

UNIVERSIDADE FEDERAL DO PARANÁ

MARCELO HENRIQUE PELEGRINI ROCHA

VERIFICAÇÃO DO POTENCIAL DAS REDES NEURAIS ARTIFICIAIS EM
REPRODUZIR O PROCESSO CHUVA-VAZÃO MENSAL COM CENÁRIOS DE
MODELOS CLIMÁTICOS REGIONAIS

CURITIBA
2014

MARCELO HENRIQUE PELEGRINI ROCHA

VERIFICAÇÃO DO POTENCIAL DAS REDES NEURAIAS ARTIFICIAIS EM
REPRODUZIR O PROCESSO CHUVA-VAZÃO MENSAL COM CENÁRIOS DE
MODELOS CLIMÁTICOS REGIONAIS

Dissertação apresentada ao Programa de Pós Graduação em Engenharia de Recursos Hídricos e Ambiental, Área de Concentração em Engenharia de Recursos Hídricos, Departamento de Hidráulica e Saneamento, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial para a obtenção do título de mestre em Engenharia de Recursos Hídricos e Ambiental.

Orientadora: Prof^a Dra. Miriam Rita Moro Mine
Coorientador: Prof Dr. Eloy Kaviski

CURITIBA
2014

Dedico este trabalho ao meu pai Nelson Rocha, minha mãe Maria Aparecida Pelegrini Rocha, meus irmãos Rafael e Guilherme Rocha e a todos meus amigos que me apoiaram nesta jornada.

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, em segundo lugar a Miriam Rita Moro Mine e Eloy Kaviski pelo acompanhamento, orientação, dedicação e amizade. Agradeço também ao João Furtado pelo auxílio na coleta de dados do Projeto CLARIS LPB. e a aos colegas do programa pela amizade e conselhos durante a elaboração do projeto.

Agradeço também, a todos os colegas, professores do Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental e do Departamento de Hidráulica e Saneamento, Setor de Tecnologia da Universidade Federal do Paraná.

Aprender generosamente significa não aprender com egoísmo, buscando a aquisição do conhecimento para a vaidade pessoal ou para vangloriar-se em um amanhã de triunfos exteriores, esquecendo que muito aprendido foi ensinado para evitar sofrimento e permitir a passagem pelos trechos difíceis no longo caminho da vida.

Raumsol

RESUMO

A etapa do projeto CLARIS LPB desenvolvida no Departamento de Hidráulica e Saneamento da Universidade Federal do Paraná, teve como objetivo avaliar os impactos das mudanças climáticas na hidroeletricidade na Bacia do Rio da Prata. Para isso utilizaram-se de dois Modelos Climáticos Regionais (RCM), PROMES e RCA, para se fazer previsões de temperatura e chuva em longo prazo, e do modelo chuva-vazão *Variable Infiltration Capacity* (VIC) para simular o comportamento das vazões. Com o objetivo de confrontar os resultados obtidos pelo modelo VIC, esta pesquisa modelou o processo chuva-vazão através do uso de Redes Neurais Artificiais (RNA) para nove bacias hidrográficas também estudadas no projeto CLARIS LPB. Este trabalho pode ser dividido em quatro etapas: calibração e validação dos modelos chuva-vazão a partir de dados observados; análise e correção das séries simuladas pelos RCM's; uso dos modelos validados com as séries corrigidas; e verificação do potencial das RNA's em descrever o processo chuva-vazão mensal com uso das séries corrigidas. Durante a etapa de calibração e validação dos modelos, pode-se concluir que as RNA's foram capazes de descrever os processos chuva-vazão. Para a etapa seguinte, pode-se concluir que as séries simuladas pelos RCM's apresentavam *bias* (tendências) e para sua correção foram propostos três métodos. Os resultados obtidos da correção, de modo geral, apresentaram melhoras nos coeficientes de Nash-Sutcliffe, porém estas melhoras não foram consideradas satisfatórias. Quando comparadas as simulações da RNA com as do VIC para um período com dados observados pode-se concluir que, as RNA's apresentaram resultados melhores em oito das nove bacias hidrográficas quando usadas as séries simuladas pelo RCM PROMES e sete das nove bacias quando usadas as séries do modelo RCA. A não capacidade das RNA em apresentar boas séries de simulações pode ser atribuída principalmente á baixa qualidade das precipitações e temperatura simuladas pelos RCM's .

Palavra-chave: Redes Neurais Artificiais, modelos chuva-vazão, PROMES, RCA, *bias*, simulação.

ABSTRACT

The CLARIS LPB Project portion developed by Hydraulics and Sanitation Department of Universidade Federal do Parana aimed of assessing the impacts of climate changes on hydropower in Rio da Prata basin. Two Regional Climate Models (PROMES and RCA) were applied in order to make temperature and rainfall predictions (forecast) in long term. In addition, Variable Infiltration Capacity (VIC) rainfall-runoff model was applied to simulate flow's behaviour. With the purpose of comparing the results obtained by VIC model, this research modeled the rainfall-runoff process by using Artificial Neural Networks (ANN) for nine watersheds that were also studied in Claris LPB project. This work can be split into four steps: calibration and validation of rainfall-runoff models based on observed data; analysis and correction of series simulated by the RCM's; use of validated models with adjusted series; and verification of ANN's potential for describing the monthly rainfall-runoff process with the use of corrected series. During the step of calibration and validation of models, it could be concluded that ANN's were able to describe the rain-runoff processes. For the next step, the conclusion is that the series simulated by RCM's presented bias (trends) and three methods for its correction have been proposed. The results obtained after the corrections showed improvement in the Nash-Sutcliffe coefficients, but these improvements were not considered satisfactory. When comparing ANN's and VIC simulations for a given observed data period it can be concluded that the ANN's outperformed in eight out of nine basins studied when used series simulated by RCM PROMES and seven out of nine basins when used the RCA series model. The inability of ANN in presenting good series of simulations can be assigned mainly to the low quality of precipitation and temperature data simulated by the RCM's.

LISTA DE FIGURAS

Figura 1 - REPRESENTAÇÃO ESQUEMÁTICA DO MODELO VIC DE DUAS CAMADAS.....	37
Figura 2 – NEURÔNIO ARTIFICIAL.....	39
Figura 3 – TIPOS DE FUNÇÕES TRANSFERÊNCIA MAIS COMUNS	42
Figura 4 - RNA DO TIPO PERCEPTRON DE UMA CAMADA (PERCEPTRON)	43
Figura 5 – RNA DO TIPO PERCEPTRON DE TRÊS CAMADAS	45
Figura 6 - MELHOR AJUSTE PARA OS PONTOS	48
Figura 7 - PROBLEMAS LINEARMENTES SEPARÁVEIS (a) E NÃO LINEARMENTE SEPARÁVEIS (b).....	48
Figura 8 – RNA DO TIPO HOPFIELD (ESQUERDA) E RUMMELHART (DIREITA).....	49
Figura 9 – PROBLEMA NÃO LINEAR MONOVARIÁVEL	50
Figura 10 – PROBLEMA NÃO LINEAR MULTI-VARIÁVEL	50
Figura 11 -FLUXO DE DADOS EM <i>FOWARD</i> DE UMA RNA.....	59
Figura 12 -FLUXO DE DADOS EM <i>BACKWARD</i> DE UMA RNA.....	60
Figura 13 FLUXOGRAMA GERAL MODELO CHUVA-VAZÃO.....	68
Figura 14 - FLUXOGRAMA DO PROCESSO DE TREINAMENTO E SIMULAÇÃO	72
Figura 15 - LOCALIZAÇÃO DA BACIA DO RIO PARANÁ.....	75
Figura 16 - BACIA DO RIO PARANÁ E SUAS PRINCIPAIS SUB-BACIAS.....	76
Figura 17 - LOCALIZAÇÃO DA BACIA DO RIO URUGUAI	77
Figura 18- BACIA HIDROGRÁFICA DO RIO URUGUAI E SUAS PRINCIPAIS SUB-BACIAS.....	78

Figura 19 – LOCALIZAÇÃO DAS ESTAÇÕES FLUVIOMÉTRICAS	81
Figura 20 – LOCALIZAÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS.....	82
Figura 21 – LOCALIZAÇÃO DAS ESTAÇÕES METEOROLÓGICAS	83
Figura 22- LOCALIZAÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS DENTRO DA RESPECTIVA REGIÃO GEOGRÁFICA.....	85
Figura 23 - CURVA DE PERMANÊNCIA DE PRECIPITAÇÕES OBSERVADAS E GERADAS EM MONTE CARMELO (SUDESTE)	87
Figura 24 - HISTOGRAMA DE PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE).....	88
Figura 25 POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE)	89
Figura 26 – FDA DAS PRECIPITAÇÕES MÁXIMAS (a) E MÍNIMAS (b) MENSAIS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE)	90
Figura 27 - CURVA DE PERMANÊNCIA DE PRECIPITAÇÃO OBSERVADAS E GERADAS EM ESTAÇÃO UNIÃO DA VITÓRIA (SUL)	91
Figura 28 - HISTOGRAMA DE PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL).....	92
Figura 29 POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL)	93
Figura 30 FDA DAS PRECIPITAÇÕES MÁXIMAS MENSAIS - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL)	93
Figura 31 – ANÁLISE DA SAZONALIDADE DA PRECIPITAÇÃO MÉDIA MENSAL (01/61 A 12/91) PARA REGIÃO SUDESTE	96
Figura 32 – ANÁLISE DA SAZONALIDADE DA PRECIPITAÇÃO MÉDIA MENSAL (01/61 A 12/91) PARA REGIÃO SUL	97
Figura 33 – BACIA DO ALTO PARANAÍBA (EMBORCAÇÃO)	109
Figura 34– BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)	109

Figura 35– BACIA DO ALTO RIO GRANDE (FURNAS)	110
Figura 36– BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA)	110
Figura 37– BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	111
Figura 38- BACIA DO RIO PARANAPANEMA (CAPIVARA)	111
Figura 39- BACIA DO RIO PARANÁ (ITAIPU)	112
Figura 40 – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)	112
Figura 41- BACIA RIO URUGUAI (ITÁ)	112
Figura 42- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – ALTO PARANAÍBA (EMBORCAÇÃO)	113
Figura 43- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BAIXO PARANAÍBA (SÃO SIMÃO)	113
Figura 44- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – ALTO RIO GRANDE (FURNAS)	114
Figura 45- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BAIXO RIO GRANDE (ÁGUA VERMELHA).....	114
Figura 46- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	114
Figura 47- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)	115
Figura 48- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO PARANÁ (ITAIPU)	115
Figura 49- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO IGUAÇU (SALTO OSÓRIO).....	115
Figura 50- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO URUGUAI (ITÁ)	116
Figura 51 – OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO ALTO PARANAÍBA (EMBORCAÇÃO).....	117

Figura 52– OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)	117
Figura 53– OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO ALTO RIO GRANDE (FURNAS).....	118
Figura 54– OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA).....	118
Figura 55 – OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA).....	118
Figura 56- OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO RIO PARANAPANEMA (CAPIVARA).....	118
Figura 57- OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO RIO PARANÁ (ITAIPU).....	119
Figura 58 – OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)	119
Figura 59- OBSERVADA <i>VERSUS</i> RNA (PROMES) – BACIA RIO URUGUAI (ITÁ)	119
Figura 60 – OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO ALTO PARANAÍBA (EMBORCAÇÃO).....	120
Figura 61– OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)	120
Figura 62– OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO ALTO RIO GRANDE (FURNAS).....	120
Figura 63– OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA).....	120
Figura 64 – OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA).....	121
Figura 65- OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO RIO PARANAPANEMA (CAPIVARA).....	121
Figura 66- OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO RIO PARANÁ (ITAIPU)	121

Figura 67 – OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO).....	121
Figura 68- OBSERVADA <i>VERSUS</i> RNA (RCA) – BACIA RIO URUGUAI (ITÁ)	122
Figura 69- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – ALTO PARANAÍBA (EMBORCAÇÃO)	124
Figura 70- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BAIXO PARANAÍBA (SÃO SIMÃO)	124
Figura 71- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – ALTO RIO GRANDE (FURNAS)	125
Figura 72- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BAIXO RIO GRANDE (ÁGUA VERMELHA)	125
Figura 73- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	125
Figura 74- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)	126
Figura 75- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO PARANÁ (ITAIPU)	126
Figura 76- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO– BACIA DO RIO IGUAÇU (SALTO OSÓRIO).....	126
Figura 77- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO URUGUAI (ITÁ)	127
Figura 78- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – ALTO PARANAÍBA (EMBORCAÇÃO)	128

Figura 79- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BAIXO PARANAÍBA (SÃO SIMÃO) .	128
Figura 80- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO– ALTO RIO GRANDE (FURNAS)	128
Figura 81- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BAIXO RIO GRANDE (ÁGUA VERMELHA)	129
Figura 82- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	129
Figura 83- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA).....	129
Figura 84- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BACIA DO RIO PARANÁ (ITAIPU) ..	130
Figura 85- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO– BACIA DO RIO IGUAÇU (SALTO OSÓRIO).....	130
Figura 86- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA) PERÍODO OBSERVADO – BACIA DO RIO URUGUAI (ITÁ)	130
Figura 87- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – ALTO PARANAÍBA (EMBORCAÇÃO) ...	131
Figura 88- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BAIXO PARANAÍBA (SÃO SIMÃO)	132
Figura 89- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – ALTO RIO GRANDE (FURNAS)	133
Figura 90- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BAIXO RIO GRANDE (ÁGUA VERMELHA)	133
Figura 91 FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	134

Figura 92- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA).....	134
Figura 93- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO PARANÁ (ITAIPU)	135
Figura 94- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)	136
Figura 95- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO URUGUAI (ITÁ)	136
Figura 96- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – ALTO PARANAÍBA (EMBORCAÇÃO)	137
Figura 97 FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BAIXO PARANAÍBA (SÃO SIMÃO)	138
Figura 98- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – ALTO RIO GRANDE (FURNAS)	138
Figura 99- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BAIXO RIO GRANDE (ÁGUA VERMELHA) ..	139
Figura 100- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)	139
Figura 101- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA).....	140
Figura 102- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO PARANÁ (ITAIPU)	140
Figura 103- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO) .	141
Figura 104- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) – BACIA DO RIO URUGUAI (ITÁ)	141

LISTA DE TABELAS

Tabela 1- PERÍODOS COM FALHAS NAS ESTAÇÕES PLUVIOMÉTRICAS.	87
Tabela 2- RESULTADOS CORREÇÃO DO <i>BIAS</i> MONTE CARMELO - CHUVA (mm)	99
Tabela 3- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> GOIÂNIA - TEMPERATURA (°C)	99
Tabela 4- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> MONTE ALEGRE DE MINAS - CHUVA (mm).....	99
Tabela 5- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> CATALÃO - TEMPERATURA (°C)	100
Tabela 6- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> FRANCA - CHUVA (mm)	100
Tabela 7- RESULTADOS CORREÇÃO <i>BIAS</i> FRANCA - TEMPERATURA (°C)	100
Tabela 8- RESULTADOS DA CORREÇÃO <i>BIAS</i> USINA COURO DO CERVO - CHUVA (mm)	101
Tabela 9- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> LAVRAS - TEMPERATURA (°C)	101
Tabela 10- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> FAZENDA BARREIRINHO - CHUVA (mm)	101
Tabela 11- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> CATANDUVA - TEMPERATURA (°C)	102
Tabela 12- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> TOMAZINA - CHUVA (mm).....	102
Tabela 13- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> CASTRO - TEMPERATURA (°C)	102
Tabela 14- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> CAIUÁ - CHUVA (mm)	103

Tabela 15- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> PRESIDENTE PRUDENTE - TEMPERATURA (°C)	103
Tabela 16- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> UNIÃO DA VITÓRIA - CHUVA (mm)	103
Tabela 17- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> CURITIBA - TEMPERATURA (°C)	104
Tabela 18- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> ESTAÇÃO LAGOA VERMELHA - CHUVA (mm).....	104
Tabela 19- RESULTADOS DA CORREÇÃO DO <i>BIAS</i> ESTAÇÃO LAJES - TEMPERATURA (°C)	104
Tabela 20 - RNA SELECIONADA E SEUS COEFICIENTES DE DESEMPENHO (01/61 a 12/90).....	108
Tabela 21 – DESEMPENHO DAS RNA COM USO DAS SÉRIES SIMULADAS PELO PROMES E RCA (01/91 a 12/06)	117
Tabela 22 – COMPARAÇÃO DO DESEMPENHO MODELO RNA E VIC COM USO DAS SÉRIES GERADAS PELOS RCM (01/1991 A 12/2006)	123

LISTA DE QUADROS

Quadro 1 – RELAÇÃO ENTRE OS TERMOS UTILIZADOS EM ESTATÍSTICA E RNA.	47
Quadro 2 – TIPOS DE MODELOS USADOS NO ESTUDO	69
Quadro 3 – LOCAIS DE ESTUDO E SUAS ESTAÇÕES SELECIONADAS ...	80
Quadro 4 - ESTAÇÕES FLUVIOMÉTRICAS	81
Quadro 5 - ESTAÇÕES PLUVIOMÉTRICAS	82
Quadro 6- ESTAÇÕES METEOROLÓGICAS	83
Quadro 7 - MODELOS RNA PARA CORREÇÃO DO <i>BIAS</i> DA CHUVA	96
Quadro 8- MODELOS RNA PARA CORREÇÃO DO <i>BIAS</i> DA TEMPERATURA	96
Quadro 9 - MÉTODOS DE CORREÇÕES SELECIONADOS	106

LISTA DE ABREVIATURAS

ADELIN	Adaptive Linear Element
ANFI	Adaptive Neuro Fuzzy Interference System
ARMA	Modelo de Médias Móveis Auto Regressivo
BATS	Biosphere-Atmosphere Transfer Scheme
GCM	Modelos de Circulação Globais
GEP	Gene Expression Programming
HEC-RAS	Hydrologic Engineering Centers River Analysis System
IA	Inteligência Artificial
IAF	Índice de Área Foliar
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
MLP	Multilayer Perceptron
NS	Nash-Sutcliffe
OMM	Organização Meteorológica Mundial
PNUMA	Programa das Nações Unidas para o Meio Ambiente
PROMES	PROgnostic at the MESoscale
RCA	Rossby Centre Regional Atmospheric Climate Model
RCM	Modelos Climáticos Regionais
RNA	Redes Neurais Artificiais
SMAP	Soil Moisture Active Passive
SSARR	Streamflow Synthesis and Reservoir Regulation
SVM	Support Vector Machine
VIC	Variable Infiltration Capacity
NCAR-CCSM3	National Center Atmospheric Research Community Climate Model, version 3.0
LMDZ	Laboratoire de Météorologie Dynamique Zoom

LISTA DE SÍMBOLOS

x_{Ni}	Elementos de entrada da matriz X ;
w_i	Pesos da matriz W ;
b_j	Bias no neurônio j ;
φ	Função transferência;
y_{Nj}	Saída N do neurônio j ;
$w_{ji}(n+1)$	Peso corrigido na conexão ij e iteração $(n+1)$;
$w_{ji}(n)$	Peso na conexão ij e iteração (n) ;
E_1	Transpiração na camada 1;
E_c	Evapotranspiração na camada dossel;
E_t	Transpiração total;
P	Precipitação;
Q_d	Escoamento superficial;
Q_b	Escoamento subsuperficial;
W_1^c	Máxima umidade contida na camada 1;
W_2^c	Máxima umidade contida na camada 2;
W_{n+1}	Vetor de coeficientes na iteração “ $n+1$ ”;
W_n	Vetor de coeficientes na iteração “ n ”;
λ_n^*	Escalar positivo que maximize $f(\lambda_n \nabla \mathcal{E} _{W_n})$;
$\nabla \mathcal{E} _{W_n}$	Gradiente da função objetivo em W_n ;
$H_{\mathcal{E}} _{W_n}$	Matriz Hessiana em W_n ;
\mathcal{E}	Função objetivo;
e	erro;
d	Saída desejada;
$f(\bar{x}_N, W)$	Saída da RNA para a iteração “ n ”;
$e_{Nk}(n)$	Erro na saída da RNA na iteração “ n ” para uma entrada “ N ”;
$d_{Nk}(n)$	Saída desejada para entrada “ N ” na iteração “ n ”;
$y_{Nk}(n)$	Saída calculada pela RNA para entrada “ N ” na iteração “ n ”;
$\varphi_k'(v_{Nk}(n))$	Derivada parcial de $\varphi_k(v_{Nk}(n))$ em relação a v_{Nk} ;
$\delta_{Nk}(n)$	Gradiente local;
$\nabla \mathcal{E} _{w_n}$	Vetor gradiente da função objetivo para o ponto w_n ;

$H_E _{w_n}$	Matriz Hessiana da função objetivo para o ponto w_n ;
$J^T(n)$	Matriz Jacobiano da função erro em função dos pesos e <i>bias</i> da RNA;
x_{nor}	Variável normalizado;
x	Variável que se deseja normalizar;
x_{min}	Menor valor da variável que se deseja normalizar;
x_{max}	Maior valor da variável que se deseja normalizar;
Q_{obs}	Vazão observada no instante “t”;
Q_{cal}	Vazão modelada no instante “t”;
\bar{Q}_{obs}	Vazão média observada;
NS	Nash-Sutcliffe;
R^2	Coeficiente de determinação;
DV	Diferença percentual entre os volumes observados e os volumes calculados pela RNA;
NC	Número de classes;
N	Tamanho da amostra;
f_r	Frequência relativa;
f	Frequência absoluta de um intervalo de classe;
$P_{cor}(n)$	Precipitação com o bias corrigido para o tempo n;
$P_{sim}(n)$	Precipitação gerada pelo RCM no tempo n;
\bar{P}_{obs}	Média das precipitações observadas;
\bar{P}_{sim}^*	Média das precipitações geradas pelo RCM para o mesmo período das precipitações observadas;
$T_{cor}(n)$	Temperatura com o bias corrigido para o tempo n;
$T_{sim}(n)$	Temperatura gerada pelo RCM no tempo n;
\bar{T}_{obs}	Média das temperaturas observadas;
\bar{T}_{sim}^*	Média das temperaturas geradas pelo RCM para o mesmo período das precipitações observadas;
X_i	Valor de um evento na posição iésima;
N	Número total de elementos na amostra;
S	Desvio padrão;
CV	Coeficiente de variação.

