R62E90E61	96.99	3.85	0	79.79	13.69	2.12
1057	R62E30E62	97.73	4.91	0.13	78.27	11.47	-0.24
1058	R62E60E62	98.12	4.47	0.02	75.77	12.28	-0.68
1059	R62E90E62	98.22	4.35	0	75.48	12.34	-0.26
1060	R62E30E63	96.71	5.55	0.24	81.54	10.94	11.77
1061	R62E60E63	97.76	4.6	0.03	78.9	12.74	19.2
1062	R62E90E63	97.76	4.59	0	78.33	12.98	19.51
1063	R63E30E61	97.77	3.35	-1.51	80.04	13.63	-1.57
1064	R63E60E61	99.79	1.02	-0.21	78.26	15.1	-6.4
1065	R63E90E61	99.99	0.16	0	77.23	17.33	-17.52
1066	R63E30E62	97.3	5.37	1.56	86.15	9.57	8.92
1067	R63E60E62	98.15	4.44	0.01	79.03	12.51	9.1
1068	R63E90E62	98.17	4.41	0	77.11	13.38	11.08
1069	R63E30E63	95.08	6.76	-0.17	85.42	9.52	8.14
1070	R63E60E63	96.71	5.55	0.25	83.07	9.99	7.34
1071	R63E90E63	97.22	5.1	0.04	61.7	20.83	9.59
1072	R64E30E61	99.38	1.76	-0.28	76.54	14.79	3.96
1073	R64E60E61	99.77	1.07	0.22	67.15	19.39	0.51
1074	R64E90E61	100	0.01	0	68.06	20.48	-5.05
1075	R64E30E62	98.71	3.71	-0.09	81.27	10.95	0.24
1076	R64E60E62	99.45	2.42	0	72.06	13.6	-3.51
1077	R64E90E62	99.56	2.18	-0.11	71.27	14.15	-4.45
1078	R64E30E63	97.9	4.47	-0.17	81.35	11.05	7.87
1079	R64E60E63	98.63	3.59	-0.04	81.64	10.63	10.8
1080	R64E90E63	98.99	3.09	-0.02	70.02	20.59	-6.55

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1081	R11F30E11	79.26	9.64	0.02	80.88	13.48	3.96
1082	R11F60E11	79.4	9.61	0.01	82.53	12.87	3.42
1083	R11F90E11	79.43	9.6	0.01	82.98	12.69	3.22
1084	R11F30E12	89.18	10.51	0.96	76.41	11.69	4.37
1085	R11F60E12	90.14	10.05	0	73.02	13.43	1.82
1086	R11F90E12	90.14	10.05	0	73.02	13.43	1.82
1087	R11F30E13	88.1	10.31	0	70.63	13.33	4.01
1088	R11F60E13	88.1	10.31	0	70.63	13.33	4.01
1089	R11F90E13	88.1	10.31	0	70.63	13.33	4.01
1090	R12F30E11	80.95	9.28	-0.25	72.36	15.83	-3.5
1091	R12F60E11	82.04	9.04	0	73	27.7	-13.34
1092	R12F90E11	82.05	9.04	0	72.22	30.15	-15.46
1093	R12F30E12	90.36	9.95	0	69.38	15.48	-1.16
1094	R12F60E12	90.36	9.94	0	69.38	15.48	-1.14
1095	R12F90E12	90.37	9.94	0	69.37	15.48	-1.13
1096	R12F30E13	88.13	10.3	0	70.37	13.41	4.03
1097	R12F60E13	88.14	10.29	0	70.34	13.43	4.06
1098	R12F90E13	88.19	10.27	-0.01	70.59	13.46	5.12
1099	R13F30E11	80.24	9.44	-0.91	79.79	13.75	3.34
1100	R13F60E11	82.86	8.85	0.05	75.88	14.66	2.4
1101	R13F90E11	84.34	8.5	-0.23	75.64	14.72	2.64
1102	R13F30E12	91.04	9.62	-1.17	72.72	14.44	-2.08
1103	R13F60E12	93.15	8.45	-1.39	72.21	18.52	-12.07