SUMÁRIO

INTRODUÇÃO	19
JUSTIFICATIVA.....	21
OBJETIVO GERAL	21
OBJETIVOS ESPECÍFICOS	21
1. REVISÃO BIBLIOGRÁFICA	22
2. CENÁRIOS DE PRECIPITAÇÃO	28
2.1 MODELOS CLIMÁTICOS	29
2.2 MODELOS CLIMÁTICOS GLOBAIS.....	30
2.2.1 Modelo LMDZ.....	30
2.2.2 Modelo ECHAM5.....	31
2.3 MODELOS CLIMÁTICOS REGIONAIS	31
2.3.1 Modelo ETA.....	32
2.3.2 Modelo REGCM3.....	32
2.3.3 Modelo PROMES	33
2.3.4 Modelo RCA	33
3. MODELOS CHUVA-VAZÃO	35
3.1 MODELO <i>VARIABLE INFILTRATION CAPACITY</i> (VIC)	36
3.2 REDES NEURAIS ARTIFICIAIS (RNA).....	38
3.2.1 Neurônio artificial	39
3.2.2 Função transferência	41
3.2.3 RNA do tipo <i>Perceptron</i> e <i>Perceptron</i> multicamadas	42
3.2.4 Outros modelos de RNA.....	48
3.2.5 Ajuste dos pesos	49
3.2.5.1 Algoritmo <i>backpropagation</i>	52
3.2.5.2 Algoritmo Levenberg-Maquardt.....	61
3.2.6 Cuidados para um melhor desempenho de uma RNA MLP	63
3.2.6.1 Arquitetura	63
3.2.6.2 <i>Epochs</i>	64
3.2.6.3 Inicialização dos pesos.....	65
3.2.6.4 Normalização	66
4. MÉTODO	67

4.1	INTRODUÇÃO	67
4.2	MODELOS.....	68
4.3	TREINAMENTO.....	69
5.	ESTUDO DE CASO	73
5.1	ÁREAS DE ESTUDO.....	74
5.1.1	Bacia do Rio Paraná	74
5.1.2	Bacia do Rio Uruguai.....	77
6.	DADOS	80
6.1	ESTAÇÕES FLUVIOMÉTRICAS.....	81
6.2	ESTAÇÕES PLUVIOMÉTRICAS.....	82
6.3	ESTAÇÕES METEOROLÓGICAS.....	83
6.4	CENÁRIOS DE PRECIPITAÇÃO E TEMPERATURA.....	84
6.5	ANÁLISE ESTATÍSTICA DE CENÁRIOS DE PRECIPITAÇÃO	84
6.5.1	Método da análise de dados.....	84
6.5.2	Resultado da análise de dados Monte Carmelo – Região Sudeste.....	87
6.5.3	Resultado da análise de dados para União da Vitória - Região Sul	90
6.5.4	Conclusões.....	94
6.6	REMOÇÃO DO <i>BIAS</i> DAS SÉRIES GERADAS	94
6.6.1	Resultados.....	98
7.	MODELAGEM CHUVA-VAZÃO	107
7.1	POTENCIAL DAS RNA's NO PROCESSO CHUVA-VAZÃO MENSAL COM DADOS OBSERVADOS.....	107
7.2	POTENCIAL DAS RNA's NO PROCESSO CHUVA-VAZÃO MENSAL COM CENÁRIOS DE RCM's	116
7.3	COMPARAÇÃO DOS MODELOS RNA E VIC	122
8.	CONCLUSÕES E RECOMENDAÇÕES	143
	APÊNDICE	153
	ANEXO.....	189

INTRODUÇÃO

Nos últimos anos, o tema mudanças climáticas tem cada vez mais despertado interesse de diversos setores da sociedade. Embora não seja consenso na comunidade científica, muitos acreditam que o aumento da concentração de gases de efeito estufa resultante da intensificação das atividades antrópicas tem causado alterações no clima mundialmente. Com a finalidade de obter um maior conhecimento científico sobre o tema, foi instituído, no ano de 1988, o Painel Intergovernamental sobre Mudanças Climáticas (IPCC) pela Organização Meteorológica Mundial (OMM) e pelo Programa das Nações Unidas para o Meio Ambiente (PNUMA). O IPCC fornece informações científicas, técnicas e sócio-econômicas para o entendimento das mudanças climáticas, seus impactos potenciais e opções de adaptação e mitigação.

Muitos autores já escreveram sobre os efeitos do aquecimento global no planeta. Segundo IPCC (2001b), as alterações climáticas afetam a disponibilidade de recursos hídricos e, conseqüentemente, o suprimento de água potável, a geração de energia e a navegação fluvial. Este fato também é percebido por MARENGO *et al.* (2001) que afirmam que, além do aquecimento global, têm-se observado maior frequência e intensidade de eventos climáticos extremos, alterações nos regimes de chuva, perturbações nas correntes marinhas, retração de geleiras e elevação do nível dos oceanos.

A fim de promover previsões futuras e simular o comportamento da temperatura e a precipitação para o longo prazo, foram elaborados Modelos de Circulação Globais (GCM). Esses modelos possuem uma grade não inferior a 100 km por se tratarem de modelos de escala global e demandarem alto processamento computacional. Com o surgimento da demanda de dados mais refinados, foram elaborados os modelos climáticos regionais (RCM), que usam as séries geradas pelos GCM's como dados de entrada e fornecem resultados mais precisos.

Entre os muitos usos, as séries simuladas pelos modelos climáticos (precipitação e temperatura) podem ser usadas em modelos chuva-vazão e, desta maneira, é possível avaliar, gerenciar e fazer previsões com certo grau

de precisão para os diversos usos da água como: abastecimento, irrigação, geração de energia, bem como prever eventos extremos de cheias e períodos de estiagem futuros.

A transformação de chuva em vazão é um processo complexo devido ao grande número de variáveis que se modificam no espaço e no tempo. Os primeiros modelos chuva-vazão surgiram na década de 30. No início estes modelos eram simples e nem sempre capazes de considerar os efeitos não lineares inerentes ao problema (MACHADO, 2011). Esta situação foi solucionada com a chegada do computador que, devido à facilidade de processar um grande número de dados num pequeno intervalo de tempo, possibilitou incorporar as características não lineares do processo nos modelos. Esses foram chamados de modelos conceituais por considerarem, embora de forma simplificada, os processos físicos que ocorrem na bacia hidrográfica. Os principais processos descritos por esses modelos são: precipitação, interceptação, evaporação, infiltração, escoamento superficial e escoamento subterrâneo. Cada um desses processos é avaliado por um algoritmo independente que integrados constituem o modelo chuva-vazão conceitual. Exemplos desses modelos são: o modelo IPHMEN, Sacramento, *Hydrologic Engineering Centers River Analysis System* (HEC-RAS), *Streamflow Synthesis and Reservoir Regulation* (SSARR) e o *Variable Infiltration Capacity* (VIC).

Uma alternativa aos modelos conceituais são os modelos empíricos ou 'caixa preta', como também são conhecidos. Um modelo empírico é definido basicamente por uma equação matemática. A característica principal desse tipo de modelo consiste em estabelecer uma relação estável entre as variáveis de entrada e saída sem considerar neste processo as leis físicas que governam o processo natural de transformação da chuva em vazão (MACHADO, 2005). Exemplos desses modelos são equações lineares e não lineares multivariáveis e Redes Neurais Artificiais (RNA).

JUSTIFICATIVA

A geração de cenários de vazão média mensal para o médio e longo prazo permite analisar os impactos das mudanças climáticas globais sobre os recursos hídricos. Desta maneira, pode-se avaliar, gerenciar e elaborar previsões com certo grau de precisão para os diversos usos da água, como abastecimento, irrigação, geração de energia, além de prever eventos extremos de cheias e períodos de estiagem para o futuro bem como tomar medidas preventivas.

OBJETIVO GERAL

O objetivo geral deste trabalho consiste em verificar o potencial das RNA's em reproduzir o processo chuva-vazão mensal com o uso de cenários de modelos climáticos regionais. Para esta verificação comparou-se as vazões mensais simuladas pelas RNA's com os resultados obtidos por um modelo chuva-vazão conceitual, o modelo VIC.

A análise compreende: um “período histórico” no qual as vazões simuladas são comparadas com vazões observadas e um “período futuro”, onde os resultados dos modelos VIC e RNA são comparados entre si. Para ambos os períodos os modelos RNA e VIC utilizaram precipitações e temperaturas simuladas por RCM's (PROMES e RCA).

OBJETIVOS ESPECÍFICOS

Os objetivos específicos desta pesquisa podem ser divididos em quatro:

- i) treinar e validar uma RNA do tipo *Perceptron* Multicamadas que seja capaz de descrever o processo chuva-vazão em escala mensal. Este treinamento e validação são feitos a partir de dados observados;
- ii) analisar e, caso necessário, corrigir o *bias* das séries de chuva e temperatura simuladas pelos RCM's;
- iii) desenvolver uma rotina computacional para simular uma série de vazões médias mensais utilizando-se das RNA's treinadas;
- iv) verificar a qualidade das séries de vazões simuladas pelas RNA's comparando-as com vazões observadas e vazões simuladas pelo modelo VIC.

1. REVISÃO BIBLIOGRÁFICA

Apresenta-se, neste item, uma breve descrição dos tipos de modelos chuva-vazão e de modelos climáticos regionais (RCM) bem como algumas aplicações. Uma discussão mais profunda sobre os modelos chuva-vazão é apresentada no capítulo 3.

Os modelos chuva-vazão podem ser divididos em dois grupos: os conceituais e os empíricos. Os modelos conceituais são desenvolvidos através de simplificações das leis da física e necessitam de dados (chuva, vazão, evapotranspiração) para calibrar os parâmetros para o local de estudo. Esses parâmetros (exemplo: condutividade do solo, capacidade de infiltração, etc...) variam de acordo com o modelo adotado. Exemplos de modelos chuva-vazão conceituais são: *Variable Infiltration Capacity* (VIC), *IPHMEN* e *Soil Moisture Active Passive* (SMAP).

Já os modelos chuva-vazão empíricos utilizam equações que não possuem relação física com o processo. Esses modelos são calibrados com dados de entrada e saída (precipitação, vazão e evapotranspiração) do processo durante um período chamado de “aprendizagem”. Exemplos desses modelos são técnicas baseadas em Inteligência Artificial (IA): Redes Neurais Artificiais (RNA), *Adaptive Neuro Fuzzy Interference System* (ANFI) e *Gene Expression Programming* (GEP).

Estudos que visam simular as vazões de uma bacia hidrográfica para um período futuro necessitam-se de séries de temperaturas e precipitações para o mesmo período. Essas temperaturas e precipitações futuras são simuladas através dos Modelos de Circulação Global (GCM). Por se tratarem de modelos de escala global, demandam alto processamento computacional e possuem uma resolução baixa. Com objetivo de aumentar a resolução dos resultados, foram desenvolvidas técnicas de *downscaling* que resultaram no surgimento de Modelos Climáticos Regionais (RCM) e métodos estatísticos. As técnicas de *downscaling* são aplicadas diretamente sobre as séries simuladas pelos GMC.

A fim de criar condições para os GCM's representarem o clima futuro, foram definidos cenários para a evolução dos gases de efeito estufa e de aerossóis na atmosfera que vão desde uma redução drástica das emissões,

cenário otimista, a um aumento das emissões, cenário pessimista. Estes cenários foram definidos pelo Painel Intergovernamental de Mudanças Climáticas (IPCC, 2001a). Sua classificação, de modo geral, é A1, A2, B1 e B2, onde cada um deles difere entre si pelo crescimento populacional, uso de tecnologia mais limpa e melhoria da renda das pessoas. Para maiores informações consultar seção 2.1 e IPCC (2001).

Mesmo com o uso de técnicas de *downscaling*, as séries simuladas pelos RCM podem conter *bias* (viés). BERG *et al.*, (2012) apresentam diversos métodos de correção do *bias*, desde simples correções por adições de um fator de escala até correções na equalização dos histogramas. Utilizaram dados de precipitação e temperatura na escala diária, para correção dos dados na escala mensal. TEUSTSCHBEIN e SEIBER, (2012) apresentam uma revisão e avaliação de diferentes métodos para correção do *bias*. Por fim aplicam correções nas séries simuladas pelos RCM e usam um modelo chuva-vazão para estudar os impactos das mudanças climáticas nos regimes fluviais. Os autores concluíram que todos os métodos de correção do *bias* aplicados apresentaram melhora no resultado. WATANABE *et al.*, (2012) apresentam uma comparação de métodos para correção do *bias* para precipitação e temperatura média mensal gerada por doze GCM's diferentes. Neste artigo, utilizaram-se de seis métodos de correção do *bias*, dentre eles um proposto pelos próprios autores. Por fim apresentaram uma discussão e propuseram uma classificação dos métodos em duas categorias: paramétricos e não paramétricos. CHADWICK *et al.*, (2001) utilizaram uma RNA para correção do *bias* das temperaturas e precipitações simuladas por um GCM e compararam com os resultados de um RCM. As entradas utilizadas para a RNA foram: temperatura e precipitação médias mensais simuladas pelo GCM e dados de topografia. Apesar da obtenção de resultados razoáveis, eles encorajam o uso de RNA e sugeriram uma maior atenção ao assunto a fim de se obter um maior "refinamento" das respostas.

1.1 APLICAÇÕES DOS MODELOS DE RNA E VIC

Com o aumento da capacidade computacional, a presença das IA em estudos hidrológicos vem ganhando cada vez mais espaço. A seguir são apresentados alguns exemplos desses estudos.

Utilizando dados diários de vazão e concentração de sedimentos das estações Quebrada Blanca e Rio Valenciano, Porto Rico, KISI (2008) treinou uma RNA para estimar a concentração de sedimentos suspensos. Após o treino, comparou os resultados gerados pelo modelo com os observados e obteve valores de coeficientes de determinação (R^2) entre 0,70 a 0,94.

Outra aplicação das IA em estudos hidrológicos referem-se à previsão do nível das marés. Através de dados horários dos níveis de marés de Darwin Harbor, situados na Austrália, KISI *et al.*, (2013) treinaram uma RNA e uma ANFI. Estas foram comparadas com um Modelo de Médias Móveis Autoegressivo (ARMA) e as conclusões obtidas foram que as IA descreveram melhor o fenômeno em relação aos resultados do modelo ARMA.

SHIRI *et al.*, (2013) criaram um modelo ANFI global que gera dados de evapotranspiração de referência para regiões úmidas e não-úmidas. Os dados de entrada para treinar estes modelos foram precipitação máxima, mínima e média, radiação solar, velocidade do vento na escala diária e umidade relativa de estações localizadas na Espanha e no Irã. Os autores concluíram que os resultados obtidos foram satisfatórios.

Outra aplicação encontrada na literatura é para previsão do nível de água subterrânea. Foram utilizados os modelos GEP, ANFI, RNA e *Support Vector Machine* (SVM) para a previsão do nível da água subterrânea para sete dias. O local de estudo escolhido para este trabalho foi a Coreia do Sul e os dados utilizados foram de precipitação e evapotranspiração no período de 2001 a 2008, sendo que os quatro primeiros anos foram utilizados para o treino e os dois últimos para teste. Depois de treinados, estes modelos foram comparados com o modelo ARMA. Os resultados obtidos por SHIRI *et al.* (2012) mostraram que o melhor modelo foi o GEP.

O uso de modelos empíricos na modelagem do processo de transformação da chuva em vazão também já foi realizado anteriormente.

KISI *et al.*, (2013) modelaram para a bacia de Kurukavak, uma pequena bacia hidrográfica localizada na Turquia, os processos chuva-vazão através dos métodos: RNA, ANFI e GEP. Os dados escolhidos para alimentar os modelos foram de precipitação e vazão diária. O período utilizado para treino foi de quatro anos (1987 a 1991). Em seguida, os autores compararam os resultados obtidos entre os três modelos com regressão multilinear. A conclusão obtida foi que todos os modelos descrevem bem o processo chuva vazão, os valores de R^2 variaram de 0,7 a 0,9, e que o melhor resultado foi obtido com o modelo GEP.

FERREIRA (2012) treinou um modelo de RNA para a transformação chuva-vazão mensal para as sub-bacias: Alto Paranaíba, Baixo Paranaíba, Alto Rio Grande, Baixo Rio Grande, Tietê, Paraná, Paranapanema, Iguçu e Uruguai. Os dados utilizados para o treino foram: precipitação, vazão e evapotranspiração média mensal para o período de janeiro de 1961 a dezembro de 2008. Os resultados obtidos foram considerados satisfatórios para todas as bacias, exceto para os rios Paranapanema e Uruguai, cujos R^2 e o coeficiente de Nash-Sutcliffe (NS) foram respectivamente iguais a 0,61 e 0,35 para o rio Paranapanema e 0,68 e 0,47 para o rio Uruguai.

Diversos autores também já utilizaram o modelo VIC na modelagem do processo de transformação da chuva em vazão.

ZHANG *et al.*, (2012) estudaram a influência da mudança no uso do solo na bacia hidrográfica de Duoyingping localizado no sudoeste da China através do modelo VIC para um período histórico (1980 a 2000) e para um período futuro (até 2030).

MISHRA *et al.* (2011) aplicaram o modelo VIC juntamente com um algoritmo para simular a variabilidade térmica de um lago situado na região dos Grandes Lagos nos Estados Unidos para estudar os efeitos das mudanças climáticas na região. A conclusão deste estudo foi que o aquecimento global está afetando o aumento da evaporação do lago que antes era protegido pela maior presença da cobertura por gelo.

GUO, *et al.*, (2011) utilizaram o modelo VIC, inserindo dados de entrada coletados através de sensoriamento remoto, para simular a vazão diária na Bacia do Lago Poyang. Após comparação dos dados de vazão simulados e os observados, puderam concluir que o modelo VIC comportou-se bem.

BAO *et al.* (2012) fizeram uma projeção hidrológica para o reservatório de Miyun, localizado na China, considerando o impacto das mudanças climáticas globais e as atividades humanas através do modelo VIC. Os dados de entrada para o modelo VIC foram simulados através do modelo climático regional NCAR-CCSM3 (*National Center Atmospheric Research Community Climate Model, version 3.0*) (COLLINS *et al.*, 2005), para os cenários A1, A2 e B2 do IPCC. Apesar dos autores terem utilizado apenas um único GCM, concluíram que os processos hidrológicos são impactados pelas atividades humanas resultando numa diminuição da vazão para a década de 2020 e um aumento para o período de 2050 a 2080 para área de estudo.

No Brasil também há registros de uso do modelo VIC. VICTORIA (2010), avaliou e adaptou o modelo hidrológico VIC para a bacia Amazônica. Neste estudo, o autor dividiu a bacia em cinco sub-bacias: Negro, Madeira, Purus, Japurá e Santo Antônio do Içá. O modelo foi calibrado a partir de vazões mensais do período de 1980 a 1990 e seu funcionamento verificado de 1990 a 2006. O autor relatou que encontrou problemas em simular o ciclo hidrológico nas bacias de Santo Antônio do Içá e Japurá justificando que os dados de temperaturas destas regiões foram subestimados. Apesar de citar dificuldades do modelo para representar a evapotranspiração adequadamente, concluiu que representou bem as vazões.

SAURRAL (2010) utilizou se de séries de diversos GCM's como forçante do modelo VIC. A região estudada foi a bacia do rio da Prata e o objetivo do trabalho foi determinar os erros que as séries de precipitação e vazão apresentam durante as simulações. As séries utilizadas foram precipitação média mensal e temperatura média mensal. Como os resultados não foram satisfatórios, as séries simuladas pelos GCM's passaram por dois métodos de *downscaling* e em seguida foram utilizados como entrada no modelo VIC novamente. Ao comparar os resultados simulados, com e sem o *downscaling*, o autor notou que em ambos os casos houve uma redução da água na bacia hidrográfica. Por fim, o modelo VIC foi simulado para um período futuro, de 2030 a 2070, através dos cenários A1B, A2 e B1. Os resultados obtidos da simulação indicam um aumento das vazões para a região.

Outra análise já feita na literatura é a comparação do desempenho entre modelos chuva-vazão. Há trabalhos que promoveram a comparação entre dois

ou mais modelos conceituais (FRANCHINI e PACCIANI, 1990 e LEE *et al.* 2005), entre dois ou mais modelos empíricos (KISI *et al.*, 2013, KISI *et al.*, 2012) e comparação entre modelos conceituais com empíricos (MACHADO *et al.* 2011 e CARCANO *et al.* 2008).

MACHADO *et al.* (2011) compararam os resultados entre dois modelos chuva-vazão. Os modelos utilizados foram uma RNA, modelo empírico, e o modelo conceitual IPHMEN. A área de estudo foi a bacia do rio Jangada, situada no estado do Paraná. Os autores concluíram que a RNA apresentou melhores coeficientes de desempenho, correlação e Nash-Sutcliffe, que o modelo IPHMEN.

CARCANO *et al.* (2008) também compararam o desempenho de dois modelos chuva-vazão. Em seu trabalho, compararam o desempenho de uma RNA com o modelo híbrido (conceitual/empírico) IHACRES (*Identification of unit Hydrographs And Component flows from Rainfall, Evaporation and Streamflow data*) para vazões diárias. A área de estudo compreendeu duas pequenas bacias hidrográficas situadas no norte ocidental da Itália. Os resultados obtidos revelaram que o modelo de RNA apresentou melhores resultados que o IHACRES, porém quando há carência de dados confiáveis, o modelo híbrido foi melhor.

JU *et al.* (2009) aplicaram uma RNA para modelar o processo chuva-vazão a fim de simular a vazão diária. Para isto os autores dividiram os dados utilizados no estudo em períodos de cheia e períodos de não cheia. Por fim compararam os resultados gerados pela RNA com o modelo Xinanjiang. Apesar da RNA subestimar os picos de vazão, ela apresentou melhores coeficientes de desempenho.

2. CENÁRIOS DE PRECIPITAÇÃO

O aumento dos gases de efeito estufa, a mudança da composição de aerossóis na atmosfera e as mudanças na superfície da Terra estão influenciando o clima no planeta Terra, tanto em escala global como regional IPCC (2001 a e b). Com objetivo de um melhor entendimento dos efeitos das mudanças climáticas em longo prazo, foram desenvolvidos Modelos de Circulação Global (GCM). Estes modelos simulam o comportamento da precipitação e temperatura para um período futuro em escala global. Como estes modelos tem o objetivo de representar um evento em um período futuro, deve-se adotar hipóteses para que o modelo tenha condições de descrever o evento. Um conjunto de hipóteses adotadas caracteriza um cenário. Para o caso dos cenários utilizados em GCM's as hipóteses consideradas são: concentração de gases de efeito estufa, concentração de aerossóis, velocidade do crescimento populacional, índice de desenvolvimento de novas tecnologias e difusão das tecnologias entre nações. Estes cenários foram definidos pelo Painel Intergovernamental de Mudanças Climáticas (IPCC). De forma geral, foram criados quatro enredos para descrever de forma consistente as relações entre as emissões e sua evolução. Nos parágrafos seguintes apresenta-se uma breve descrição de alguns dos cenários criados pelo IPCC (IPCC, 2001 a e b).

O contexto A1 descreve um futuro com um crescimento econômico rápido com um pico de crescimento populacional no meio do século e a introdução de novas técnicas mais eficientes frente ao petróleo. Temas fundamentais são a convergência entre regiões, capacitação e aumento das interações culturais e sociais, com uma redução das diferenças regionais na renda per capita. Dentro do cenário A1 contém uma família de três grupos que descrevem alternativas de uso da tecnologia. O cenário A1F1 representa o uso intensivo de combustíveis fósseis, o A1T o abandono dos combustíveis e o cenário A1B o uso balanceado de ambas as tecnologias.

Já os cenários contidos no contexto A2 descrevem um mundo bastante heterogêneo. Os padrões de fertilidade entre as regiões convergem muito lentamente, o que resulta no aumento contínuo da população. O

desenvolvimento econômico per capita e as mudanças de tecnologias estão mais fragmentados e mais lentos.

O contexto B1 descreve um mundo convergente com a mesma população, o pico do crescimento populacional ocorre no meio do século e em seguida ocorre um decréscimo. Há uma rápida mudança na estrutura econômica em direção a uma economia de serviços e informações, com reduções na quantidade de material e a introdução de tecnologias limpas e utilização eficiente dos recursos. A ênfase está na solução global para a sustentabilidade econômica, social e ambiental.

O contexto B2 descreve um mundo em que a ênfase está em soluções locais para a sustentabilidade econômica, social e ambiental. O crescimento populacional global aumenta continuamente, a uma taxa menor do que A2, níveis intermediários de desenvolvimento econômico e mudança tecnológica menos rápida e mais diversa do que nos cenários A1 e B1.

2.1 MODELOS CLIMÁTICOS

Como já citado, os cenários são utilizados como dados de entrada nos GCM's. Os principais usos dos GCM's são em estudos das características climáticas de larga escala, como a circulação geral atmosférica, oceânica e os regimes subcontinentais de precipitação e temperatura. Estes modelos demandam alto processamento computacional e por esta razão não possuem resoluções menores que 100 km (*grid-scale*).

Para solucionar o problema da escala foram desenvolvidas técnicas de transferência da informação para escalas menores, os chamados métodos de *downscaling*. Os métodos de *downscaling* basicamente podem ser enquadrados em duas vertentes: (a) os modelos dinâmicos regionais, que são modelos numéricos semelhantes aos GCM's, mas com resolução mais alta, usando como condições de contorno o resultado da simulação do GCM; e (b) métodos estatísticos, na maior parte das vezes funções de transferência estatística entre os dados dos campos de larga escala e a variável de interesse na superfície (WILBY *et al.*, 1998). Uma revisão comparando diversos métodos de *downscaling* aplicados à saída dos GCM's é visto em WILBY e WIGLEY (1997) e GIORGI *et al.* (2001).

A ideia de criação de modelos climatológicos regionais, com melhor resolução espacial em relação aos modelos globais, foi inicialmente apresentada em 1989 por uma equipe de pesquisadores liderados por Dickinson, e no mesmo ano, Giorgi e Bates fizeram a primeira simulação para um período futuro de alguns meses, e mais tarde em 1994, Giorgi liderou o grupo de pesquisadores que fez a primeira simulação futura para alguns anos (RUMMUKAINEM *et al.*, 2001).

Os modelos climáticos regionais calculam o estado do tempo em grades com espaçamentos de alguns graus de latitude e longitude, ou algumas dezenas de quilômetros. Estes modelos numéricos, dentre outras utilidades, são extremamente úteis na elaboração da previsão de tempo, principalmente em regiões montanhosas onde, devido aos efeitos da topografia e condições meteorológicas, exibem grande variabilidade espacial (DERECZYNSKI *et al.*, 2010).

Cabe ressaltar que, tanto os GCMs quanto os RCM's, são modelos de previsões e que seus resultados não devem ser considerados como verdades incontestáveis. A função destes modelos é a previsão de possíveis tendências do clima a longo prazo.

2.2 MODELOS CLIMÁTICOS GLOBAIS

Como anteriormente citados, os Modelos Climáticos Globais são modelos matemáticos que descrevem a circulação global atmosférica. São amplamente utilizados em estudos de previsão climática, entendimento do clima e projeções para as mudanças climáticas. Demandam alto processamento computacional e por esta razão seus resultados possuem grande escala.

2.2.1 Modelo LMDZ

O modelo LMDZ (Laboratoire de Météorologie Dynamique Zoom) possui um grid ajustável, desta maneira sua classificação, RCM ou GCM, depende do ajuste do grid. Baseado na resolução numérica das equações primitivas da meteorologia, o modelo climático LMDZ é a quarta versão do modelo de

geração dinâmica (MGC). O modelo usa a coordenada vertical sigma, primeiro, para eliminar a instabilidade condicional quando ocorre a saturação, e, segundo, para levar em consideração a convergência de vapor de água em grande escala e a evaporação da superfície. A variável água líquida de nuvem é uma variável prognóstica do modelo, a qual é calculada considerando os termos fontes e sumidouros. As nuvens criadas por convecção não são consideradas até o momento. A precipitação associada é estratiforme (FRANC, et al., 2005; JOURDAIN et al., 2008). Para maiores detalhes sobre o modelo, consultar HOURDIN et al., (2006).

2.2.2 Modelo ECHAM5

É a quinta versão do modelo da família ECHAM, desenvolvido pelo Max Planck Institute for Meteorology (MPIM). Possui resolução horizontal de 1,9° a 5,6°. O modelo usa a coordenada σ -híbrida para descrever a coordenada vertical. A coordenada σ -híbrida é definida de tal forma que as coordenadas do modelo seguem o terreno na troposfera inferior, mas se tornam pressão na troposfera superior. Os valores dependem da pressão de superfície de cada localização no globo terrestre. Os níveis de pressão variam de até 1 a 10hPa. Para maiores informações sobre o modelo, consultar o manual do modelo (ROECKNER, 2003).

2.3 MODELOS CLIMÁTICOS REGIONAIS

Como já citado, os RCM's são modelos que utilizam como dado de entrada a saída dos GCM's e demandam menor processamento computacional por atuarem em uma região específica do globo. Existem diversos tipos de modelos os quais se diferenciam, de modo geral, pela resolução horizontal, vertical, as equações e simplificações adotadas, o centro de pesquisa que o desenvolveu e a região do globo em que possui melhor desempenho.

2.3.1 Modelo ETA

O modelo regional ETA, inicialmente desenvolvido na Universidade de Belgrado, é utilizado operacionalmente para fornecer previsões de tempo de curto prazo, isto é, de 6h em 6h. Tem uma resolução horizontal de 40 km ou 80 km, com 38 níveis na vertical. O domínio do modelo cobre grande parte da América do Sul. O topo do modelo está posicionado em 50 hPa. Uma das características deste modelo é a utilização da coordenada vertical ETA, que segundo MESINGER (1984), foi criada para reduzir o erro no cálculo da força do gradiente de pressão em modelos que usam coordenadas sigma, portanto, coordenadas que levam em conta a pressão atmosférica e a altura topográfica (BUCHIR, 2012). As variáveis prognosticadas são temperatura, vento horizontal, umidade específica, pressão à superfície, energia cinética turbulenta e hidrometeoros de nuvens (DERECZYNSKI *et al.*, 2010). Para maiores informações sobre o modelo, consultar BLACK (1994).

2.3.2 Modelo REGCM3

Trata-se da terceira geração do modelo RegCM (*Regional Climate Model*), que iniciou seu desenvolvimento na década de 80 pelo NCAR-PSU (*National Center for Atmospheric Research-Pennsylvania State University*), a partir do modelo atmosférico MM4 (*Mesoscale Model version 4*). A componente dinâmica do RegCM3 é semelhante a do MM4, ou seja, é um modelo compressível, com balanço hidrostático, em coordenada vertical sigma e de área limitada em diferenças finitas. A resolução horizontal do modelo é não inferior a 10 km e a vertical pode ser definida entre um valor que varia entre 0 e 1 o que não necessariamente precisa ser espaçado em intervalos iguais.

Os processos de interação solo-planta-atmosfera no RegCM3 são representados através do esquema BATS (*Biosphere-Atmosphere Transfer Scheme*). Este esquema considera a presença de vegetação e a interação com o solo nas trocas turbulentas de momento, energia e vapor de água entre a superfície e a atmosfera. O esquema de transferência radiativa do RegCM3 é o mesmo do CCM3 (*Community Climate Model 3*). Este esquema calcula separadamente as taxas de aquecimento e fluxos na superfície de radiação

solar e no infravermelho sob condições de céu claro e nublado. As contribuições dos gases CO₂, H₂O, O₃ e nuvens estão incluídas nos cálculos de transferência radiativa na banda do infravermelho. Os efeitos do CO₂, H₂O, O₃ e O₂ são considerados para a radiação solar. Esta parametrização inclui ainda os efeitos dos gases de efeito estufa (NO₂, CH₄, CFCs), aerossóis atmosféricos e gelo de nuvem (BUCHIR, 2012). Para maiores informações sobre o modelo RegCM, consultar o manual do usuário (ELGUINDI *et al.*, 2007).

2.3.3 Modelo PROMES

PROMES (*PROgnostic at the MESoscale*) é um modelo paralelo oceano-atmosfera de alta resolução, desenvolvido como um projeto conjunto por pesquisadores das universidades de Castilla-La Mancha e Politécnica de Madrid. Este modelo atmosférico é de área limitada 3D que utiliza a projeção cônica de Lambert, projeção cartográfica em que a superfície da Terra é representada sobre um cone imaginário que está em contato com a esfera em determinado paralelo, para lidar com as coordenadas horizontal e vertical. O modelo tem uma resolução espacial de 25 km a 50 km e 37 níveis para discretização vertical. Suas variáveis prognósticas são: temperatura potencial, pressão à superfície, componentes horizontais do vento, umidade específica, nuvens e chuva (GARRIDO, *et al.*, 2009). Para maiores informações sobre o modelo PROMES, consultar CASTRO *et al.* (1993).

2.3.4 Modelo RCA

O RCA (*Rosby Centre Regional Atmospheric Climate Model*) é um modelo regional de medição do clima baseado no modelo operacional de alta resolução para previsão do clima numa área limitada HIRLAM (*High Resolution Limited Area Model*). Trata-se de um modelo hidrostático com 24 níveis verticais, sendo o mais alto a 10 hPa e se baseia em equações primitivas de ponto de grade, do qual são calculadas as variáveis prognósticas. O RCA fornece cenários climáticos regionais com resolução horizontal de aproximadamente 10 km a 50 km, e as suas variáveis prognósticas são

temperatura, umidade específica, vento horizontal, precipitação e pressão à superfície (RUMMUKAINEM, *et al.*, 2001). Para uma descrição detalhada do modelo, consultar SAMUELSSON *et al.* (2010).

3. MODELOS CHUVA-VAZÃO

Os modelos chuva-vazão podem ser vistos como uma abordagem simplificada dos processos físicos que ocorrem em uma bacia hidrográfica. Os dados de entrada são, em geral, os valores de precipitação, evapotranspiração e vazões de passos de tempo anteriores. Os dados de saída são as vazões para uma dada seção de bacia hidrográfica. Muitos destes modelos são capazes de representar o processo de evaporação, infiltração, percolação da água subterrânea, interceptação, escoamento superficial e escoamento subterrâneo.

O processo chuva vazão é considerado um processo difícil de ser modelado devido a não linearidade do fenômeno e da heterogeneidade das contribuições físicas. Segundo ZHANG e GOVINDARAJU (2000) a complexidade e não linearidade no processo chuva-vazão ocorrem principalmente devido às características de armazenamento, às diferentes capacidades de infiltração e às interações entre os vários componentes do ciclo hidrológico.

Os modelos chuva-vazão de causa e efeito podem ser divididos em dois grandes grupos: modelos empíricos e conceituais.

Modelos empíricos ou “caixa preta” são considerados os modelos que não se baseiam nas leis da física que regem os processos, mas ajustam os valores de entrada aos valores de saída com base em dados observados como o hidrograma unitário. Segundo MACHADO *et al.*, (2011) estes modelos são fáceis de serem aplicados e supostamente mais baratos em relação aos modelos conceituais. Dentre os exemplos deste tipo de modelo, encontram-se as Redes Neurais Artificiais (RNA).

Modelos conceituais são embasados em equações derivadas das leis que governam os processos físicos envolvidos. Segundo MACHADO *et al.* (2011) apesar dos modelos conceituais geralmente apresentarem bons resultados, alguns aspectos são desafiadores. A calibração em muitos casos depende de levantamentos de dados de campo que, em muitos casos, são escassos. Somando-se a isso, utilizam-se de dados médios de parâmetros da bacia. Estas características muitas vezes tornam a implantação do modelo

conceitual difícil e financeiramente mais alta quando comparada aos empíricos. Um exemplo de modelo conceitual é o modelo *Variable Infiltration Capacity (VIC)*.

3.1 MODELO VARIABLE INFILTRATION CAPACITY (VIC)

Inicialmente o modelo VIC foi desenvolvido para descrever processos de transferência vertical de água e energia entre o solo, a vegetação e a atmosfera em modelos de circulação. Posteriormente, desenvolveu-se a capacidade do modelo de representar os fluxos horizontais gerados em cada célula simulada, podendo-se assim, representar as descargas em cada célula.

O modelo divide o solo em três camadas: a superfície ou camada dossel que compreende a superfície do solo até a copa das árvores, a camada 1 e a camada 2. A superfície, ou camada dossel, é descrita por N tipos de cobertura do solo que representam os diferentes tipos de vegetação e o solo exposto. Não há restrições para os tipos de cobertura de solo, mas para maior dinamismo do modelo propõe-se usar N sempre menor que 10 (LIANG e LETTERMAIN., 1994). Os caminhos percorridos pela água no solo (verticais e horizontais) estão apresentados na Figura 1, onde E_1 representa a transpiração na camada 1, E_c a evapotranspiração na camada dossel, E_t a transpiração total, P a precipitação, Q_d o escoamento superficial, Q_b escoamento subsuperficial, W_1^c máxima umidade contida na camada 1 e W_2^c máxima umidade contida na camada 2.

Os tipos de cobertura do solo são caracterizados pelo seu Índice de Área Foliar (IAF), resistência da camada dossel e fração relativa das raízes em cada uma das duas camadas do solo. A evapotranspiração para cada tipo de vegetação é caracterizada pela evaporação potencial juntamente com a resistência da camada dossel, resistência estrutural da transferência da água e as resistências de superfície. Associado a cada classe de cobertura do solo há a camada dossel, camada de solo 1 (camada superior) e a camada de solo 2 (camada inferior). A função da camada de solo superior (camada 1) é representar o comportamento dinâmico da coluna de solo que responde aos eventos de precipitação e a camada 2 (camada inferior) tem a função de representar a lenta variação entre o comportamento da chuva e a umidade no

solo. A camada 2 só responde a chuva quando a camada 1 encontra-se saturada e então pode se separar o escoamento subsuperficial de uma resposta rápida a uma tempestade. As raízes podem encontrar-se apenas na camada 1 ou em ambas as camadas dependendo do tipo de vegetação e solo. Para a classe de solo exposto, não há camada dossel. Na presente forma do modelo, as características do solo são as mesmas para todas as classes de cobertura. O fluxo total do calor latente transferido para atmosfera, calor sensível total, fluxos de calor do solo, a temperatura efetiva na superfície, a vazão superficial total, a vazão subsuperficial total são obtidos somando os valores de todas as classes de cobertura superficial consideradas no modelo.

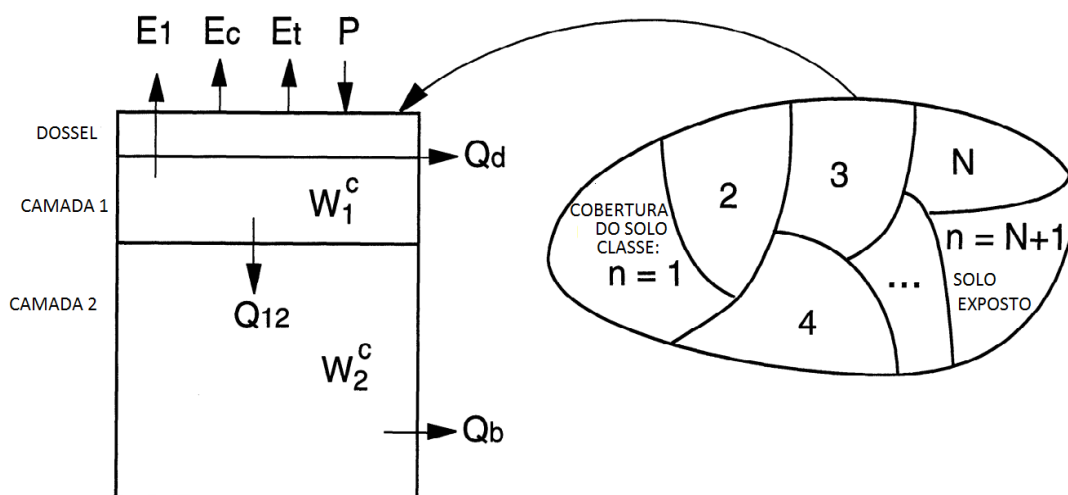


Figura 1 - REPRESENTAÇÃO ESQUEMÁTICA DO MODELO VIC DE DUAS CAMADAS

Fonte: Adaptado de LIANG e LETTERMAIN. (1994)

A principal característica do modelo é a curva de infiltração variável, que determina a máxima velocidade de infiltração da água e o escoamento superficial em cada uma das coberturas vegetais da célula, de acordo com a umidade do solo. Esta curva representa a distribuição estatística da capacidade máxima de armazenamento do solo em cada célula do modelo. Para maiores informações sobre o modelo consultar o Anexo, que é uma tradução de LIANG e LETTERMAIN (1994)

3.2 REDES NEURAIIS ARTIFICIAIS (RNA)

As RNA's foram desenvolvidas baseadas no processo de comunicação entre neurônios presentes no cérebro humano. São constituídas por um conjunto de elementos de processamento conectados entre si. Cada elemento recebe e envia informações de forma semelhante a uma célula neural biológica. Com uma malha muito menor de elementos que o cérebro humano, as RNA's 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).

Os primeiros estudos sobre o cérebro humano e seu funcionamento datam do final do século XIX e início do século XX. Esses estudos, de certa forma, foram a base para conceitos e características das RNA.

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

No fim da década de 50, Frank Rosenblatt (ROSENBLATT, 1958 *apud* HAYKINS, 1994) concebeu a primeira RNA nos mesmos moldes das RNA's 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 definidas por Hebb.

Em 1960, Widrow e Hoff, introduziram o algoritmo Least Mean-Square (LMS) utilizado para formular a RNA *ADALINE* (*Adaptive Linear Element*). Em 1969, Marvin Minsky e Seymour Papert publicaram o livro "PERCEPTRON", no qual apresentaram uma série de críticas às RNA's. Os autores alegaram que,

além de utilizar processos de aproximação empíricos, as RNA's não realizavam algumas operações booleanas. Esta obra impactou seriamente as pesquisas no campo das RNA's diminuindo drasticamente investimentos e programas de pesquisa (HAYKIN, 1994).

Apenas em 1974, Paul Werbos definiu o algoritmo de treinamento *backpropagation* que, em 1986 seria apresentado por Rummelhart, Hinton e Williams. No mesmo ano, o livro *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, escrito por Rummelhart e McClelland, foi publicado. Este livro tornou-se, mais tarde, o de maior influência no uso do método de aprendizado *backpropagation* (HAYKIN, 1994).

3.2.1 Neurônio artificial

O neurônio artificial, também chamado de nó ou unidade de processamento, é o elemento básico que constitui uma RNA (Figura 2).

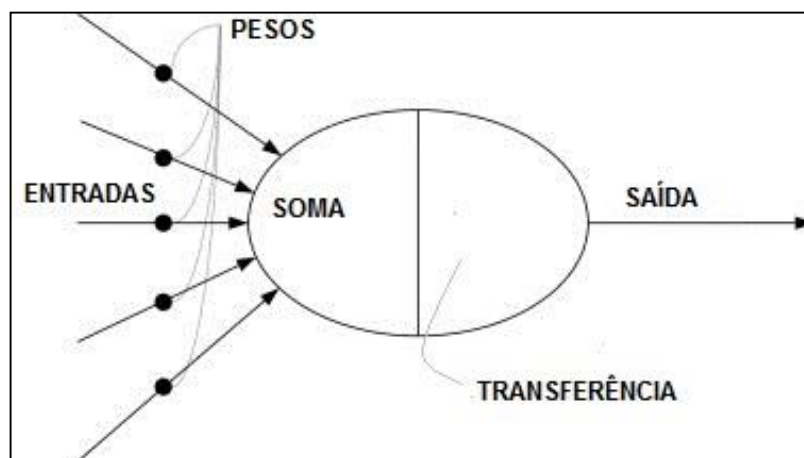


Figura 2 – NEURÔNIO ARTIFICIAL

FONTE: Adaptado KADIR *et al.*, (2009)

Foi concebido de tal forma que simula o mesmo comportamento de um neurônio humano, ou seja, o neurônio artificial recebe estímulos, processa e transmite uma resposta a outros elementos conectados a este. É constituído de três elementos: os pesos, um somatório e uma função de transferência.

O conjunto de pesos são responsáveis por atribuírem à RNA a capacidade de aprendizado. Nos ajustes dos pesos, a RNA possui a

capacidade de adaptação do estímulo a respostas. Com a utilização de pesos, pode-se simular a forma de entrada de dados em uma célula neural biológica. Dada uma matriz de entrada (“N” linhas e p colunas) $\mathbf{X} = [x_{11}, x_{12}, x_{13} \dots x_{1p}; x_{21}, x_{22}, x_{23} \dots x_{2p}; x_{N1}, x_{N21}, x_{N3}, \dots, x_{Np}]$, cada linha da matriz \mathbf{X} é multiplicada pelos pesos $\mathbf{W} (w_1; w_2; \dots w_p; \dots)$.

O somatório é o responsável pelo estímulo que chega à unidade de processamento, somando as correntes eletroquímicas. No neurônio artificial, o somatório é o resultado do produto dos elementos da matriz \mathbf{X} pelos pesos \mathbf{W} , $x_{11} w_1 + x_{12} w_2 + \dots + x_{1p} w_p; x_{21} w_1 + x_{22} w_2 \dots + x_{2p} w_p; x_{N1} w_1 + x_{N2} w_2 \dots + x_{Np} w_p$. Esta operação é conhecida como a combinação linear dos dados de entrada do neurônio.

Função de transferência é considerada a unidade onde ocorre o processamento do estímulo. Ela recebe o estímulo, combinação linear dos dados de entrada, então é aplicada uma função de transferência e por fim o estímulo sai do neurônio. No neurônio, a função de transferência também tem o papel de limitar a amplitude da saída deste estímulo. Normalmente esta saída está no intervalo entre [0,1] ou [-1,1] (HAYKIN, 1994).

Existe também a entrada de um elemento chamado de *bias* (ruído aleatório). Isto significa que à combinação linear deve ser somada a um termo constante “b”. As Equações (1) e (2) descrevem um neurônio j:

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

$$y_{Nj} = \varphi(u_j + b_j) \quad (2)$$

onde:

x_{Ni} : Elementos de entrada da matriz \mathbf{X} ;

w_i : Pesos da matriz \mathbf{W} ;

b_j : *Bias* no neurônio j;

φ : Função transferência;

y_{Nj} : Saída N do neurônio j.

3.2.2 Função transferência

Como já citado, a função transferência (φ) define como será o formato da saída do neurônio. O uso da função transferência em neurônios artificiais permite a RNA identificar relações lineares e não lineares entre as variáveis de entrada e saída. Algumas das funções transferência mais usuais são apresentadas na Figura 3.

Ao analisar a Figura 3 pode-se notar que as funções degrau e rampa possuem ações restritivas para valores extremos, ou seja, ultrapassado certo limite as funções ajustam a saída para -1 ou 1 (degrau) ou 0 e 1 (rampa), estas funções são usualmente utilizadas em RNA's treinadas para resolver problemas de classificação. Já a função sigmóide produz um valor nulo 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), sendo usualmente utilizada para problemas com características não lineares.