1104	R13F90E12	93.62	8.16	-0.06	68.75	24.26	-17.31
1105	R13F30E13	89.11	9.9	-0.02	71.26	13.12	-1.26
1106	R13F60E13	89.64	9.66	-0.07	67.72	13.33	0.54
1107	R13F90E13	90.45	9.31	-0.05	63.88	13.9	2.93
1108	R14F30E11	82.06	9.05	0.42	77.29	14.53	6.02
1109	R14F60E11	87.57	7.63	0.61	73.57	15.35	4.56
1110	R14F90E11	93.91	5.46	-2.2	70.02	16.66	5.98
1111	R14F30E12	92.66	8.73	-0.22	68.21	16.15	-4.79
1112	R14F60E12	93.41	8.29	0	68.31	16.19	-0.1
1113	R14F90E12	93.92	7.97	-0.02	65.3	16.08	-0.04
1114	R14F30E13	90.07	9.47	-0.23	67.8	13.45	-0.62
1115	R14F60E13	92.08	8.5	0.48	65.6	14	7.9
1116	R14F90E13	92.31	8.38	0	64.95	14.29	10.09
1117	R21F30E21	83.93	8.61	0.02	86.16	12.14	2.59
1118	R21F60E21	84.51	8.46	0.01	87.92	11.43	4.04
1119	R21F90E21	84.52	8.46	0	87.91	11.43	4.06
1120	R21F30E22	94.41	7.65	-0.15	85.66	9.27	2.85
1121	R21F60E22	94.42	7.64	0	85.47	9.35	3.02
1122	R21F90E22	94.42	7.64	0	85.47	9.35	3.02
1123	R21F30E23	91.79	8.66	0	79.37	10.56	5.23
1124	R21F60E23	91.79	8.66	0	79.37	10.56	5.23
1125	R21F90E23	91.79	8.66	0	79.37	10.56	5.22
1126	R22F30E21	87.52	7.66	0	82	13.07	7.98
1127	R22F60E21	90.08	6.92	2.1	82.94	14.12	-1.17
1128	R22F90E21	91.33	6.45	0.01	77.35	19.59	-1.12
1129	R22F30E22	93.33	8.34	-0.09	83.41	9.98	2.97
1130	R22F60E22	93.53	8.22	0	83.28	10.05	3.35
1131	R22F90E22	93.53	8.21	0	83.25	10.06	3.36
1132	R22F30E23	93.27	7.87	-0.77	83.92	9.14	3.31
1133	R22F60E23	93.29	7.86	0	84.1	9.14	3.97
1134	R22F90E23	93.29	7.86	0	84.1	9.14	3.97

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1135	R23F30E21	86.56	7.93	0.39	84.51	12.18	1.02
1136	R23F60E21	89.49	7.07	0.09	76.97	14.91	9.74
1137	R23F90E21	90.98	6.57	0.04	68.28	24.18	10.94
1138	R23F30E22	94.7	7.46	-0.07	76.17	12.61	-1.83
1139	R23F60E22	95.13	7.16	-0.04	76.27	13.03	-5.21
1140	R23F90E22	96.4	6.18	-0.16	77.85	11.93	-7.72
1141	R23F30E23	93.2	7.91	-0.8	77.84	11.45	1.46
1142	R23F60E23	95.35	6.58	-0.05	77.15	12	0.86
1143	R23F90E23	95.65	6.36	-0.01	76.95	12.54	0.55
1144	R24F30E21	86.5	7.96	0.04	83.95	12.68	3.52
1145	R24F60E21	89.94	6.95	-2.41	78.41	13.99	1.17
1146	R24F90E21	93.3	5.7	0.07	78.84	13.87	-1.92
1147	R24F30E22	93.92	7.98	-1.04	83.19	10.51	0.29
1148	R24F60E22	96.16	6.38	-0.57	74.68	13.25	-4.97
1149	R24F90E22	97.17	5.48	-0.27	76.12	12.81	-4.17
1150	R24F30E23	94.36	7.22	0.15	83.81	9.13	2.79
1151	R24F60E23	94.88	6.89	-0.11	81.7	9.94	3.91