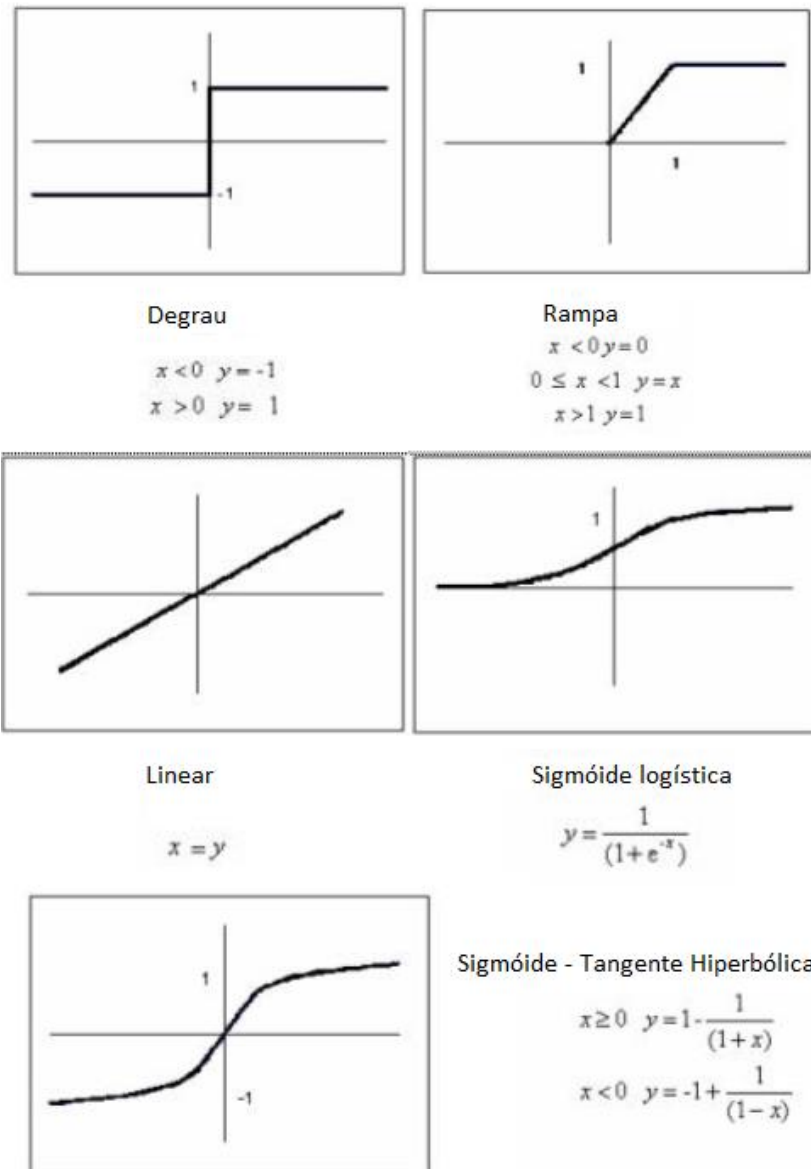


Figura 3 – TIPOS DE FUNÇÕES TRANSFERÊNCIA MAIS COMUNS
 Fonte: Adaptado TAFNER *et al.*, (1996)

3.2.3 RNA do tipo *Perceptron* e *Perceptron* multicamadas

Define-se, de modo geral, uma RNA como sendo a combinação de neurônios. As RNA's do tipo *Perceptron*, consideradas como sendo o modelo mais simples de RNA, foram criadas por Rosenblatt no final da década de 50 e são constituídas por uma ou mais entradas conectadas a um único neurônio na camada de saída (Figura 4). Na saída dos neurônios encontra-se a função de transferência. Ela é utilizada pelas RNA's do tipo *Perceptron* para limitar os valores de saída no intervalo de $[-1, 1]$ ou $[0, 1]$. Entre as conexões encontram-se

pesos que possuem a função de simular o conhecimento da RNA sobre um problema proposto. As RNA's do tipo *Perceptron* são aplicadas, principalmente, na classificação de dados e identificação de padrões (MACHADO, 2005).

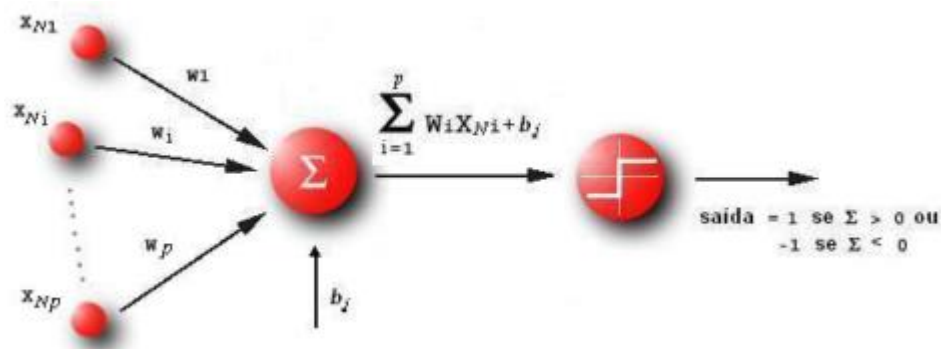


Figura 4 - RNA DO TIPO PERCEPTRON DE UMA CAMADA (PERCEPTRON)

Fonte: Adaptado de WASHINGTON (2004)

Antes de se aplicar uma RNA a um problema prático, ela deve passar por um processo de calibração, também chamado de treinamento. Durante o treinamento é que ocorre o ajuste dos pesos nas RNA's. O treinamento de uma RNA pode ser dividido, de forma geral, em dois tipos: os supervisionados e os não supervisionados.

No treinamento do tipo supervisionado, ou também chamado de treinamento com professor, é apresentado à RNA pares de entrada e a saída desejada. Toda vez que for apresentado à RNA uma entrada, uma saída será calculada e se a diferença entre a saída desejada e a saída calculada for maior que um erro máximo aceitável, os pesos entre as conexões são ajustados. Esta forma de treinamento é a mais utilizada.

Já no treinamento não supervisionado, a RNA analisa os dados apresentados a ela, estima algumas propriedades dos conjuntos de dados e incorpora tais propriedades a sua saída. A RNA utiliza correções, padrões e regularidades para agrupar os conjuntos de dados em classes. As propriedades variam em função do tipo de arquitetura adotada e da lei de aprendizagem adotada. Como exemplo de método de aprendizagem não supervisionada, pode-se citar o mapa auto-organizado de Kohonen (HAYKIN, 1994)

O método utilizado para treinamento das RNA's do tipo Perceptron é o supervisionado. O algoritmo de treinamento do Perceptron sugerido por Widrow e Hoff, também conhecido como regra delta, é apresentado na Equação (3). Neste método inicialmente atribui-se valores aleatórios aos pesos, calcula-se a resposta (saída da RNA) e o erro na saída da RNA. Caso o erro seja maior que o definido previamente, faz-se o ajuste dos pesos proporcionalmente ao erro.

$$w_{ji}(n + 1) = w_{ji}(n) + \Delta w_{ij}(n) \quad (3)$$

onde:

$w_{ji}(n + 1)$: Peso corrigido na conexão ij e iteração (n+1)

$w_{ji}(n)$: Peso na conexão ij e iteração (n)

Com o aumento da capacidade de processamento computacional, pode-se agregar mais neurônios e camadas na RNA do tipo perceptron, caracterizando a chamada RNA do tipo *Perceptron Multicamada (Multilayer Perceptron – MLP)*. A RNA do tipo MLP possui, além de uma camada de entrada, uma ou mais camadas escondidas, também chamadas de camadas intermediárias, e uma camada de saída. Cada um dos neurônios da camada de entrada estão ligados a todos os neurônios contidos na camada intermediária que, por conseguinte, estão ligados a todos os neurônios da próxima camada e assim por diante até a camada de saída. Não há conexões diretas entre neurônios em camadas não vizinhas. Entre todas as conexões são introduzidos pesos. Os processos de treinamento têm o objetivo de minimizar o erro na saída da RNA. A Figura 5 apresenta uma RNA do tipo MLP com uma camada de entrada com n neurônios, uma camada intermediária com dois neurônios e uma camada de saída com um neurônio.

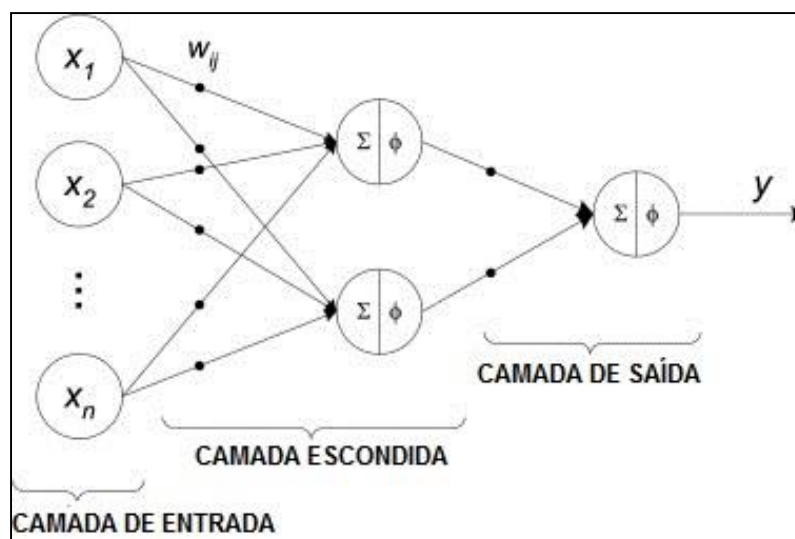


Figura 5 – RNA DO TIPO PERCEPTRON DE TRÊS CAMADAS

Fonte: Adaptado KADIR *et al.*, 2009

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 estimula a função de transferência a emitir uma resposta. Ao contrário das RNA's do tipo *Perceptron*, onde a resposta da função de transferência é considerada a resposta da RNA, na RNA do tipo *Perceptron* Multicamadas a resposta da função de transferência é a entrada para a próxima camada que, por sua vez, pode ser mais uma camada intermediária ou a camada de saída.

O estímulo que chega à camada de saída é a combinação linear das saídas da camada intermediária que passaram por uma função de transferência. A saída da camada de saída é a resposta da RNA.

Para uma RNA do tipo MLP com uma camada de entrada com p neurônios, uma camada escondida com q neurônios, uma camada de saída com 1 neurônio, uma matriz de entrada $X = [x_{11}, x_{12}, x_{13}, \dots; x_{n1}, x_{n2}, x_{n3}]$, um vetor de saídas da RNA $D = [d_0; d_1; d_2; \dots; d_N]$ e um vetor de pesos $W = [w_{j1}, w_{j2}, \dots, w_{ji}, w_{k1}, w_{k2}, \dots, w_{kj}]$ define-se a entrada no neurônio j da camada intermediária através da Equação (4).

$$\sum_{i=1}^p w_{ji}x_{Ni} + b_j = w_{j1}x_{N1} + w_{j2}x_{N2} + \dots + w_{jp}x_{Np} + b_j \quad (4)$$

A saída do neurônio j é a resposta da função de transferência aplicada à combinação linear do neurônio [Equação (5)].

$$\varphi\left(\sum_{i=1}^p w_{ji}x_{Ni} + b_j\right) = \varphi(w_{j1}x_{N1} + w_{j2}x_{N2} + \dots + w_{jp}x_{Np} + b_j) \quad (5)$$

A Equação (5), saída do neurônio j , é a entrada para o neurônio k da camada de saída. Assumindo que existem “ q ” neurônios na camada intermediária a entrada no neurônio k que encontra na camada de saída é dada pela Equação (6).

$$y_{Nk} = \varphi\left(\sum_{i=1}^q w_{ki}y_{Ni} + b_k\right) \quad (6)$$

Substituindo o termo y_{Ni} pela Equação (5) obtém-se a Equação (7), que representa a saída do neurônio k , camada de saída, em função das saídas dos neurônios da camada intermediária:

$$y_{Nk} = \varphi\left(\sum_{i=1}^q w_{ki}\varphi\left(\sum_{i=1}^p w_{ji}y_{Ni} + b_j\right) + b_k\right) \quad (7)$$

A Equação (7) apresenta a saída da RNA em função da matriz de entrada \mathbf{X} e dos vetores pesos \mathbf{W} e pode ser representada como uma função $f(\bar{x}_N, \mathbf{W})$, onde \bar{x}_N é um vetor linha com p elementos da matriz \mathbf{X} . A função $f(\bar{x}_N, \mathbf{W})$ é a forma matemática de uma RNA MLP. Para descrever a forma precisa desta função, necessita-se conhecer a quantidade de camadas e neurônios em cada camada da RNA.

A utilização de uma RNA para solucionar um problema consiste em determinar duas questões: a forma funcional de $f(\bar{x}_N, \mathbf{W})$ e o algoritmo de estimação dos pesos.

FERNANDES *et al.*, (1996) apresentam semelhanças entre as RNA do tipo MLP com modelos estatísticos. O Quadro 1 apresenta a relação entre os termos utilizados em RNA MLP e modelos estatísticos.

A função $f(\bar{x}_N, \mathbf{W})$, estatisticamente analisando, é uma função de regressão a qual ajusta uma relação entre a matriz de entrada \mathbf{X} ao vetor de saída \mathbf{D} . Os elementos constituintes da matriz de entrada \mathbf{X} são abordados como variáveis exógenas e o vetor peso \mathbf{W} como conjunto de parâmetros. A função $f(\bar{x}_N, \mathbf{W})$ representa uma família de curvas. O problema estatístico é obter o estimador ótimo \mathbf{W}^* que minimize o quadrado da soma dos erros, ou seja, o problema consiste em determinar em um universo de curvas a que melhor descreve o problema em questão (Figura 6).

RNA MLP	MODELOS ESTATÍSTICOS
Pesos	Parâmetros
Conjunto de treinamento	Amostras
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

Quadro 1 – RELAÇÃO ENTRE OS TERMOS UTILIZADOS EM ESTATÍSTICA E RNA.

Fonte: FERNANDES *et al.*, (1996)

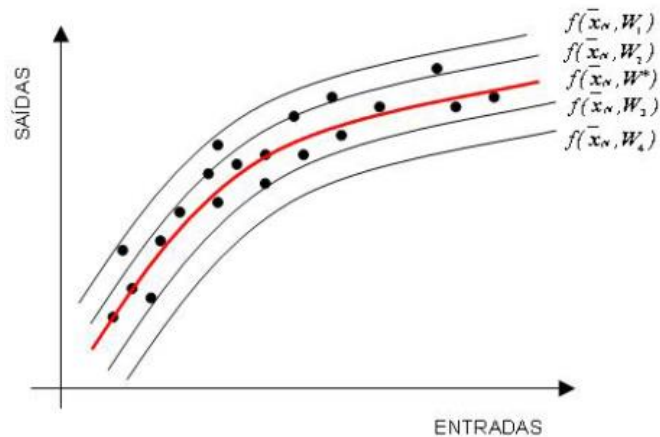


Figura 6 - MELHOR AJUSTE PARA OS PONTOS

Fonte: Adaptado FERNANDES *et al.*, (1996)

3.2.4 Outros modelos de RNA

A RNA do tipo Perceptron mostrada na Figura 4 é uma RNA com apenas duas camadas. Uma camada de entrada e uma camada de saída. Este tipo de estrutura limitava as RNA a apenas resolver problemas linearmente separáveis (Figura 7)




Figura 7 - PROBLEMAS LINEARMENTES SEPARÁVEIS (a) E NÃO LINEARMENTE SEPARÁVEIS (b)

Fonte: HAYKIN (1994)

Em 1982 e 1986, Hopfield e Rummelhart publicaram seus trabalhos propondo outros dois tipos de RNA como alternativa na solução de problemas não-lineares. Hopfield propôs uma RNA cuja arquitetura apresentava todos os neurônios interconectados e o fluxo de dados em todas as direções (*Recurrent-feedback* ou *feedback*). A estrutura da RNA de Hopfield está apresentada na

Figura 8, à esquerda. A título de comparação, a Figura 8 da direita apresenta a RNA proposta por Rumelhart (*Perceptron MLP*) com neurônios dispostos em camadas bem distintas com fluxo de dados numa única direção. FERNANDES *et al.* (1996) e GALVÃO *et al.* (1999) citam que uma RNA de Rumelhart, com um número suficiente de neurônios na camada intermediária e uma função de transferência do tipo sigmóide são ajustáveis a qualquer problema não-linear.

Existem outros tipos de RNA, muitas delas variações das RNA de Rumelhart e Hopfield. Estas RNA podem ser encontradas em MATLAB (2012) e HAYKIN (1994).




Figura 8 – RNA DO TIPO HOPFIELD (ESQUERDA) E RUMMELHART (DIREITA)

Fonte: Adaptado de GORNI (1993)

3.2.5 Ajuste dos pesos

O ajuste dos pesos de uma RNA é baseado na teoria da otimização. Problemas de otimização são caracterizados por uma função objetivo ou também chamada de custo e equações ou inequações de restrições. A função objetivo pode possuir diversas formas como: linear e não linear de uma ou múltiplas variáveis. As funções lineares e não lineares de uma variável são representadas por linhas e curvas no plano (Figura 9) e as funções de múltiplas variáveis são representadas em superfícies com três ou mais dimensões dependendo do número de variáveis independentes (Figura 10). Para o caso em que o número de variáveis independentes é dois a função objetivo é representada em três dimensões, caso se tenha mais que duas variáveis independentes a função objetivo é representada por uma superfície com mais de três dimensões e por essa razão não se pode representá-la graficamente.



Figura 9 – PROBLEMA NÃO LINEAR MONOVARIÁVEL

Fonte: MULLER (1996)




Figura 10 – PROBLEMA NÃO LINEAR MULTI-VARIÁVEL

Fonte: MULLER (1996)

Segundo BRONSON (1985), o método de maior gradiente e o método de Newton-Raphson são técnicas eficazes na solução de problemas de otimização não lineares.

No método de maior gradiente arbitra-se um vetor inicial W_0 e determinam-se os vetores W_1, W_2, \dots, W_M através da Equação (8).

$$W_{n+1} = W_n - \lambda_n^* \nabla \varepsilon|_{W_n} \quad (8)$$

onde:

W_{n+1} : Vetor de coeficientes na iteração “n+1”

W_n : Vetor de coeficientes na iteração “n”

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

$\nabla \varepsilon|_{W_n}$: Gradiente da função objetivo em W_n

A presença de um sinal negativo no segundo termo da direita da Equação (8) indica a descida do gradiente na superfície do erro. Antes de se iniciar o processo de iteração, adota-se um valor de erro máximo aceitável e a parada do método ocorre quando a diferença de dois valores sucessivos de W for menor ou igual ao erro máximo tolerável.

No método de Newton-Raphson, como no método de maior gradiente, escolhe-se um vetor inicial W_0 e definem-se W_1, W_2, \dots, W_M através da Equação (9).

$$W_{n+1} = W_n - (H_{\varepsilon|W_n})^{-1} \nabla \varepsilon|_{W_n} \quad (9)$$

onde:

$H_{\varepsilon|W_n}$: Matriz Hessiana em W_n

A matriz Hessiana é definida como a derivada segunda da função objetivo em relação aos pesos [Equação (10)]:

$$\begin{bmatrix} \frac{\partial^2 \varepsilon}{\delta W_1^2} & \dots & \frac{\partial^2 \varepsilon}{\delta W_1 W_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 \varepsilon}{\delta W_m W_n} & \dots & \frac{\partial^2 \varepsilon}{\delta W_m W_n} \end{bmatrix} \quad (10)$$

O critério de parada é o mesmo para o método de maior gradiente. Dependendo da escolha de W_0 o método pode convergir para um mínimo local ou não convergir. Por esta razão, o método deve ser reinicializado com novos valores para o vetor W_0 .

Como já citado, as técnicas de otimização são utilizadas para solução dos ajustes dos pesos de uma RNA. Supondo uma função objetivo como sendo a Equação (11):

$$MIN \varepsilon = \sum e^2 \quad (11)$$

onde:

ε : Função objetivo;

e : erro.

O erro “ e ” para o caso das RNA pode ser definido através da Equação (12):

$$e = d - f(\bar{x}_N, \mathbf{W}) \quad (12)$$

onde:

d : Saída desejada;

$f(\bar{x}_N, \mathbf{W})$: Saída da RNA para a iteração “n”.

Substituindo (12) em (11), tem-se:

$$MIN \varepsilon = \frac{1}{2} \sum (d - f(\bar{x}_N, \mathbf{W}))^2 \quad (13)$$

Para solucionar este problema existem diversas técnicas consagradas, dentre elas pode-se citar o algoritmo *backpropagation* que se confunde com o gradiente descendente, gradiente descendente com *momentum*, gradiente cascata, Gauss-Newton e Levenberg-Maquardt (MACHADO, 2005). Dentre as técnicas citadas, as de uso mais comum são o algoritmo *backpropagation* ou gradiente descendente e o algoritmo Levenberg-Maquardt.

3.2.5.1 Algoritmo *backpropagation*

O algoritmo *backpropagation* pode ser considerado como uma adaptação dos métodos de otimização para o caso das RNA. Este método foi apresentado por Paul Werbos (1974) *apud HAYKIN (1994)*, porém, ganhou maior destaque com Rummelhart, Hinton e Willians (1986) *apud HAYKIN (1994)*.

Os métodos de otimização convencionais, apresentados na seção anterior, possuem o objetivo de ajustar os coeficientes das variáveis independentes a fim de minimizar o valor do erro entre os valores da regressão e a variável dependente. Neste caso, cada coeficiente está correlacionado a uma única variável dependente e, por esta razão, todas as variáveis têm a mesma responsabilidade sobre o erro.

Para o caso das RNA do tipo MLP, os neurônios estão dispostos em camadas. Devido a esta configuração, os pesos presentes na ligação entre a primeira camada e a camada intermediária possuem relação direta com as

variáveis de entrada da RNA, já os pesos das camadas seguintes estão relacionados com as variáveis modificadas por combinações lineares e pelas funções de transferência. Neste caso, os pesos de diferentes camadas têm responsabilidades desiguais sobre o erro da saída.

O algoritmo *backpropagation* considera esta característica das RNA e corrige o peso entre cada conexão de forma proporcional à responsabilidade que cada neurônio tem sobre o erro na saída da RNA. Matematicamente, o algoritmo fornece um método para obter as primeiras derivadas da função objetivo em relação aos pesos e *bias* de maneira eficiente. 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 gradiente pelo termo λ . No método do maior gradiente [Equação (9)], λ é calculado a cada ajuste a fim de maximizar o direcionamento na direção do mínimo do problema. Já no método do gradiente descendente, o termo λ é substituído por η , taxa de aprendizado, previamente determinado [Equação (14)]. Quanto maior for o valor de η , maior será a taxa de convergência para a solução, porém, aumenta o risco de ultrapassar o ponto de mínimo.

$$W_{n+1} = W_n - \eta \nabla \varepsilon|_{W_n} \quad (14)$$

Ao analisar a Equação (14), forma geral de correções dos pesos para as RNA do tipo MLP, pode-se notar grande semelhança com a Equação (8) onde Δw_{ij} é igual ao termo $\eta \nabla \varepsilon|_{W_n}$.

É apresentado, a seguir, como são calculadas as primeiras derivadas da função objetivo através do método *backpropagation*.

Considerando uma RNA MLP de três camadas p,q e 1 neurônios em cada camada respectivamente o erro do neurônio k contido na camada de saída para uma entrada “N” é calculado através da Equação (15):

$$e_{Nk}(n) = d_{Nk}(n) - y_{Nk}(n) \quad (15)$$

onde:

$e_{Nk}(n)$: Erro na saída da RNA na iteração “n” para uma entrada “N”;

$d_{Nk}(n)$: Saída desejada para entrada “N” na iteração “n”;

$y_{Nk}(n)$: Saída calculada pela RNA para entrada “N” na iteração “n”.

Através da Equação (13), substituindo $y_{Nk}(n)$ no lugar de $f(\bar{x}_N, W)$, e a Equação (15) pode-se obter [Equação (16)]:

$$\varepsilon = \sum e_{Nk}(n)^2 \quad (16)$$

Cabe ressaltar que a função objetivo pode ser representada de outras maneiras. HAYKIN (1994) acrescenta uma constante que multiplica o somatório. Ele justifica o uso desta constante como um simplificador de cálculos. A forma apresentada neste trabalho é a mesma utilizada pelo *software* MATLAB (2012).

A combinação linear das entradas da RNA e sua posterior saída são apresentadas nas Equações (17) e (18), respectivamente:

$$v_{Nk}(n) = \sum_{j=1}^q w_{kj} y_{Nj} + b_k \quad (17)$$

$$y_{Nk}(n) = \phi_k(v_{Nk}(n)) \quad (18)$$

O gradiente para uma função objetivo genérica é dado pela Equação (19):

$$\nabla \varepsilon|_{w_n} = \left[\frac{\partial \varepsilon(n)}{\partial w_{j1}(n)} \frac{\partial \varepsilon(n)}{\partial w_{j2}(n)} \cdots \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \frac{\partial \varepsilon(n)}{\partial w_{jp}(n)} \frac{\partial \varepsilon(n)}{\partial w_{k1}(n)} \frac{\partial \varepsilon(n)}{\partial w_{k2}(n)} \cdots \frac{\partial \varepsilon(n)}{\partial w_{kj}(n)} \frac{\partial \varepsilon(n)}{\partial w_{kq}(n)} \right] |_{w_n} \quad (19)$$

O peso w_{ji} [Equação (19)] representa o peso sináptico conectado a saída do neurônio “i” e a entrada do neurônio “j”.

Através da regra da cadeia o elemento genérico $\frac{\partial \varepsilon(n)}{\partial w_{kj}(n)}$ pode ser expresso através da Equação (20):

$$\frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial w_{kj}(n)} \quad (20)$$

Diferenciando a equação (16) em relação a $e_{Nk}(n)$ obtém-se a Equação (21):

$$\frac{\partial \mathcal{E}(n)}{\partial e_{Nk}(n)} = 2e_{Nk}(n) \quad (21)$$

Diferenciando a Equação (21) em relação a $y_{Nk}(n)$ obtém-se a Equação (22):

$$\frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} = -1 \quad (22)$$

Diferenciando a Equação (18) em relação a $v_{Nk}(n)$ obtém-se a Equação (23):

$$\frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} = \varphi_k'(v_{Nk}(n)) \quad (23)$$

onde:

$\varphi_k'(v_{Nk}(n))$: Derivada parcial de $\varphi_k(v_{Nk}(n))$ em relação a v_{Nk} .

E por fim, diferenciando a Equação (17) em relação a $w_{Nk}(n)$ obtém-se a Equação (24):

$$\frac{\partial v_{Nk}(n)}{\partial w_{kj}(n)} = y_{Nj}(n) \quad (24)$$

Substituindo das Equações (21) a (24) em (20) obtém-se a Equação (25) a seguir:

$$\Delta w_{jk} = w_{jk}(n+1) - w_{jk}(n) = \eta \delta_{Nk}(n) y_{Nk}(n) \quad (25)$$

onde:

$\delta_{Nk}(n)$: Gradiente local

O gradiente local, $\delta_{Nk}(n)$, é definido pela Equação (26):

$$\delta_{Nk}(n) = -\frac{\partial \mathcal{E}(n)}{\partial v_{Nk}(n)} = -\frac{\partial \mathcal{E}(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} = -2e_{Nk}(n) \varphi'(v_{Nk}(n)) \quad (26)$$

Nota-se que para os ajustes dos pesos, Equações (25) e (26), utilizam-se do erro na saída do neurônio k, camada de saída. No caso, o neurônio j, que se encontra na camada intermediária, é o problema deste ajuste, por não compreender o erro existente. Portanto, deve-se reformular o gradiente local (Equação (26)) para Equação (27):

$$\delta_{Nj}(n) = -\frac{\partial \mathcal{E}(n)}{\partial y_{Nj}(n)} \frac{\partial y_{Nj}(n)}{\partial v_{Nj}(n)} = -\frac{\partial \mathcal{E}(n)}{\partial y_{Nj}(n)} \varphi_j'(v_{Nj}(n)) \quad (27)$$

Diferenciando a Equação (16) em relação a $y_{Nj}(n)$ obtém-se a Equação (28):

$$\frac{\partial \mathcal{E}(n)}{\partial y_{Nj}(n)} = 2 \sum_1^N e_{Nk}(n) \frac{\partial e_{Nk}(n)}{\partial y_{Nj}(n)} \quad (28)$$

A derivada parcial $\frac{\partial e_{Nk}(n)}{\partial y_{Nj}(n)}$ pode ser desenvolvida através da regra da cadeia e é apresentada na Equação (29):

$$\frac{\partial e_{Nk}(n)}{\partial y_{Nj}(n)} = \frac{\partial e_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial y_{Nj}(n)} \quad (29)$$

Substituindo (28) em (29) obtém-se [Equação (30)]:

$$\frac{\partial \mathcal{E}(n)}{\partial y_{Nj}(n)} = 2 \sum_1^N e_{Nk}(n) \frac{\partial e_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial y_{Nj}(n)} \quad (30)$$

Das Equações (15) e (18) tem-se (Equação (31)):

$$e_{Nk} = d_{Nk}(n) - \varphi_k(v_{Nk}(n)) \quad (31)$$

Diferenciando a Equação (31) por $v_{Nk}(n)$ obtém-se [Equação (32)]:

$$\frac{\partial e_{Nk}(n)}{\partial v_{Nk}(n)} = -\varphi'_k(v_{Nk}(n)) \quad (32)$$

Diferenciando a Equação (17) pelo termo $y_{Nj}(n)$ obtém-se [Equação (33)]:

$$\frac{\partial v_{Nk}(n)}{\partial y_{Nj}(n)} = w_{kj}(n) \quad (33)$$

Substituindo (32) e (33) em (29) obtém-se a Equação (34):

$$\frac{\partial \mathcal{E}(n)}{\partial y_{Nj}(n)} = -2 \sum_1^N e_{Nk}(n) \varphi'_k(v_{Nk}(n)) w_{kj}(n) = - \sum_1^N \delta_{Nk}(n) w_{kj}(n) \quad (34)$$

Substituindo (34) em (27) obtém-se a equação para o gradiente local nas camadas escondidas [Equação (35)]:

$$\delta_{Nj}(n) = \varphi'_j(v_{Nj}(n)) \sum_1^N \delta_{Nk}(n) w_{kj}(n) \quad (35)$$

Nota-se que fator $\varphi'_j(v_{Nj}(n))$ utilizado para o cálculo do gradiente local $\delta_{Nj}(n)$ na Equação (35) depende apenas da função de transferência do neurônio oculto “j”.

Portanto, o ajuste dos pesos para a camada de entrada e a camada intermediária é feito através da Equação (25) substituindo $\delta_{Nk}(n)$ por $\delta_{Nj}(n)$.

Durante o processo de treinamento os *bias* também são ajustados. Considerando:

$$b_{n+1} = b_n - \eta \nabla \mathcal{E}|_{w_n} \quad (36)$$

$$\frac{\partial \mathcal{E}(n)}{\partial b_k(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_{Nk}(n)} \frac{\partial e_{Nk}(n)}{\partial y_{Nk}(n)} \frac{\partial y_{Nk}(n)}{\partial v_{Nk}(n)} \frac{\partial v_{Nk}(n)}{\partial b_k(n)} \quad (37)$$

Diferenciando a Equação (17) em relação a $b_k(n)$ obtém-se [Equação (38)]:

$$\frac{\partial v_{Nk}(n)}{\partial b_k(n)} = 1 \quad (38)$$

Substituindo as Equações (21), (22), (23) e (38) em (36) obtém-se:

$$\Delta b_j = \eta \delta_{Nk}(n) \quad (39)$$

Os ajustes dos bias contidos nos neurônios da camada intermediária são feitos substituindo δ_{Nk} por δ_{Nj} na Equação (39).

A Figura 11 e a Figura 12 representam o fluxo de dados, respectivamente em *forward* e *backward* de uma RNA com três camadas e um único neurônio na camada de saída.

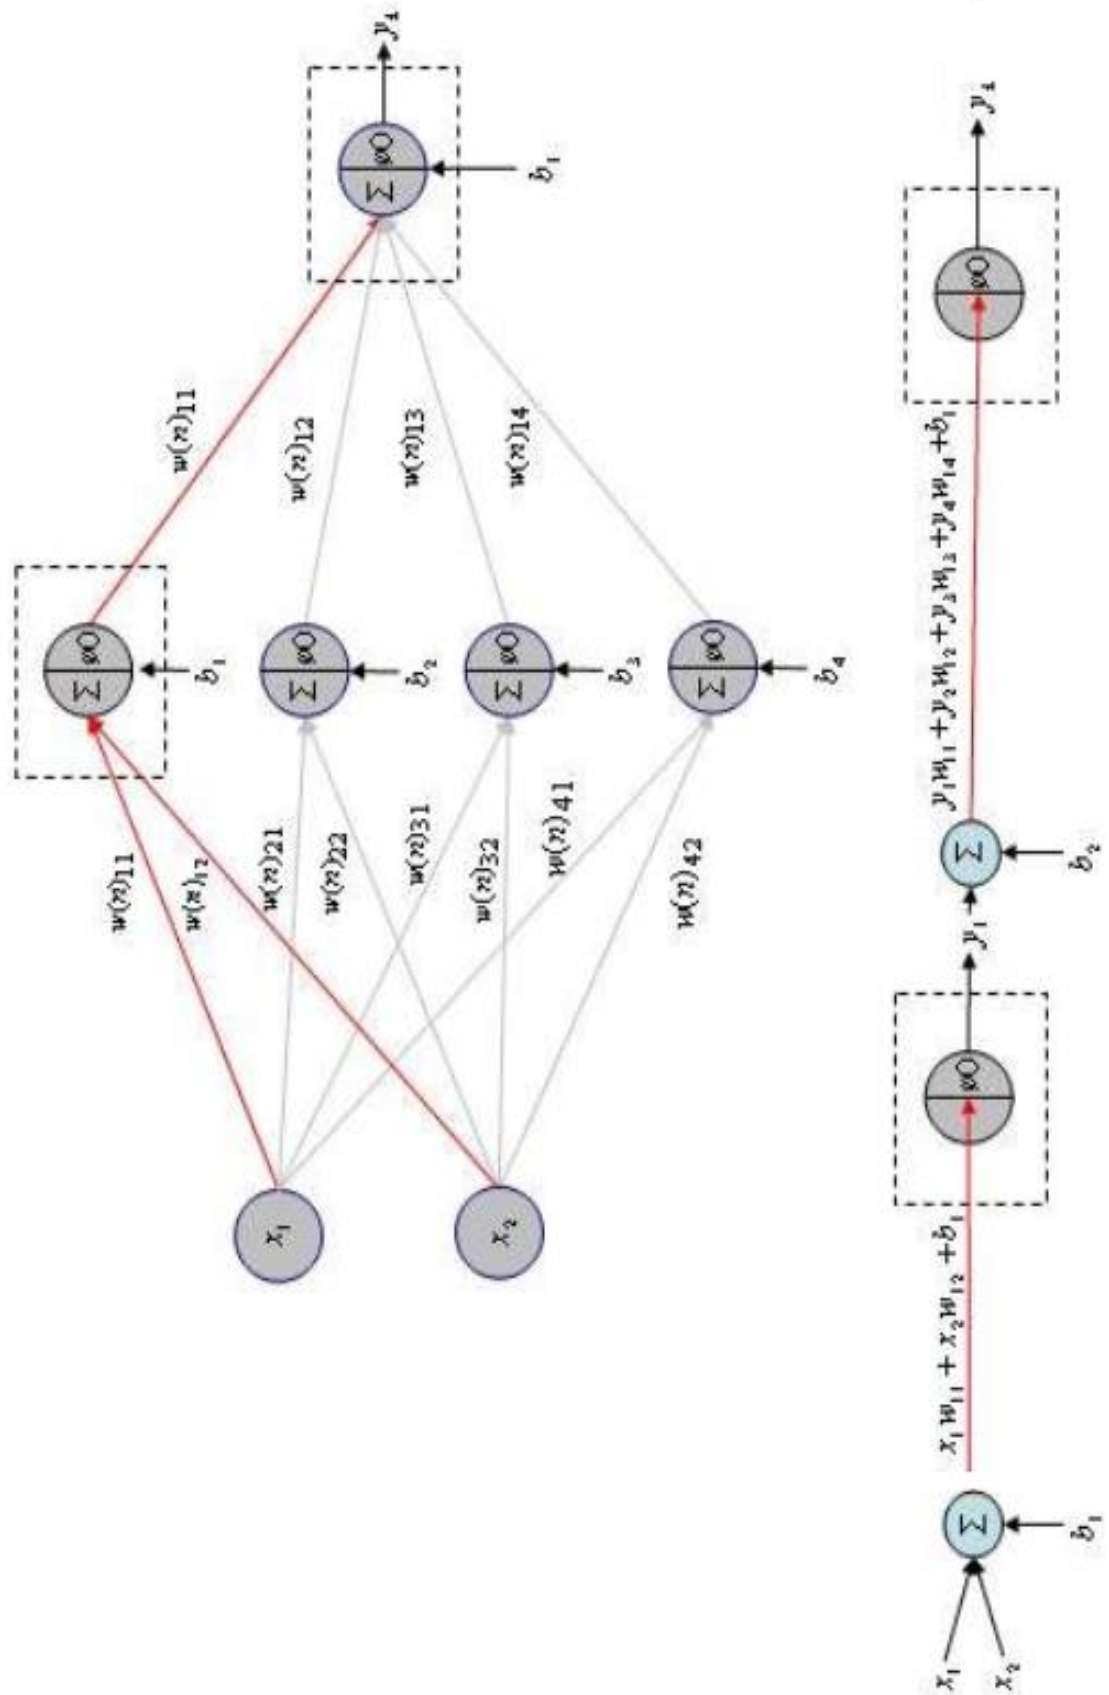


Figura 11 -FLUXO DE DADOS EM FOWARD DE UMA RNA
Fonte: MACHADO (2005)

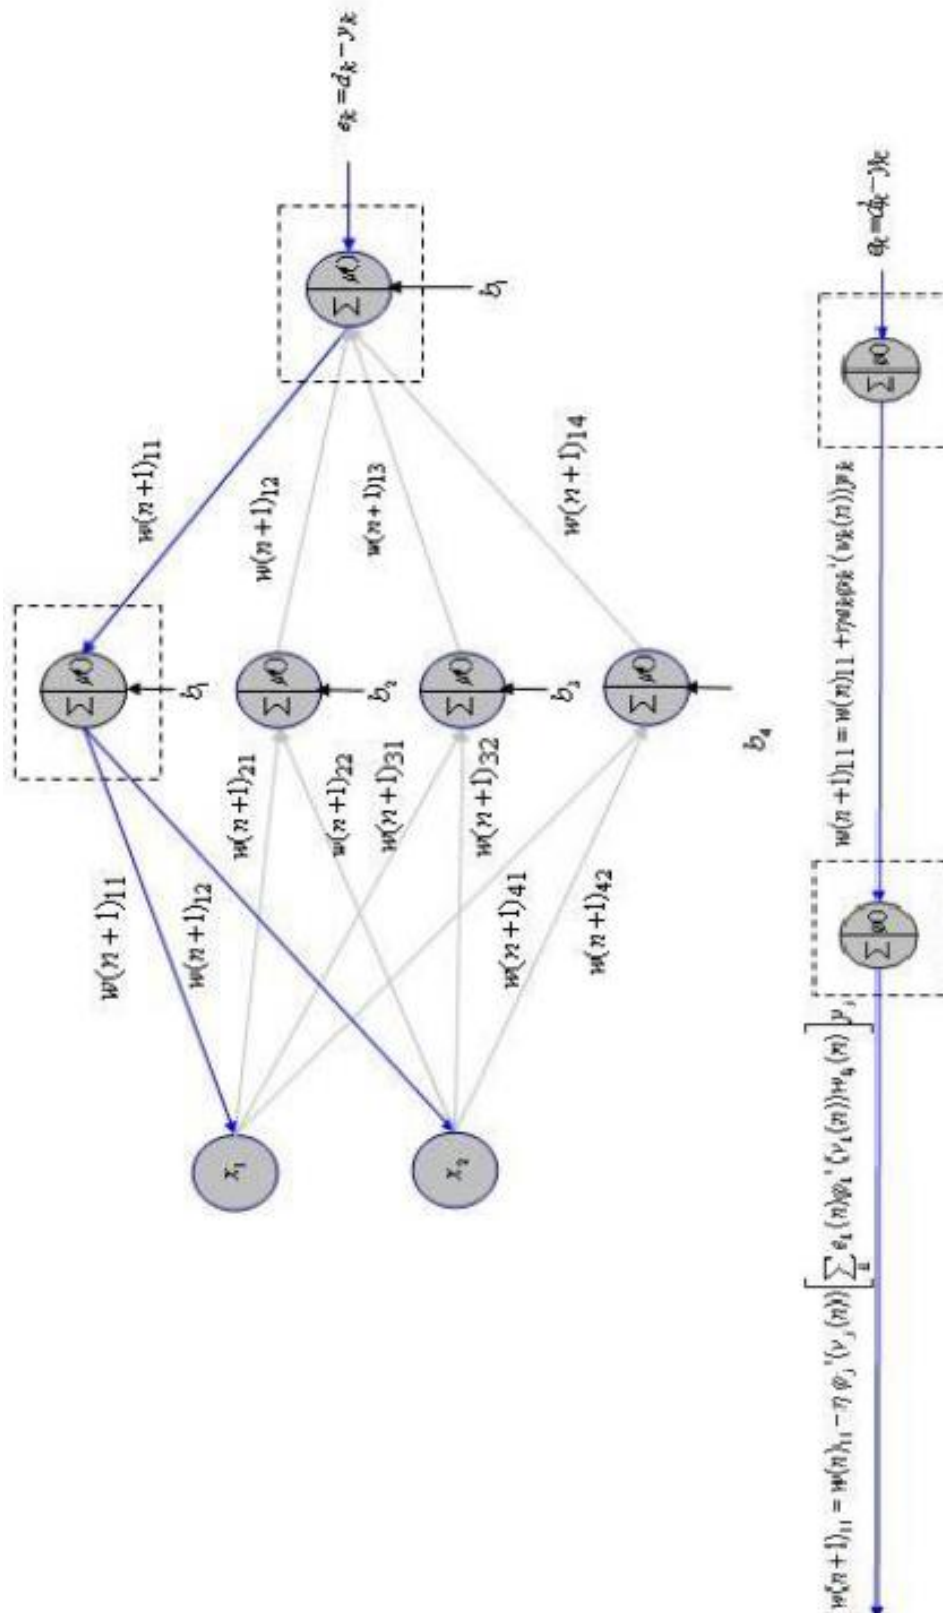


Figura 12 -FLUXO DE DADOS EM *BACKWARD* DE UMA RNA
Fonte: MACHADO (2005)

3.2.5.2 Algoritmo Levenberg-Maquardt

O algoritmo Levenberg-Maquardt é uma extensão do método Newton-Raphson. Para determinação das primeiras e segundas derivadas aplicam-se os mesmos procedimentos que o algoritmo *backpropagation*. Segundo MATLAB (2012) o uso do algoritmo Levenberg-Maquardt torna o ajuste mais rápido e eficiente. O ajuste dos pesos, segundo o método de Newton-Raphson, da função objetivo é dado pela razão entre o vetor gradiente pela matriz Hessiana ou a primeira e a segunda derivada [Equação (40)].

$$\Delta w_{jk} = - \frac{\nabla \mathcal{E}|_{w_n}}{H_{\mathcal{E}}|_{w_n}} \quad (40)$$

onde:

$\nabla \mathcal{E}|_{w_n}$: Vetor gradiente da função objetivo para o ponto w_n ;

$H_{\mathcal{E}}|_{w_n}$: Matriz Hessiana da função objetivo para o ponto w_n .

Para uma função objetivo na forma quadrática, Equação (16), MATLAB (2012) demonstra que:

$$\nabla \mathcal{E}|_{w_n} = J^T(n)e(n) \quad (41)$$

$$H_{\mathcal{E}}|_{w_n} = J^T(n)J(n) \quad (42)$$

onde:

$J^T(n)$: Matriz Jacobiano da função erro em função dos pesos e *bias* da RNA.

Substituindo Equação (41) (42) em (40) tem-se a Equação (43):

$$\Delta w_{jk} = - [J^T(n)J(n)]^{-1}J^T(n)e(n) \quad (43)$$

Para que o método de otimização funcione a matriz resultante do termo entre colchetes da Equação (43) tem que ser definida e positiva para todo o intervalo. Para assegurar esta hipótese utiliza-se do seguinte artifício matemático: adiciona-se uma matriz diagonal $\mu\mathbf{I}$ ao termo entre colchetes da equação (43). Esta adaptação do método de Newton-Raphson é chamado de algoritmo de Levenberg-Maquardt e está apresentado na Equação (44):

$$\Delta w_{jk} = - [\mathbf{J}^T(n)\mathbf{J}(n) + \mu\mathbf{I}]^{-1}\mathbf{J}^T(n)e(n) \quad (44)$$

O fator μ é escolhido no início do processo. À medida que se adota valores mais elevados para μ o termo $[\mathbf{J}^T(n)\mathbf{J}(n)]^{-1}$ da Equação (44) se torna cada vez menos relevante até o momento em que pode ser desconsiderado e o algoritmo se aproxima do método do gradiente descendente com a taxa de aprendizado, η , próximo a $1/\mu$. Para valores pequenos de μ a Equação (44) tende a se aproximar ao método de Newton-Raphson [Equação (43)]. Durante o processo de otimização o valor de μ pode passar por ajustes que dependem da performance da função objetivo. Se entre duas iterações consecutivas o erro aumenta, fato que evidencia uma piora na função objetivo, então o valor de μ é multiplicado por um fator β previamente determinado. Se o desempenho diminui, μ é dividido por β .

A matriz Jacobiana $\mathbf{J}(n)$ é obtida a partir do algoritmo *backpropagation* com algumas modificações. O algoritmo *backpropagation* é utilizado para obtenção da primeira derivada da função objetivo em relação aos pesos e *bias* da RNA. A Equação (45) apresenta uma relação entre a função objetivo e os pesos da RNA:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{kj(n)}} \quad (45)$$

Diferenciando ambos os lados da Equação (16) em relação a $\partial w_{kj(n)}$ obtém-se uma relação direta entre o termo da Equação (45) e as primeiras derivadas do erro [Equação (46)].

$$\frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)} = 2e(n) \frac{\partial e(n)}{\partial w_{kj}(n)} \quad (46)$$

A Matriz Jacobiana do método de Levenberg-Maquardt é obtida calculando-se a derivada parcial da função objetivo em relação aos pesos e *bias* da RNA [Equação (45)] em cada conexão do algoritmo *backpropagation*. Da Equação (46), pode-se obter a primeira derivada do erro em relação aos pesos da RNA [Equação (47)]:

$$\frac{\partial e(n)}{\partial w_{kj}(n)} = \frac{1}{2e(n)} \frac{\partial \mathcal{E}(n)}{\partial w_{kj}(n)} \quad (47)$$

Pode-se obter a derivada parcial do erro em relação ao *bias* da RNA através da mesma maneira [Equação (48)]:

$$\frac{\partial e(n)}{\partial w_{kj}(n)} = \frac{1}{2e(n)} \frac{\partial \mathcal{E}(n)}{\partial b_{kj}(n)} \quad (48)$$

3.2.6 Cuidados para um melhor desempenho de uma RNA MLP

MACHADO (2005) cita que há outros elementos que influenciam no desempenho de uma RNA além da escolha de um dos modelos de otimização para correção dos pesos. Nos tópicos a seguir são apresentados os cuidados relevantes que devem ser tomados para obter um desempenho melhor de uma RNA.