1152	R24F90E23	95.11	6.74	0.08	82.73	9.57	5.46
1153	R31F30E31	93.62	5.57	-0.19	85.05	12.47	-6.96
1154	R31F60E31	94.06	5.38	0	76.34	34.09	-40.61
1155	R31F90E31	94.06	5.38	0	75.43	36.93	-44.23
1156	R31F30E32	96.19	6.35	0.6	86.75	9.05	6.5
1157	R31F60E32	96.2	6.34	0	86.64	9.08	6.06
1158	R31F90E32	96.2	6.34	0	86.64	9.08	6.06
1159	R31F30E33	94.25	7.29	0.07	72.87	23.65	-8.43
1160	R31F60E33	94.36	7.22	-0.06	72.54	23.59	-8.3
1161	R31F90E33	94.56	7.1	0	72.55	23.7	-9.02
1162	R32F30E31	95	4.95	0.01	79.63	13.72	-0.5
1163	R32F60E31	95	4.94	0	79.67	13.7	-0.42
1164	R32F90E31	95	4.94	0	79.67	13.7	-0.42
1165	R32F30E32	95.77	6.69	1.19	86.78	9.03	6.03
1166	R32F60E32	95.8	6.66	0	86.75	9.03	5.1
1167	R32F90E32	95.8	6.66	0	86.75	9.03	5.1
1168	R32F30E33	94.02	7.43	-0.07	85.3	9.11	7.06
1169	R32F60E33	94.04	7.42	0.02	85.49	9.05	7.11
1170	R32F90E33	94.05	7.42	0	85.5	9.04	7.09
1171	R33F30E31	94.51	5.19	-0.06	81.46	13.07	1.2
1172	R33F60E31	95.99	4.49	2.31	79.12	13.84	3.13
1173	R33F90E31	97.92	3.21	-0.04	76.37	14.68	6.16
1174	R33F30E32	97.72	4.93	-0.19	74.89	14.6	-3.63
1175	R33F60E32	97.93	4.7	-0.04	71.61	15.02	-1.75
1176	R33F90E32	98.02	4.59	-0.01	73.94	13.68	-1.21
1177	R33F30E33	94.36	7.23	-0.25	85.37	9.16	5.99
1178	R33F60E33	95.63	6.38	0.39	82.89	9.55	9.6
1179	R33F90E33	96.14	6	0.02	81.78	9.73	8.91
1180	R34F30E31	95.56	4.66	-0.12	82.29	12.81	2.63
1181	R34F60E31	96.51	4.15	-0.01	77.04	14.43	-0.31
1182	R34F90E31	97.94	3.2	-0.07	64.49	18.69	-8.38
1183	R34F30E32	96.7	5.92	-0.03	81.93	11.26	4.64
1184	R34F60E32	97.31	5.35	-0.47	77.8	12.73	-1.35
1185	R34F90E32	97.86	4.78	0.11	75.52	13.91	-0.09
1186	R34F30E33	94.39	7.2	0	82.88	10.08	7.86
1187	R34F60E33	94.41	7.19	0.01	82.57	10.15	7.31
1188	R34F90E33	95.47	6.5	0.1	80.03	11.06	15.39

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1189	R41F30E41	94.17	5.32	0	79.1	13.83	-2.13
1190	R41F60E41	94.17	5.32	0	79.01	13.86	-1.99
1191	R41F90E41	94.17	5.32	0	79.1	13.83	-2.13
1192	R41F30E42	96.12	6.41	0.2	88.61	8.43	5.55
1193	R41F60E42	96.28	6.27	0	63.64	14.32	12.51
1194	R41F90E42	96.28	6.27	0	50.9	16.81	14.04
1195	R41F30E43	94.5	7.13	0.03	85.7	9.01	5.21
1196	R41F60E43	94.51	7.13	0	85.4	9.12	4.91
1197	R41F90E43	94.51	7.13	0	85.4	9.12	4.91
1198	R42F30E41	93.69	5.54	-0.87	83.86	12.28	-0.77
1199	R42F60E41	95.88	4.5	-0.01	80.76	13.29	-0.94
1200	R42F90E41	96.24	4.3	0	80.48	13.4	-1.55