3.2.6.1 Arquitetura

De modo geral, define-se como sendo arquitetura a maneira como os neurônios estão dispostos em uma RNA. Para uma RNA do tipo MLP, o número de camadas e o número de neurônios presentes em cada camada são as variáveis que compõe a arquitetura. Segundo HAYKIN (1994) e GALVÃO (1999), uma RNA do tipo MLP de três camadas é suficiente para aproximar uma função a um conjunto de dados, seja esta função linear ou não linear.

Neste caso, definir qual será a arquitetura de uma RNA consiste em determinar o número de entradas e o número de neurônios na camada intermediária. O número de saídas é consequência do problema proposto.

As entradas de uma RNA são função do tamanho do banco de dados disponível, ou seja, o número de entradas para uma RNA pode ser menor ou igual à extensão do banco de dados. A quantidade de neurônios presentes na camada intermediária é arbitrária, porém sabe-se que uma RNA com poucos neurônios em uma camada intermediária, em geral, não é capaz de se ajustar a um problema proposto. Por outro lado, utilizar-se de muitos neurônios na camada intermediária pode diminuir a capacidade da RNA de generalizar o problema em questão, além de aumentar o tempo gasto para processamento. Por não existir uma regra matemática geral que se determina, de forma eficiente, o número de neurônio na camada intermediária, é comum testar diversos ajustes por tentativa. MACHADO (2011) e FERREIRA (2012) criaram RNA's com 3, 5, 8 e 10 neurônios na camada intermediária e avaliaram o desempenho de cada RNA, baseados nos coeficientes de correlação (R), raiz do erro médio quadrático (RMSE) e Coeficiente de Nash-Sutcliffe (NS).

3.2.6.2 *Epochs*

Representam o número de vezes em que a mesma entrada e saída desejada são apresentadas a uma RNA, ou seja, o número de atualizações dos pesos e viéses de uma RNA. As *epochs* podem ocorrer de duas maneiras distintas: *on-line* e *batch*.

Quando ocorre a epoch tipo *on-line*, diz-se que a RNA opera em modo *on-line*, cada uma das linhas do vetor de entradas X é apresentado a RNA individualmente, os pesos e viéses são atualizados e é registrada uma *epoch*. Já para uma RNA que opera em *batch*, todos os valores do vetor de entrada X são apresentados para a RNA para, em seguida, ocorrer a correção dos pesos e viéses. Cada vez que este processo ocorre é registrado como uma *epoch*. O processo mais comum de atualização de pesos e registro de *epochs* é o *batch*, o mesmo adotado pelo software MATLAB (2012).

Ao analisar o número de *epochs* de maneira crítica, pode-se considerá-lo como o estágio em que se encontra o aprendizado de uma RNA. No início,

os erros são grandes e a RNA é capaz de se ajustar a funções mais simples. À medida que o número de *epochs* aumenta, o erro diminui e, conseqüentemente, aumenta a capacidade da RNA de se ajustar a funções mais complexas. Porém, para grandes valores de *epochs* ocorre o fenômeno chamado de *overfitting*, ou seja, a RNA acaba associando os dados de entrada aos de saída e, por esta razão, diminui a capacidade de generalização do problema.

Portanto, encontrar o número de *epochs* ideal durante o treino de uma RNA está relacionado à capacidade de um RNA generalizar o problema em questão.

3.2.6.3 Inicialização dos pesos

São nos pesos da RNA que o “conhecimento” fica armazenado. Matematicamente, os pesos entre as conexões definem um ponto na superfície da função objetivo. Para o caso dos pesos ótimos, o ponto na superfície deve encontrar-se no mínimo global da superfície. Porém nem sempre os métodos de otimização encaminham a resposta para um mínimo global. Às vezes a solução é encaminhada para um mínimo local. HSU *et al.*, (1995) *apud* MACHADO (2005) citam que as RNA's do tipo MLP geram superfícies muito irregulares e a chance da solução encontrar um mínimo local é alta. A chance aumenta quando o ponto inicial encontra-se próximo a um mínimo local. Portanto a escolha dos pesos está relacionada com a probabilidade da solução encontrar um mínimo local e, por esta razão, aconselha-se a inicialização dos pesos mais de uma vez.

Outro fator que se deve cuidar é a escala dos valores dos pesos. Segundo HAYKIN (1994) pesos iniciais com valores elevados tornam a ação das funções de transferência restritivas e, desta maneira, os gradientes locais assumem valores pequenos e, conseqüentemente, uma aprendizagem mais lenta. Por outro lado, para valores de pesos pequenos, o método de otimização pode operar em uma região muito plana.

3.2.6.4 Normalização

As entradas no neurônio são a combinação linear de todos os sinais de entradas que chegam a este. O resultado desta combinação linear é o estímulo para a função transferência. Todas as funções de transferência apresentam restrições para estímulos extremos, com exceção da função de transferência linear (Figura 3), 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. Na grande maioria dos problemas práticos os estímulos possuem grandeza maior que o intervalo [-1,1]. Portanto, com exceção no caso de uma função de transferência linear, todos os valores de entrada do problema devem passar por um ajuste de escala para que sejam compatíveis com a função transferência utilizada. Este ajuste da escala dos dados é feito através de uma técnica chamada de normalização. As funções de transferência mais utilizadas em modelos chuva-vazão são do tipo sigmóide nos neurônios intermediários e linear nos neurônios presentes na camada de saída. As respostas dos estímulos que passam por uma função de transferência do tipo sigmóide são sempre positivas, coerentes com o fenômeno chuva-vazão. Existem diversas maneiras de normalizar os dados, porém a mais utilizada é apresentada na Equação (49):

$$x_{nor} = V_{min} + \frac{(x - x_{min})}{(x - x_{max})} (V_{máx} - V_{min}) \quad (49)$$

onde:

- x_{nor} : Variável normalizado
- x : Variável que se deseja normalizar
- x_{min} : Menor valor da variável que se deseja normalizar
- x_{max} : Maior valor da variável que se deseja normalizar
- $V_{máx}$: Maior valor para normalização
- V_{min} : Menor valor para normalização

4. MÉTODO

4.1 INTRODUÇÃO

Modelos matemáticos são equações ou conjuntos de equações que relacionam um ou mais estímulos de entrada a uma ou mais saídas. Modelos chuva-vazão são modelos matemáticos que respondem com uma vazão aos estímulos fornecidos. Estes estímulos variam de acordo com o modelo adotado e usualmente são: precipitação, temperatura, evapotranspiração e vazões de passos anteriores de tempo. Juntamente aos estímulos, os parâmetros também são caracterizados como dados de entrada. Representam as características físicas da bacia e geralmente são valores médios de uma característica desta, como por exemplo, área, declividade, uso e tipo de solo e sua respectiva área, capacidade de infiltração e índices de saturação. A saída de um passo de tempo geralmente é usada com entrada no passo de tempo seguinte. Na Figura 13, tem-se fluxograma de um modelo chuva-vazão onde “ $P(t)$ ” representa chuva, “ $EVT(t)$ ” a evapotranspiração e “ $Q(t)$ ” a vazão para o instante de tempo “ t ”.

Aplicar um modelo conceitual a uma bacia consiste em ajustar os parâmetros do modelo conforme as características do local de estudo. Em muitos casos, os parâmetros são ajustados para reproduzir com mínimo de erro um período do passado. Em modelos empíricos, a relação entre precipitação e vazão é determinada pelo ajuste de funções matemáticas arbitrárias que não possuem relação com os processos hídricos. O número de parâmetros depende da função específica que se pretende utilizar como, por exemplo, as RNA's. Aplicar uma RNA na modelagem do processo de transformação da precipitação em vazão consiste em ajustar os pesos e *bias* da RNA. Neste caso, o ajuste dos pesos e *bias* é feito através de técnicas de otimização e não guardam nenhuma relação com as características físicas da bacia (MACHADO, 2005).

O ajuste dos parâmetros pode ser dividido em duas etapas: calibração e validação. Na calibração, os parâmetros são modificados para rodadas sucessivas do modelo. O objetivo é ajustar as respostas do modelo à resposta

da bacia observada. Nesta etapa é apresentada ao modelo uma série com os estímulos e as respectivas respostas. Já na etapa de validação, o objetivo é verificar se os parâmetros ajustados na calibração são capazes de responder com certa precisão a estímulos diferentes daqueles utilizados durante a calibração.

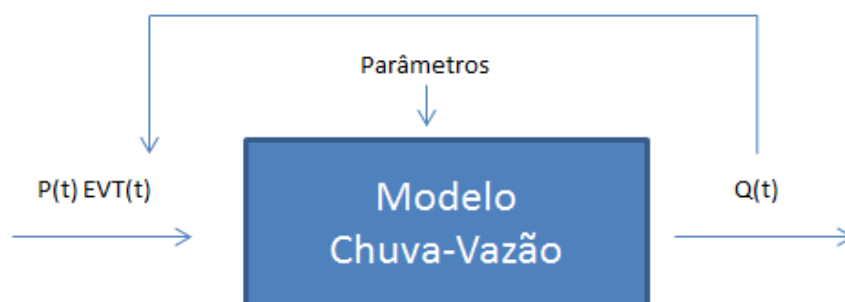


Figura 13 FLUXOGRAMA GERAL MODELO CHUVA-VAZÃO

Fonte: O autor (2014)

Neste trabalho foram calibradas e validadas diversas RNA's a fim de selecionar a melhor opção para cada área de estudo. Os resultados do modelo VIC foram obtidos por SAURRAL (2010) e foram utilizados diretamente nesta pesquisa.

A seguir apresenta-se a metodologia utilizada para criação, calibração (treinamento) e validação das RNA's, bem como, a regra de escolha da melhor RNA para cada região estudada. A metodologia aplicada neste trabalho é a mesma proposta por MACHADO (2005).

4.2 MODELOS

Como o processo chuva-vazão é um processo não linear e a forma funcional para o ajuste deste fenômeno é desconhecido, não basta apenas aplicar uma RNA qualquer e ajustar seus pesos e *bias* à amostra de dados observados. Deve-se investigar, variando a arquitetura da RNA, uma forma funcional mais próxima do comportamento dos dados observados (MACHADO, 2005).

As RNA's 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.

Os modelos são diferenciados pelo 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 o Quadro 2.

MODELO	ENTRADAS	SAÍDA
1	P(t) T(t)	Q(t)
2	P(t) T(t) Q(t-1)	Q(t)
3	P(t-1) P(t) T(t-1) T(t)	Q(t)
4	P(t-1) P(t) T(t-1) T(t) Q(t-1)	Q(t)
5	P(t-2) P(t-1) P(t) T(t-2) T(t-1) T(t)	Q(t)
6	P(t-2) P(t-1) P(t) T(t-2) T(t-1) T(t) Q(t-2) Q(t-1)	Q(t)

Quadro 2 – TIPOS DE MODELOS USADOS NO ESTUDO

Fonte: O autor (2014)

No Quadro 2 “P” representa a precipitação (mm/mês), “T” representa a temperatura (°C) e “Q” a vazão média mensal (m³/s). O termo entre parênteses representa o instante de tempo considerado. Pode-se notar que foram considerados para este estudo, entradas com até dois intervalos de tempo anteriores ao evento.

Para cada modelo apresentado no Quadro 2 foi treinada uma RNA com 3, 5, 8 e 10 neurônios na camada intermediária, totalizando um total de 24 tipos de RNA's.

4.3 TREINAMENTO

Treinar uma RNA significa o mesmo que calibrar o modelo. O ato de treinar uma RNA consiste em ajustar os pesos e *bias* da RNA até que ela atinja um erro aceitável.

Treinar uma RNA consiste em apresentar valores de entrada para a mesma, a partir de um conjunto de séries de entradas e saídas conhecidas. Esta RNA, por sua vez, calcula uma saída e compara com a saída desejada.

Os pesos e *bias* da RNA são ajustados através de um algoritmo de otimização. Este algoritmo calcula os ajustes dos pesos e *bias* através do erro entre a saída calculada e a observada.

Todas as RNA's foram treinadas utilizando o algoritmo de otimização de Levenberg-Maquardt. Seu uso é justificado devido a sua rápida convergência e seu sucesso em aplicações por MACHADO *et al.* (2011), LIMA e FERREIRA FILHO (2003) e SPERB *et al.* (1999). O algoritmo de Levenberg-Maquardt possui dois parâmetros, μ e β , que devem ser definidos antes do processo de treinamento. Os valores adotados foram 0,1 para μ e 10 para β , os mesmos adotados por MACHADO (2005). Antes do treinamento, todas as entradas foram normalizadas através da Equação (49).

Os valores adotados para o valor mínimo (V_{\min}) e máximo (V_{\max}) da normalização foram 0,05 e 0,95 respectivamente. Após a normalização, os dados de entrada também foram sorteados de forma aleatória a fim de se poder contar com dados de períodos distintos na amostra utilizada para o treinamento das RNA's. O processo de sorteio foi feito através de uma função pré-estabelecida no software MATLAB. Durante o treinamento, houve variação do número de *epochs*, inicialização dos pesos e da extensão da série de dados.

Quando se inicia o treinamento de uma RNA é necessário adotar um critério de parada. Este pode ser o erro mínimo desejado ou número de *epochs*. Quando se utiliza o erro mínimo como critério de parada, a série de dados será apresentada a RNA tantas vezes quanto necessário, até que atinja o erro desejado. O número de *epochs* consiste no número de vezes que a amostra é apresentada à RNA.

Neste trabalho o número de *epochs* foi definido como critério de parada, pois é sabido que, no caso de um número excessivo de *epochs*, as RNA memorizam as amostras e perdem a capacidade de generalizar o problema. As 24 RNA's foram treinadas com 30, 60 e 90 *epochs*.

A inicialização dos pesos foi utilizada a fim de evitar que a solução alcance um mínimo local. Os pesos e *bias* das RNA's foram inicializados de 1 a 6 vezes no intervalo $[-1,1]$.

A extensão da série de dados está relacionada com a quantidade de dados utilizados para o treinamento e a validação das RNA's. Neste trabalho

foram definidos três conjuntos de dados. O primeiro com 60 registros para treinamento e 300 para validação, o segundo com 120 registros para treinamento e 240 para validação e o terceiro com 180 para treinamento e 180 para validação. Cabe ressaltar que para os locais onde se obtiveram falhas de medição (ver Tabela 1), a quantidade de dados para treino foi preservada e a quantidade de dados para validação foi diminuída.

A Figura 14 apresenta um diagrama do processo de treinamento e simulação das RNA. Considerando a primeira entrada, a RNA é inicializada com 30, 60 e 90 *epochs*. Ao fim de cada treinamento, a RNA é simulada gerando 3 respostas que são armazenadas juntamente com seus respectivos pesos e *bias*. Os pesos e *bias* são reinicializados e se repete o processo. Ao total são feitas seis reinicializações. Ao fim são geradas 18 (3x6) respostas cada vez que uma dada RNA é treinada utilizando uma entrada em particular. Como todas as RNA's são treinadas usando todas as entradas, cada RNA gera 54 (3x18) respostas totalizando 1296 (24x54) respostas para as 24 RNA's.

Para medir a qualidade dos resultados gerados durante o treinamento e a validação foram calculados o Coeficiente de Nash-Sutcliffe (NS), coeficiente de determinação (R^2) e a diferença percentual entre os volumes observados e os volumes calculados pela RNA (DV).

O coeficiente de Nash-Sutcliffe foi determinado através da Equação (50):

$$NS = 1 - \frac{\sum(Q_{obs} - Q_{cal})^2}{\sum(Q_{obs} - \bar{Q}_{obs})^2} \quad (50)$$

onde:

Q_{obs} : Vazão observada no instante "t".

Q_{cal} : Vazão modelada no instante "t".

\bar{Q}_{obs} : Vazão média observada.

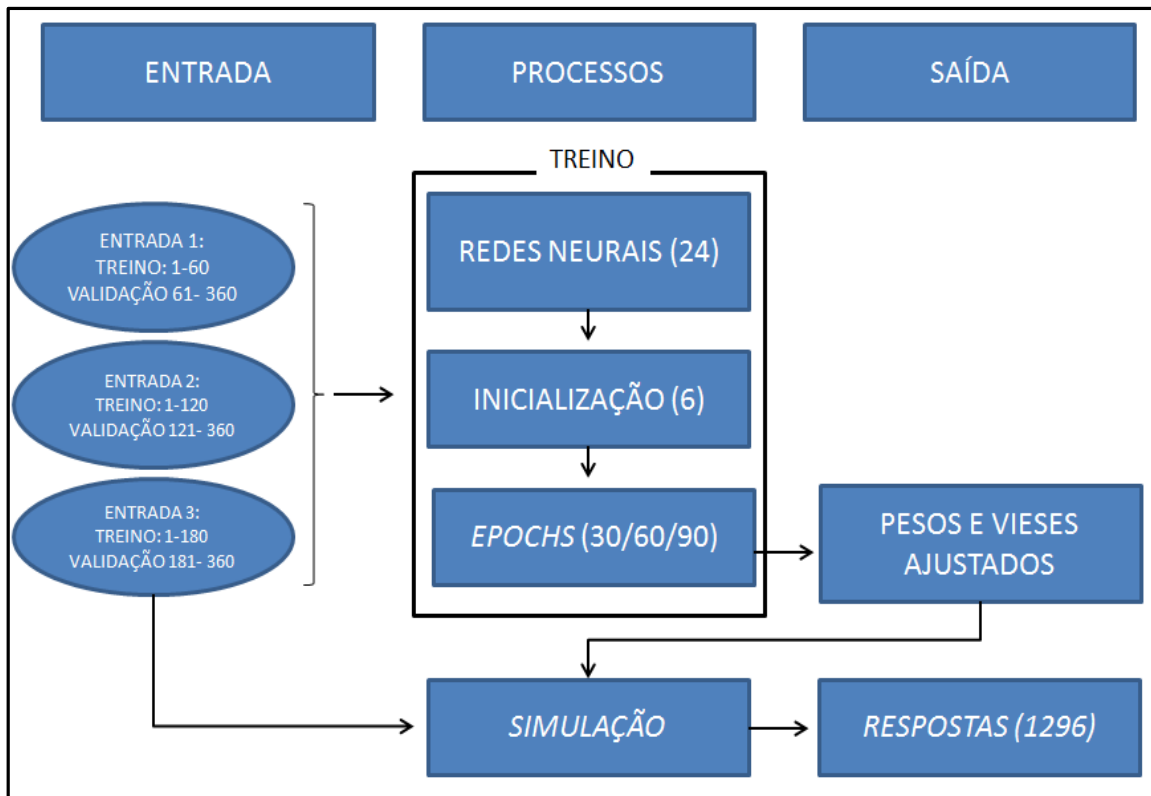


Figura 14 - FLUXOGRAMA DO PROCESSO DE TREINAMENTO E SIMULAÇÃO

FONTE: O autor (2014)

O coeficiente de determinação foi calculado através da Equação (51)

$$R^2 = \left(\frac{\sum((Q_{obs} - \bar{Q}_{obs})(Q_{cal} - \bar{Q}_{cal}))}{\sqrt{\sum(Q_{obs} - \bar{Q}_{obs})^2 \sum(Q_{cal} - \bar{Q}_{cal})^2}} \right)^2 \quad (51)$$

A diferença percentual entre os volumes escoados e os volumes calculados pela RNA foi determinado através da Equação (52)

$$DV = \left(\frac{\sum Q_{obs} - \sum Q_{cal}}{\sum Q_{obs}} \right) * 100 \quad (52)$$

5. ESTUDO DE CASO

Um dos objetivos deste trabalho é comparar as séries de vazões geradas durante o projeto CLARIS LBP com as geradas pelo autor. O projeto CLARIS LPB, concluído em setembro de 2012, foi uma iniciativa envolvendo diversas instituições da América do Sul e da Europa. Teve como objetivo prever os possíveis impactos das mudanças climáticas na Bacia do Rio da Prata. Para tanto foram criados grupos de trabalho entre instituições europeias e sul-americanas para análise de diferentes tipos de impactos. Os resultados de interesse do presente trabalho (séries de vazões e disponibilidade de energia) foram publicados em relatório final (MINE *et al.*, 2009). Os resultados obtidos foram significativos e levaram à formulação de novas metas com enfoque na agricultura, geração de energia elétrica e outros usos dos recursos hídricos na Bacia do Rio da Prata.

As análises das mudanças climáticas foram embasadas nos resultados de modelos climáticos regionais e de chuva-vazão. Simulações da temperatura e precipitação para a região de estudo para o período de 1961 a 2095 foram feitas através de diversos modelos climáticos regionais entre eles o PROMES e o RCA usados neste trabalho. Os resultados destes modelos climáticos regionais (precipitação e temperatura) foram usados como dados de entrada no modelo chuva-vazão VIC. A partir das séries de vazões geradas, em locais estratégicos das diversas sub-bacias, foram feitas análises dos impactos sobre a geração de energia hidrelétrica na Bacia do Rio da Prata por pesquisadores do Departamento de Hidráulica e Saneamento (DHS) da Universidade Federal do Paraná (UFPR).

Neste trabalho foram geradas vazões, através do modelo chuva-vazão RNA, para nove estações chave dentro da Bacia do Rio da Prata que também foram estudadas no projeto CLARIS LPB. Foram geradas duas séries de vazões: a primeira com a série de chuvas e temperatura do modelo PROMES e a segunda com a série de chuvas e temperatura do modelo RCA. Em seguida compararam-se as vazões geradas pelos modelos chuva-vazão VIC e RNA. Esta comparação ocorreu para um período histórico e um futuro. O período histórico representa janeiro de 1991 a dezembro de 2006 e nele foram

comparadas as vazões simuladas pela RNA e VIC com dados observados. Já o período futuro, janeiro de 2007 a dezembro de 2095, foi confrontado as séries de vazões simuladas pelo modelo RNA e VIC.

5.1 ÁREAS DE ESTUDO

As informações aqui apresentadas foram retiradas do relatório parcial 03 de fevereiro de 2010 do projeto CLARIS LPB (MINE *et al.*, 2009).

5.1.1 Bacia do Rio Paraná

A bacia hidrográfica do rio Paraná é de grande importância para o Brasil. Está situada na região de maior desenvolvimento econômico do país, abrangendo uma área de aproximadamente 880.000 km² com cerca de 32% da população nacional.

5.1.1.1 Caracterização geral

Regiões hidrográficas são espaços territoriais que compreendem uma bacia hidrográfica ou um conjunto de bacias com características naturais e socioeconômicas semelhantes. A região hidrográfica do Paraná é uma das doze regiões hidrográficas do Brasil, classificadas pelo Conselho Nacional de Recursos Hídricos (CNRH) e está representada na Figura 15

A região hidrográfica do Paraná ocupa uma área de aproximadamente 880.000 km² (10% do território nacional) e abrange os estados de São Paulo (25% da região), Paraná (21%), Mato Grosso do Sul (20%), Minas Gerais (18%), Goiás (14%), Santa Catarina (1,5%) e Distrito Federal (0,5%). A vazão média na região é de 11.000 m³/s (7% do total do país).

Cerca de 54,5 milhões de pessoas vivem na região (32% da população do país), 90% dos quais vivem em áreas urbanas. A região abriga a cidade mais populosa da América do Sul, São Paulo, com aproximadamente 10,5 milhões de habitantes. As cidades de Brasília (2 milhões de habitantes), Curitiba (1,7 milhão), Goiânia (1,1 milhão), Campinas (969 mil), Campo Grande

(663 mil) e Londrina (500 mil) são também centros populacionais importantes desta região.




Figura 15 - LOCALIZAÇÃO DA BACIA DO RIO PARANÁ

Fonte: O autor (2014)

A maioria da população está concentrada nas sub-bacias do Rio Tietê e Grande que, juntos, respondem por 63% da população total. A densidade populacional da região é de 63,7 habitantes/km², mais alta que a média nacional, que é de aproximadamente 22,4 habitantes/km².

A precipitação média para a região é 1.500 milímetros/ano. A estação das chuvas ocorre entre novembro e fevereiro, e o resto do ano é caracterizado como uma estação seca. A evaporação média anual é de 1.100 milímetros.

O crescimento de centros urbanos no entorno dos rios, como São Paulo, Curitiba e Campinas colocou pressão sobre os corpos hídricos. Enquanto a demanda por água aumenta, a disponibilidade cai, devido à contaminação da água por efluentes domésticos e industriais e de drenagem urbana.

5.1.1.2 Disponibilidade e uso da água

O Rio Paraná é formado pela confluência do Rio Grande, que nasce na Serra da Mantiqueira e corre 1.300 km de leste a oeste, e do Rio Paranaíba,

formado por muitos afluentes, dos quais o mais setentrional é o São Bartolomeu, que se eleva na Serra dos Pirineus, nos arredores de Brasília.

O curso inicial do alto Paraná corre na direção sudoeste até atingir a Serra do Maracaju. Neste trecho inicial, o rio Paraná tem uma série de afluentes em ambas as margens, sendo os mais importantes deles o Tietê, Paranapanema e Iguaçu, todos na margem esquerda.

A Região Hidrográfica do Paraná é dividida em nove sub-bacias hidrográficas: Grande, Iguaçu, Paranapanema, Tietê, Rio Grande, Paranaíba, Verde / Peixe. A Figura 16 apresenta a bacia do rio Paraná e suas principais sub-bacias.

O Rio Paraná, em território brasileiro até a foz do rio Iguaçu, registra uma taxa de vazão média de 11.000 m³/s (7% do total nacional) e uma taxa de descarga específica de 13 L/s/km². Com exceção da sub-bacia do Iguaçu (21,8 L/s/km²), todas as outras sub-bacias registram taxas de vazão específicas de 9 a 16 L/s/km², indicando que a disponibilidade de água é relativamente bem distribuída ao longo da região hidrográfica.

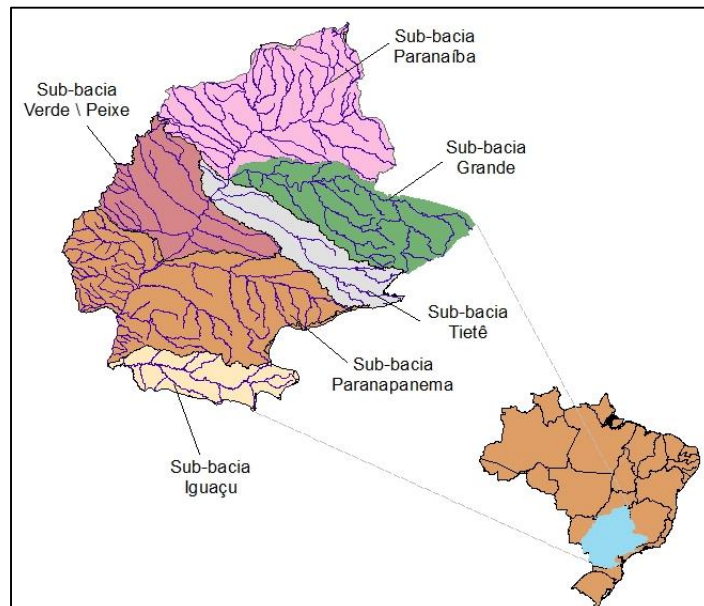


Figura 16 - BACIA DO RIO PARANÁ E SUAS PRINCIPAIS SUB-BACIAS

Fonte: O autor (2014)

5.1.2 Bacia do Rio Uruguai

A Região Hidrográfica do Uruguai é de grande importância para o país, devido à sua contribuição agro-industrial e seu potencial hidrelétrico. Em conjunto com a bacia do Rio Paraná e o Paraguai, formam a região da bacia da Prata. A Figura 17 apresenta a localização da Bacia do rio Uruguai dentro do Brasil.



Figura 17 - LOCALIZAÇÃO DA BACIA DO RIO URUGUAI

Fonte: O autor (2014)

5.1.2.1 Caracterização geral

A parte brasileira da Bacia Hidrográfica do Rio Uruguai cobre aproximadamente 177.500 km² (2,1% do país) e tem uma vazão média de 4.150 m³ /s. A área total da bacia do Rio Uruguai é 385.000 km², 46% localizado em território brasileiro. O Rio Uruguai possui uma extensão de 2.200 km, com origem na confluência dos rios Pelotas e Peixe e correndo na direção leste-oeste, dividindo os estados do Rio Grande do Sul e Santa Catarina. A bacia hidrográfica abrange partes do estado do Rio Grande do Sul (74%) e Santa Catarina (26%).

Devido às suas características hidrológicas, os principais rios que formam esta bacia foram divididos em sete sub-bacias: Canoas (15,007 km² -

8% da região), Pelotas (13,710 km² - 8% da região), Peixe (12,664 km² - 7% da região), Chapecó (21,137 km² - 12% da região), Várzea (26,069 km² - 15% da região), Piratinim / Ijuí / Icamaguã (27,718 km² - 16% da região) e Ibicuí / Quaraí / Negro (61,189 km² - 16% da região). A Figura 18 apresenta um mapa da bacia hidrográfica do Rio do Uruguai e suas principais sub-bacias. Aproximadamente 3,8 milhões de pessoas vivem na região brasileira da bacia hidrográfica do Uruguai, com as principais concentrações populacionais situadas em: Chapecó (21,0%), Várzea (20,1%) e sub-bacias do Rio Ibicuí / Quaraí / Negro (14,1%). A população urbana representa 68,2% do total. A densidade populacional é 21,6 habitantes/km². A região possui um total de 337 municípios, dos quais os seguintes devem ser destacados: Lages e Chapecó, em Santa Catarina e Erechim, Ijuí, Uruguaiana, Santana do Livramento e Bagé, no Rio Grande do Sul.

O clima da região é temperado, com chuvas distribuídas ao longo do ano, embora seja mais elevada no mês de inverno (maio a setembro). Precipitação anual da região é de 1.800 milímetros e temperatura anual média varia entre 16 e 20°C. A evapotranspiração é de aproximadamente de 1.047mm.

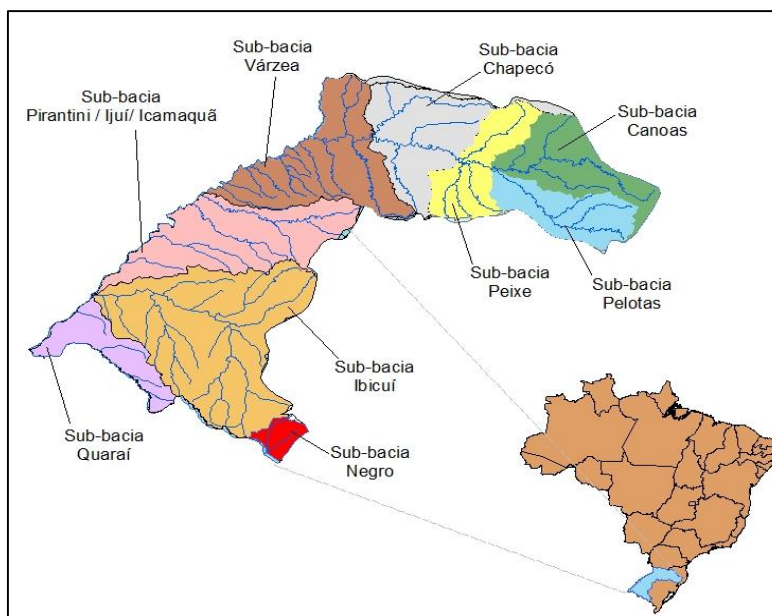


Figura 18- BACIA HIDROGRÁFICA DO RIO URUGUAI E SUAS PRINCIPAIS SUB-BACIAS

Fonte: O autor (2014).

5.1.2.2 Disponibilidade de água e uso

A Bacia do Rio Uruguai é formada pela confluência dos rios Pelotas e Canoas. Todos os seus afluentes são perenes. Alguns de seus afluentes mais importantes são Chapecó e Peixe na margem direita e Várzea, Piratinim e Ijuí na margem esquerda.

A vazão média anual da região hidrográfica do Uruguai é 4.150 m³/s, o que corresponde a 2% dos recursos hídricos do país disponíveis.

Sua descarga específica média é alta (23 l/s/km²), com pouca variação entre sub-regiões.

A região hidrográfica do Uruguai (no contexto dos múltiplos usos dos recursos hídricos) tem um grande potencial hidrelétrico com uma capacidade de produção total de 40,5 kW/km² quando se considera tanto a parte brasileira quanto a argentina. Esta é uma das proporções mais altas de energia do mundo, o que representa um potencial absoluto de 16.500 MW, dos quais apenas 3.995 MW (cerca de 6% da energia produzida no Brasil) são exploradas. O potencial do Brasil de geração hidrelétrica instalada atual é 1.536 MW, de Passo Fundo (221 MW) e Itá (1.315 MW), sendo dois dos principais produtores. Isso representa 38% do potencial total instalado do lado brasileiro da região hidrográfica e apenas 9% do potencial total da bacia. Várias pequenas instalações hidrelétricas de até 7 MW de capacidade estão espalhadas por toda a região. A barragem São Marcos na sub-bacia do Quaraí merece uma menção especial por ser atualmente a maior construção utilizada para irrigação.

A navegação fluvial na região é praticamente inexistente, devido ao terreno irregular, desníveis concentrados, e problemas de assoreamento.

6. DADOS

Os dados utilizados neste estudo foram: precipitação, temperatura e vazão e foram classificados em três grupos: “série histórica para treino e validação do modelo”, “série histórica” e “série futura”. A “série histórica para treino e validação do modelo” compreende o período de janeiro de 1961 a dezembro de 1990 e foi usada para treino e validação da RNA. A “série histórica” compreende o período de janeiro de 1961 a dezembro de 2006 e foi utilizada para comparar os resultados dos modelos (RNA e VIC) com os dados observados. A “série futura” compreende o período de janeiro de 2007 a dezembro de 2095 e apenas foi confrontado os resultados dos modelos (RNA e VIC)

	BACIA HIDROGRÁFICA	ESTAÇÃO FLUVIOMÉTRICA	ESTAÇÃO PLUVIOMÉTRICA	ESTAÇÃO METEOROLÓGICA
1-	Alto Paranaíba	Emborcação	Monte Carmelo	Goiânia
2-	Baixo Paranaíba	São Simão	Monte Alegre de Minas	Catalão
3-	Alto Rio Grande	Furnas	Franca	Franca
4-	Baixo Rio Grande	Água Vermelha	Usina Couro do Cervo	Lavras
5-	Tietê	Nova Avanhandava	Fazenda Barreirinho	Catanduva
6-	Parapanema	Capivara	Tomazina	Castro
7-	Paraná	Itaipu	Caiuá	Presidente Prudente
8-	Iguaçu	Salto Osório	União da Vitória	Curitiba
9-	Uruguai	Itá	Lagoa Vermelha	Lajes

Quadro 3 – LOCAIS DE ESTUDO E SUAS ESTAÇÕES SELECIONADAS
Fonte: Projeto MINE *et al.* (2009)

As séries históricas observadas foram cedidas pelo Operador Nacional do Sistema (ONS) e pelo Instituto Nacional de Meteorologia (INMET).

O Quadro 3 apresenta as nove bacias hidrográficas estudadas e as suas respectivas estações fluviométricas, pluviométricas e meteorológicas. Cabe ressaltar que as séries geradas pelos modelos RCA e PROMES foram simuladas para os mesmos locais das observadas.

6.1 ESTAÇÕES FLUVIOMÉTRICAS

A Figura 19 apresenta a localização das estações fluviométricas e o Quadro 4 apresenta suas características.

CÓDIGO	NOME	COORDENADAS			ÁREA DE DRENAGEM (km ²)
		LAT	LONG	ALTITUDE (m)	
-	-				-
61660000	Furnas	-20:40:00	-46:18:00	768	52.138
62148500	Água Vermelha	-23:32:00	-46:20:00	380	139.437
65895002	Salto Osório	-25:32:14	-53:00:32	380	45.769
64902080	Itaipu	-25:24:27	-54:35:14	150	822.150
60160080	Emborcação	-18:26:54	-47:59:05	530	29.050
62829580	Nova Avanhandava	-21:07:00	-50:12:06	336	62.300
73200080	Itá	-27:16:01	-52:22:53	370	44.118
60877080	São Simão	-19:00:55	-50:29:35	-	17.1474
64516080	Capivara	-22:39:37	-51:21:29	339	84.715

Quadro 4 - ESTAÇÕES FLUVIOMÉTRICAS

Fonte: Projeto MINE *et al.* (2009)

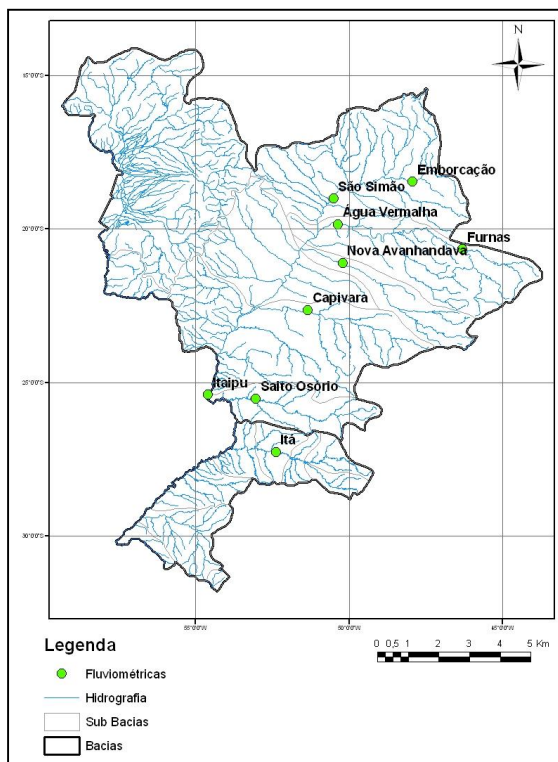


Figura 19 – LOCALIZAÇÃO DAS ESTAÇÕES FLUVIOMÉTRICAS

Fonte: Projeto MINE *et al.* (2009)

6.2 ESTAÇÕES PLUVIOMÉTRICAS

A Figura 20 apresenta a localização e o Quadro 5 as características das estações pluviométricas.

BACIA HIDROGRÁFICA	CÓDIGO	NOME	COORDENADAS		ALTITUDE
			LAT	LONG	
Alto Paranaíba	01847000	Monte Carmelo	-18:43:14	-47:31:28	880
Baixo Paranaíba	01848000	Monte Alegre de Minas	-18:52:20	-48:52:10	730
Alto Grande	02145007	Usina Couro do Cervo	-21:20:37	-45:10:13	813
Baixo Grande	02047017	Franca	-20:31:0	-47:24:0	1020
Tietê	02148128	Fazenda Barreirinho	-21:54:0	-49:0:0	450
Parapanema	02349033	Tomazina	-23:46:0	-49:57:0	483
Iguaçu	02651000	União da Vitória	-26:13:41	-51:4:49	736
Uruguai	02851014	Lagoa Vermelha	-28:13:19	-51:30:45	842
Paraná	02151035	Caiuá	-21:50:0	-51:59:0	350

Quadro 5 - ESTAÇÕES PLUVIOMÉTRICAS
Fonte: MINE *et al.* (2009)

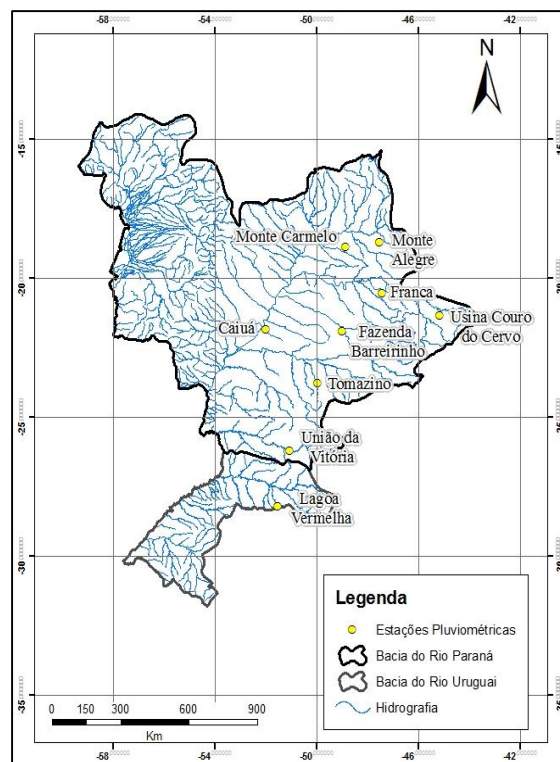


Figura 20 – LOCALIZAÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS
Fonte: MINE *et al.* (2009)

6.3 ESTAÇÕES METEOROLÓGICAS

A Figura 21 apresenta a localização e o Quadro 6 as características das estações meteorológicas.

NOME	ESTADO	BACIA	COORDENADAS		ALTITUDE (m)
			LAT	LONG	
Catalão	Goiás	Alto Paranaíba	-18.10°	-47.57°	840
Goiânia	Goiás	Baixo Paranaíba	-16.40°	-49.15°	740
Lavras	Minas Gerais	Alto Grande	-21.14	-45.00°	920
Franca	São Paulo	Baixo Grande	-20.33°	-47.26°	1026
Catanduva	São Paulo	Tietê	-21.80°	-48.58°	536
Castro	Paraná	Parapanema	-24.47°	-50.00°	1009
Curitiba	Paraná	Iguaçu	-25.43°	-49.27°	923
Lages	Santa Catarina	Uruguai	-27.82°	-50.33°	937
Presidente Prudente	São Paulo	Paraná	-22.70°	-51.23°	435

Quadro 6- ESTAÇÕES METEOROLÓGICAS

Fonte: MINE *et al.* (2009)

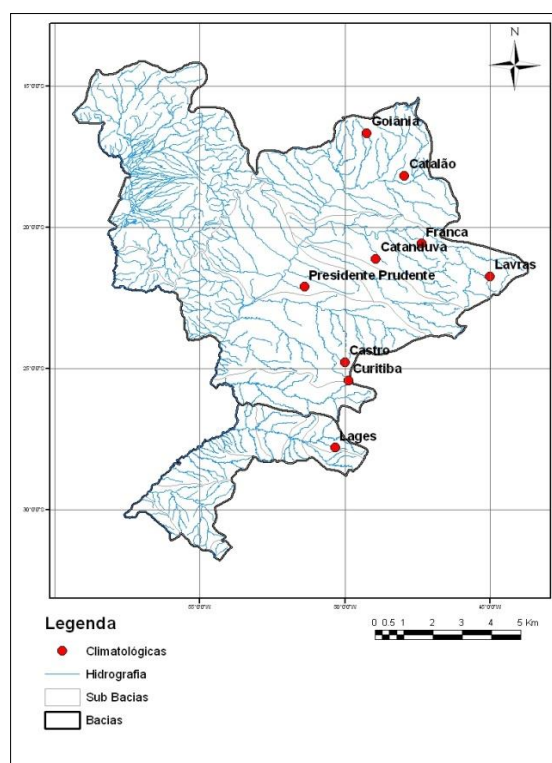


Figura 21 – LOCALIZAÇÃO DAS ESTAÇÕES METEOROLÓGICAS

Fonte: MINE *et al.* (2009)

6.4 CENÁRIOS DE PRECIPITAÇÃO E TEMPERATURA

Como dito anteriormente, as previsões climáticas feitas para longo prazo precisam se pautar na escolha de um cenário futuro e modelos climáticos. Este trabalho compartilhou com o projeto CLARIS LPB as mesmas séries de precipitações e temperaturas futuras. A série simulada pelo PROMES utilizou o GCM HadCM3 e o cenário A1B. Já a série simulada pelo RCA utilizou o GCM ECHAM5 e o cenário A1B.

6.5 ANÁLISE ESTATÍSTICA DE CENÁRIOS DE PRECIPITAÇÃO

Em geral, os modelos matemáticos são uma simplificação do sistema que ele representa e, por conseguinte, seus resultados podem conter erros. Por esta razão, aconselha-se que os resultados simulados por modelos devam ser comparados com valores observados do fenômeno a fim de se avaliar a sua qualidade. Caso sejam encontrados erros acima de um limite tolerável deve-se fazer correções. Estas correções podem ser feitas nos parâmetros/ajustes dos modelos ou diretamente nas séries geradas. A escolha do tipo de correção está condicionada à disponibilidade de acesso ao modelo.

A análise da qualidade da série gerada compreende um estudo com objetivo de investigar algum tipo de comportamento tendencioso das séries simuladas pelos modelos RCM's. Para as séries simuladas de precipitação pelos modelos PROMES e RCA foram feitas as seguintes análises estatísticas: histogramas, polígonos de frequência, curvas de permanência, além de uma análise de frequência empírica de precipitações máximas e mínimas.

6.5.1 Método da análise de dados

Devido ao comportamento hidrológico diferenciado das vazões nas regiões Sul e Sudeste do Brasil, apresentou-se, na Figura 22, as estações pluviométricas divididas por regiões geográficas.

Procedeu-se a um estudo de frequências das chuvas observadas nas estações apresentadas na Figura 22 e as simuladas pelos modelos climáticos regionais PROMES e RCA nos mesmos locais. Para este estudo foram elaborados histogramas de frequência e polígonos de frequência para as nove estações. Primeiramente as precipitações mensais foram agrupadas em classes e para cada classe foi determinada a frequência. O número de classes foi determinado pela Equação (53) conhecida como equação de Sturges. Foram determinados: a frequência relativa para cada classe pela Equação (54) e o valor médio de cada classe. Os resultados estão apresentados em forma gráfica.