1201	R42F30E42	96.27	6.28	-0.31	85.32	9.47	1.55
1202	R42F60E42	96.64	5.97	-0.01	84.55	9.72	0.04
1203	R42F90E42	96.65	5.96	-0.03	84.52	9.74	-0.11
1204	R42F30E43	95.31	6.6	-0.01	88.76	7.89	3.6
1205	R42F60E43	95.33	6.59	-0.01	88.7	7.93	3.76
1206	R42F90E43	95.38	6.56	-0.02	88.49	7.99	3.18
1207	R43F30E41	98.76	2.56	2.32	65.81	17.53	16.72
1208	R43F60E41	98.89	2.35	0	63.52	18.29	19.71
1209	R43F90E41	98.89	2.35	0	63.61	18.28	19.69
1210	R43F30E42	96.87	5.76	0.06	88.04	8.67	7.42
1211	R43F60E42	97.41	5.25	0.02	86.91	9.12	8.84
1212	R43F90E42	97.83	4.81	0.38	85	9.85	7.97
1213	R43F30E43	95.61	6.4	0.24	88.01	8.17	4.48
1214	R43F60E43	95.86	6.21	0.05	88.02	8.1	3.73
1215	R43F90E43	96.58	5.66	-0.02	89.32	7.75	1.01
1216	R44F30E41	98.23	2.97	0.09	75.7	15.22	14.03
1217	R44F60E41	99.56	1.49	0.01	69.99	17.22	20.64
1218	R44F90E41	99.85	0.87	0.02	68.82	17.63	20.95
1219	R44F30E42	96.62	5.98	-0.28	84.18	10.35	1.46
1220	R44F60E42	96.8	5.83	-0.36	83.14	10.79	1.04
1221	R44F90E42	97.68	4.98	-0.08	78.8	12.5	-3.12
1222	R44F30E43	95.27	6.63	-0.04	86.08	8.63	5.39
1223	R44F60E43	97.9	4.45	0.48	86.09	9.21	12.07
1224	R44F90E43	98.73	3.46	-0.05	84.67	9.8	9.49
1225	R51F30E51	96.26	4.29	0.11	84.84	12.2	2.31
1226	R51F60E51	97.73	3.35	-0.02	82.31	13.02	-1.47
1227	R51F90E51	97.73	3.35	0	82.08	13.09	-1.58
1228	R51F30E52	98.11	4.49	0.02	30.77	38.26	-18.88
1229	R51F60E52	98.14	4.45	0	51.86	22.8	-8.75
1230	R51F90E52	98.16	4.43	0	51.69	24.28	-11.23
1231	R51F30E53	95.31	6.6	-0.01	82.97	10.56	6.16
1232	R51F60E53	95.55	6.44	-0.01	85.3	9.73	7.74
1233	R51F90E53	95.58	6.42	0	85.1	9.87	7.75
1234	R52F30E51	95.27	4.81	0.29	79.95	13.68	-0.63
1235	R52F60E51	97.13	3.76	-0.06	79.78	13.61	-0.52
1236	R52F90E51	97.24	3.69	0	79.77	13.64	0.69
1237	R52F30E52	97.52	5.13	0	85.45	9.66	9.52
1238	R52F60E52	97.56	5.09	0	84.11	10.05	9.23
1239	R52F90E52	97.56	5.09	0	84.09	10.06	9.1
1240	R52F30E53	96.85	5.43	-0.21	78.63	11.98	10.47
1241	R52F60E53	96.93	5.37	0	78.87	11.97	11.45
1242	R52F90E53	96.93	5.36	0	78.69	12.03	11.47

continua

continuação

n	REDE	TREINAMENTO			VALIDACAO		
		R	RMSE	DV (%)	R	RMSE	DV (%)
1243	R53F30E51	98.42	2.8	-0.13	76.77	14.77	-7.05
1244	R53F60E51	99.49	1.6	-0.02	68.96	18.27	1.38
1245	R53F90E51	99.9	0.69	-0.01	68.03	19.11	-1.05
1246	R53F30E52	97.47	5.19	-0.04	84.75	9.93	0.51
1247	R53F60E52	97.6	5.05	-0.02	84.96	9.86	1.24
1248	R53F90E52	97.66	4.99	-0.02	84.97	9.84	1.33
1249	R53F30E53	96.91	5.38	-0.04	79.8	11.54	12.98
1250	R53F60E53	96.93	5.36	0	80.03	11.48	13.06
1251	R53F90E53	96.93	5.36	0	80.05	11.48	13.03
1252	R54F30E51	99	2.23	-0.12	64.98	18.18	5.29
1253	R54F60E51	99.23	1.95	0.36	62.52	18.98	9.95
1254	R54F90E51	99.39	1.74	0	57.44	20.27	12.7
1255	R54F30E52	98.93	3.38	-0.58	70.95	15.19	3.71
1256	R54F60E52	99.51	2.3	-0.02	67.29	16.23	3.49
1257	R54F90E52	99.62	2.03	0	67.24	16.53	2.04
1258	R54F30E53	96.59	5.65	-0.21	86.75	9.14	8.64
1259	R54F60E53	98.28	4.03	-0.05	77.81	14.18	2.45
1260	R54F90E53	98.62	3.61	0	71.3	19.27	-1.57
1261	R61F30E61	95.09	4.9	0	85.85	11.58	-0.95
1262	R61F60E61	95.1	4.89	0	85.78	11.61	-1.08
1263	R61F90E61	95.1	4.89	0	85.73	11.63	-1.1
1264	R61F30E62	96.56	6.03	0.01	86.43	9.21	6.29
1265	R61F60E62	96.7	5.9	0.02	86.37	9.24	6.44
1266	R61F90E62	96.79	5.83	-0.03	86.32	9.25	6.2
1267	R61F30E63	95.76	6.29	-1.14	85.93	10.5	4.77
1268	R61F60E63	96.96	5.34	-0.01	74.53	31.79	-15.2
1269	R61F90E63	96.96	5.34	0	74.55	31.78	-15.16
1270	R62F30E61	96.17	4.33	-0.03	82.03	12.95	2.39
1271	R62F60E61	96.61	4.08	0	79.86	13.76	2.11
1272	R62F90E61	97.18	3.73	-0.01	81.33	13.69	-7.57
1273	R62F30E62	96.49	6.09	0	86.65	9.14	6.57
1274	R62F60E62	96.49	6.09	0	86.65	9.14	6.57
1275	R62F90E62	96.49	6.09	0	86.65	9.14	6.57
1276	R62F30E63	94.78	6.96	0	85.88	9.39	9.38
1277	R62F60E63	94.78	6.96	0	85.88	9.39	9.38
1278	R62F90E63	94.78	6.96	0	85.88	9.39	9.38
1279	R63F30E61	97.84	3.27	0.04	84.92	12.03	-5.14
1280	R63F60E61	98.12	3.05	0.16	83.53	13.49	-9.57
1281	R63F90E61	98.26	2.94	0	83.45	13.87	-11.04
1282	R63F30E62	97.83	4.8	-0.04	78.95	12.27	1.18
1283	R63F60E62	98.39	4.14	-0.05	74.11	17.07	-4.71
1284	R63F90E62	98.99	3.3	0	74.44	14.71	-7.51
1285	R63F30E63	97.16	5.16	-0.03	74.75	26.82	-11.07
1286	R63F60E63	97.46	4.89	-0.02	74.18	27.89	-12.24
1287	R63F90E63	97.57	4.78	-0.07	74.08	28.76	-15.84
1288	R64F30E61	94.27	5.31	-1.07	84.06	12.29	-0.48
1289	R64F60E61	95.78	4.55	-0.29	84.3	12.15	0.72
1290	R64F90E61	98.34	2.91	-1.82	80.13	13.54	-3
1291	R64F30E62	97.97	4.66	-0.77	85.49	9.58	0.49
1292	R64F60E62	98.42	4.1	-0.18	80.99	10.91	0.21
1293	R64F90E62	99.29	2.77	-0.1	71.86	14.56	-6.85
1294	R64F30E63	96.4	5.8	-0.23	85.68	9.05	5.09
1295	R64F60E63	98.4	3.88	-0.13	80.33	14.17	-4.93
1296	R64F90E63	98.64	3.58	-0.01	77.16	18.23	-8.64

conclusão