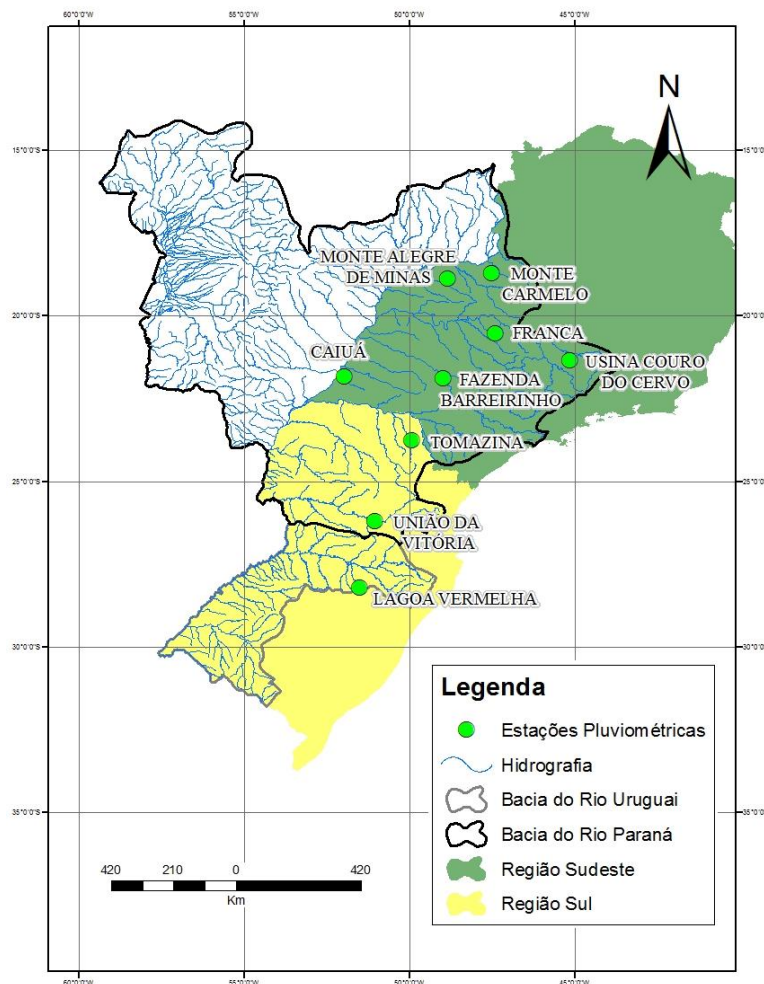


Figura 22- LOCALIZAÇÃO DAS ESTAÇÕES PLUVIOMÉTRICAS DENTRO DA RESPECTIVA REGIÃO GEOGRÁFICA

Fonte: o autor (2014)

$$NC = 1 + 3,3 \log_{10} N \quad (53)$$

onde:

NC : Número de classes;

N : Tamanho da amostra.

$$f_r = \frac{f}{N} \quad (54)$$

onde:

f_r : Frequência relativa;

f : Frequência absoluta de um intervalo de classe.

O período considerado para a análise estatística dos cenários de precipitação foi janeiro de 1961 a dezembro de 1991. Foi escolhido este período pela razão das séries de precipitação encontrarem com poucas falhas.

A Tabela 1 apresenta as falhas encontradas nas chuvas observadas. Os anos com mais de dois meses de falhas, conforme apresentado na Tabela 1, não foram considerados.

Fez-se um estudo de frequência empírica de precipitações máximas anuais usando-se a frequência acumulada por Kimbal para obter a Função de Distribuição Acumulada (FDA) empírica. Os resultados são apresentados graficamente. O mesmo procedimento foi adotado para o estudo de precipitações mínimas anuais, tanto observadas como geradas pelos dois RCM's.

Os tópicos seguintes apresentam os resultados da análise de dados para as estações Monte Carmelo e União da Vitória. Escolheram-se as duas estações, pois cada uma encontra-se em uma região do Brasil, Sudeste e Sul, respectivamente. Os resultados obtidos para as demais estações encontram-se no Apêndice 1.

Tabela 1- PERÍODOS COM FALHAS NAS ESTAÇÕES PLUVIOMÉTRICAS

Estação	Falhas
Monte Carmelo	01/63 a 12/66
Monte Alegre de Minas	sem falhas
Usina Couro do Cervo	sem falhas
Franca	sem falhas
Fazenda Barreirinho	11/79; 2/80
Tomazina	sem falhas
União da Vitória	sem falhas
Lagoa Vermelha	02/82 a 06/82; 08/82 a 12/82; 02/83; 04/83 a 12/83; 09/85 a 12/90
Caiuá	sem falhas

Fonte: O autor (2014)

6.5.2 Resultado da análise de dados Monte Carmelo – Região Sudeste

As Figuras 23a e 23b apresentam uma comparação entre a curva de permanência dos dados observados com a precipitação gerada pelos RCM's (PROMES e RCA)

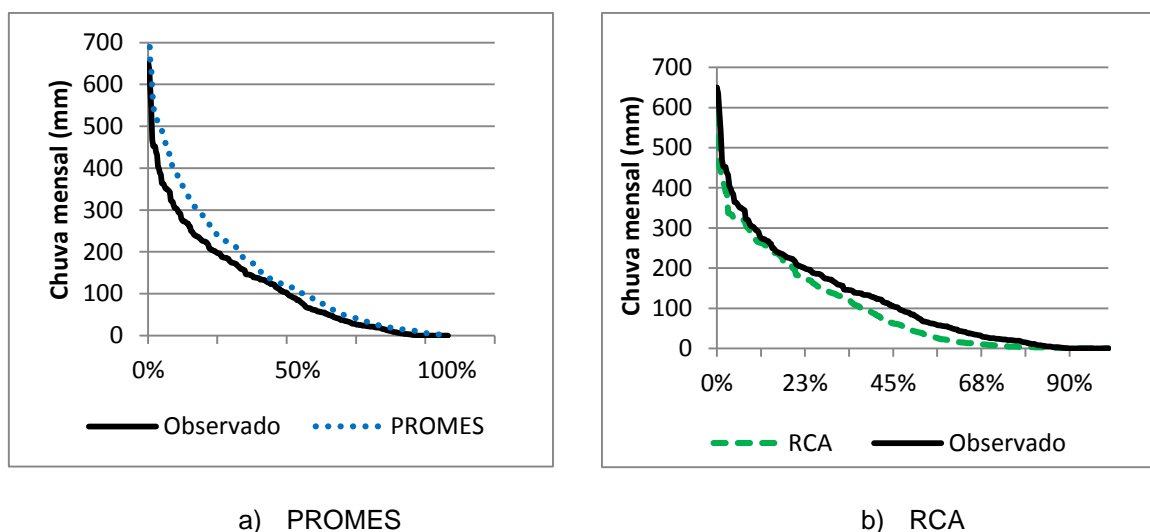


Figura 23 - CURVA DE PERMANÊNCIA DE PRECIPITAÇÕES OBSERVADAS E GERADAS EM MONTE CARMELO (SUDESTE)

Fonte: O autor (2014)

Ao se analisar as curvas de permanência (Figura 23), nota-se que o modelo PROMES conseguiu explicar melhor as precipitações mais baixas, curvas estão mais próximas entre 75 a 100%, e que o modelo RCA foi melhor para as precipitações maiores, para permanências de 0 a 20%.

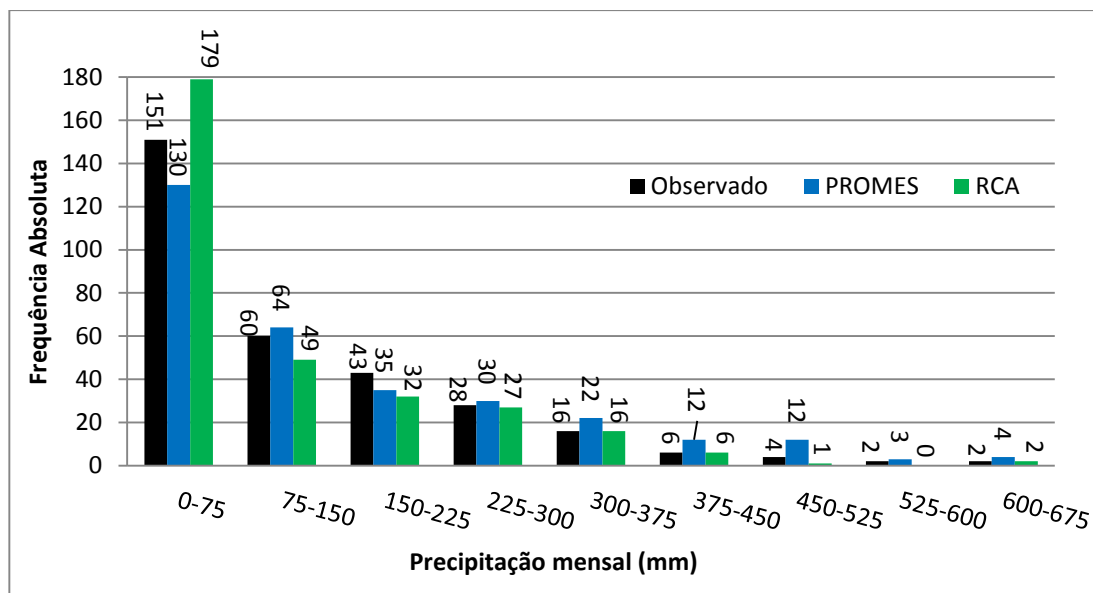


Figura 24 - HISTOGRAMA DE PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE)

Fonte: O autor (2014)

Na Figura 24, histograma das chuvas mensais, pode-se notar que o intervalo de 0 a 75 mm/mês foi o que obteve o maior número de ocorrências, tanto para dados observados como séries simuladas pelos RCM's (PROMES e RCA). Outra constatação que se pode fazer, é que a série simulada pelo RCA apresentou quase que 60% dos seus registros no intervalo de 0 a 75 mm/mês enquanto que os dados observados apresentaram aproximadamente 50% dos registros e aproximadamente 40% para o PROMES. De modo geral, a série simulada pelo RCA apresentou uma maior concentração de registros nos primeiros intervalos enquanto que a série simulada pelo modelo PROMES apresentou registros mais espalhados pelos intervalos e os dados observados ficaram espalhadas, porém menos que a série simulada pelo PROMES.

A Figura 25 apresenta os polígonos de frequência para as séries de precipitações observadas e para as geradas pelos RCM's PROMES e RCA.

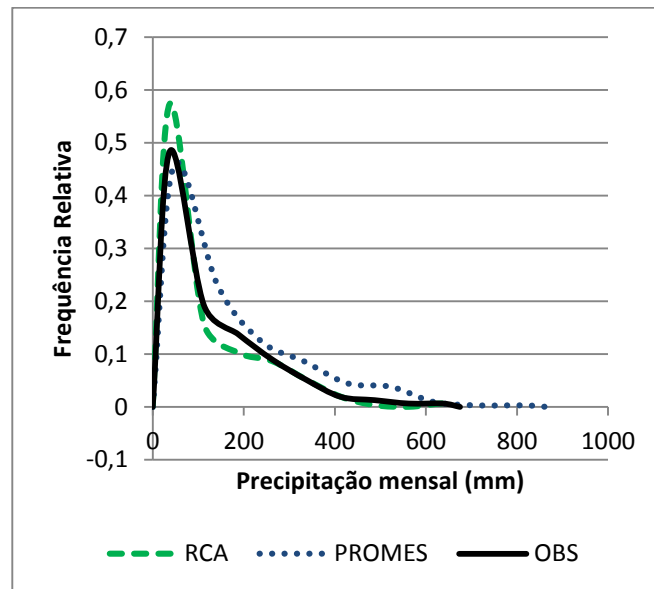


Figura 25 POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE)

Fonte: O autor (2014)

Ao analisar a Figura 25 observa-se que a curva gerada pelo modelo PROMES encontra-se deslocada para a direita, fato que confirma a análise feita anteriormente que o modelo PROMES superestima as precipitações. Outro fato que se pode constatar é que, quando comparada a curva gerada pelo modelo RCA com as demais, ela possui um pico maior. Este fato evidencia que o modelo RCA apresentou mais casos com precipitações com valores mais baixos. Outra análise que se pode fazer é a comparação dos resultados dos modelos RCA e PROMES com as precipitações observadas, pode-se concluir que o modelo RCA apresentou melhores resultados que o modelo PROMES, exceto na região de pico do gráfico.

As Figura 26a e 26b apresentam, respectivamente, a FDA para as precipitações mensais máximas e mínimas anuais.

Ao se comparar as FDA das precipitações máximas anuais (Figura 26a), observa-se que a curva do modelo PROMES encontra-se deslocada para a direita, o que representa que o modelo gerou chuvas mais intensas que

realmente existiram. Já a curva do modelo RCA ficou parte sobreposta sobre a curva FDA das precipitações observadas e parte deslocada para a esquerda (chuvas menos intensas que realmente existiram), isto caracteriza que o modelo RCA, mesmo se comportando melhor que o modelo PROMES, também não conseguiu explicar bem o fenômeno das precipitações máximas no período observado.

Na Figura 26b, FDA das precipitações mínimas mensais, o modelo PROMES apresentou resultados melhores que o modelo RCA, ambos os RCM's, apresentaram chuvas menores que realmente existiram.

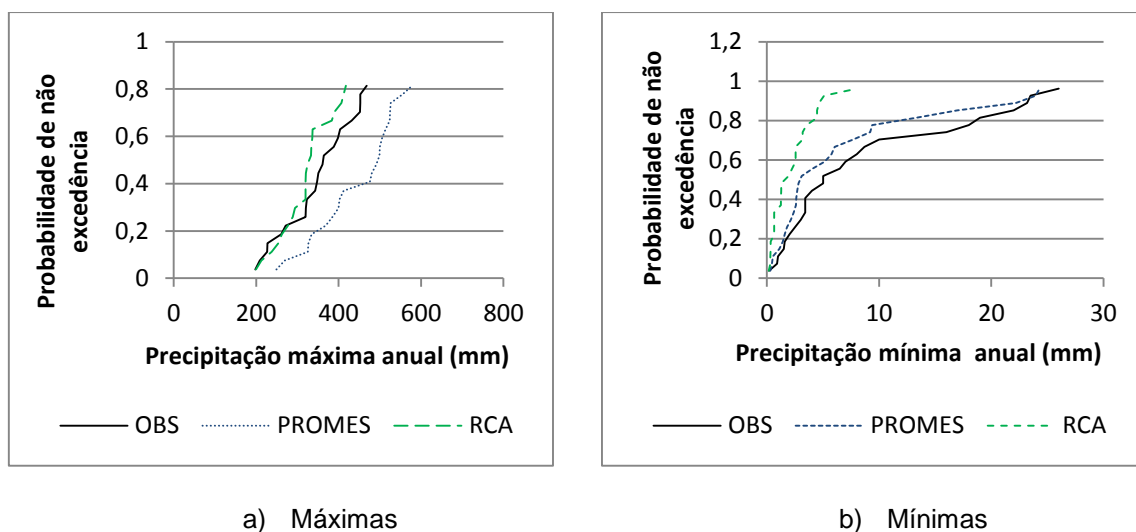


Figura 26 – FDA DAS PRECIPITAÇÕES MÁXIMAS (a) E MÍNIMAS (b) MENSAIS - ESTAÇÃO MONTE CARMELO (REGIÃO SUDESTE)

Fonte: O autor (2014)

6.5.3 Resultado da análise de dados para União da Vitória - Região Sul

A Figura 27a apresenta a curva de permanência para as precipitações observadas e para as simuladas pelo modelo PROMES e a Figura 27b, a curva de permanência para as precipitações observadas e precipitações simuladas pelo modelo RCA. Observa-se, de modo geral, que o modelo PROMES apresentou melhores resultados que o modelo RCA e que ambos os RCM's conseguiram descrever as precipitações mais altas, porém para as baixas não ocorreu o mesmo.




Figura 27 - CURVA DE PERMANÊNCIA DE PRECIPITAÇÃO OBSERVADAS E GERADAS EM ESTAÇÃO UNIÃO DA VITÓRIA (SUL)

Fonte: O autor (2014)

A Figura 28 apresenta os histogramas de frequência para as precipitações mensais observadas e simuladas pelos RCM's (PROMES e RCA). Observa-se que para os três primeiros intervalos (0 a 240mm/mês) os resultados encontram-se em discordância e o restante dos intervalos os registros são mais semelhantes. Enquanto foram observados 91 registros de chuva no intervalo de 0 a 80 o modelo PROMES simulou 128 e o modelo RCA 152 registros. No intervalo de 80 a 160 mm/mês foi o que se obteve maior número de registros de chuvas observadas e simuladas pelo modelo PROMES enquanto que para o modelo RCA foi o intervalo de 0 a 80 mm/mês.

A Figura 29a apresenta o polígono de frequência para as séries de precipitações observadas e para as geradas pelos modelos PROMES e RCA.




Figura 28 - HISTOGRAMA DE PRECIPITAÇÕES OBSERVADAS E SIMULADAS - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL)

Fonte: O autor (2014)

Ao analisar a Figura 29, pode-se notar que ambas as curvas geradas pelos RCM's (PROMES e RCA) estão deslocadas à esquerda quando comparadas com a curva dos dados observados. Este fato evidencia que ambos os RCM's geraram menos chuvas do que foi observado. Ao se analisar o comprimento da "cauda" dos gráficos, nota-se que a cauda em preto é mais extensa que as demais, indicando que os RCM's não conseguiram prever as chuvas de maior intensidade. Ao comparar os picos dos gráficos, pode-se constatar que a curva do modelo RCA possui a menor altura seguida da curva do PROMES. Isto evidencia que as chuvas são mais distribuídas nos RCM's quando comparadas com os dados observados.




Figura 29 POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL)

Fonte: O autor (2014)

As Figura 30a e 30b apresentam, respectivamente, a FDA para as precipitações mensais máximas e mínimas anuais.

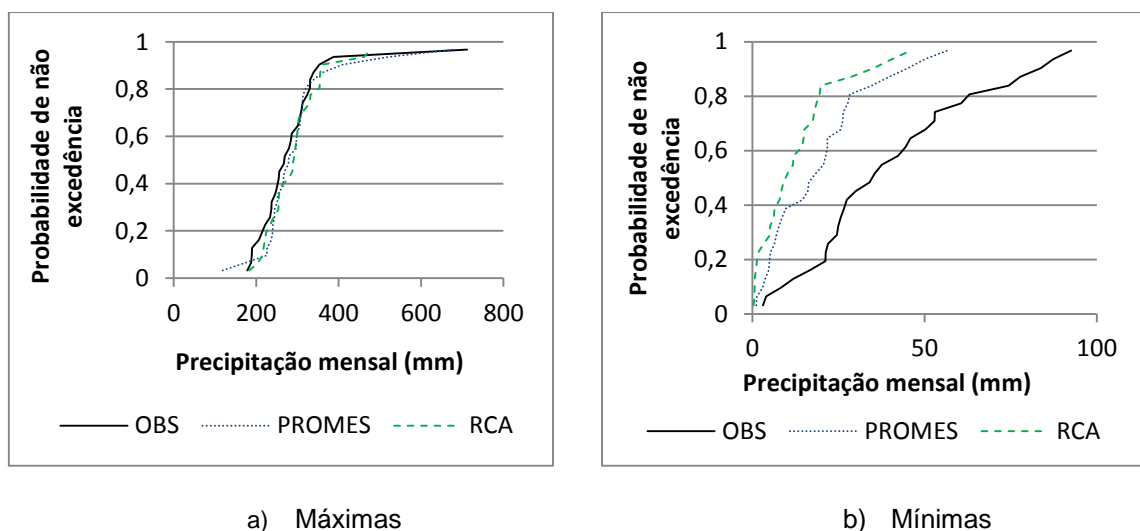


Figura 30 FDA DAS PRECIPITAÇÕES MÁXIMAS MENSASIS - ESTAÇÃO UNIÃO DA VITÓRIA (REGIÃO SUL)

Fonte: O autor (2014)

Ao se comparar as FDA das precipitações máximas mensais de cada ano, Figura 30a, observa-se que ambos os RCM's (PROMES e RCA) conseguiram descrever bem o fenômeno e que o modelo PROMES foi o que mais conseguiu aproximar os valores máximos.

Na Figura 30b, FDA das precipitações mínimas mensais de cada ano, pode-se notar que nenhum dos RCM's foram capazes de descrever o fenômeno, pois ambas as curvas encontram-se deslocadas para a esquerda. Este fato demonstra que os RCM's apresentaram chuvas menos intensas para a região do que de fato existiu.

6.5.4 Conclusões

Após análise para todas as estações (Anexo 1) pode-se concluir que as séries simuladas pelos RCM's contêm *bias* e necessitam passar por uma correção.

6.6 REMOÇÃO DO *BIAS* DAS SÉRIES GERADAS

Existem diversos métodos apresentados na literatura para correção do *bias* (BERG *et al.*, 2012; TEUSTSCHBEIN e SEIBER, 2012; WATANABE *et al.*, 2012). Estes métodos variam de acordo com sua complexidade e podem ajustar desde a média até o desvio padrão e o coeficiente de variação das séries simuladas pelos RCM's. Quanto maior a complexidade do método, maior a necessidade de uso de dados com espaço de tempo mais curto, como por exemplo, o uso de dados com escalas diárias ou horárias. Neste trabalho não se teve acesso aos dados diários de precipitação e temperatura simulados pelos RCM's, portanto foram testados apenas três métodos para correção do *bias*.

O primeiro método, também chamado de método de correção linear da temperatura e precipitação (LENDERINK *et al.*, 2007), trabalha com a correção mensal dos valores baseados na diferença entre os dados observados e os simulados pelos RCM's. O método consiste em ajustar o primeiro momento das precipitações e temperaturas geradas pelos RCM's aos dados observados.

As Equações (55) e (56) apresentam as correções para a precipitação e a temperatura respectivamente.

$$P_{cor}(n) = P_{sim}(n) \left(\frac{\overline{P_{obs}}}{\overline{P_{sim}^*}} \right) \quad (55)$$

$$T_{cor}(n) = T_{sim}(n) + \overline{T_{obs}} - \overline{T_{sim}^*} \quad (56)$$

onde:

$P_{cor}(n)$: Precipitação com o *bias* corrigido para o tempo n ;

$P_{sim}(n)$: Precipitação gerada pelo RCM no tempo n ;

$\overline{P_{obs}}$: Média das precipitações observadas;

$\overline{P_{sim}^*}$: Média das precipitações geradas pelo RCM para o mesmo período das precipitações observadas;

$T_{cor}(n)$: Temperatura com o *bias* corrigido para o tempo n ;

$T_{sim}(n)$: Temperatura gerada pelo RCM no tempo n ;

$\overline{T_{obs}}$: Média das temperaturas observadas;

$\overline{T_{sim}^*}$: Média das temperaturas geradas pelo RCM para o mesmo período das precipitações observadas;

O segundo método adotado para correção do *bias* foi através do uso das RNA's. Foi escolhido o uso de RNA para correção do *bias* devido a sua capacidade de reconhecer padrões e relações não lineares entre as entradas e as saídas desejadas. A metodologia utilizada para a obtenção dos modelos e a escolha da melhor RNA foi a mesma apresentada nas seções 4.2 e 4.3 diferenciando apenas nos dados de entrada e saída. Para o caso das correções do *bias* das precipitações, utilizaram-se os modelos apresentados no Quadro 7. Já para o caso das temperaturas utilizaram-se os apresentados no Quadro 8. Portanto se obteve duas RNA's para cada área de estudo, uma para corrigir as precipitações e a outra para corrigir as temperaturas.

MODELO	ENTRADAS	SAÍDA
1	$P_{sim}(t) T_{sim}(t)$	$P_{cor}(t)$
2	$P_{sim}(t-1) P_{sim}(t) T_{sim}(t-1) T_{sim}(t)$	$P_{cor}(t)$
3	$P_{sim}(t-2) P_{sim}(t-1) P_{sim}(t) T_{sim}(t-2) T_{sim}(t-1) T_{sim}(t)$	$P_{cor}(t)$

Quadro 7 - MODELOS RNA PARA CORREÇÃO DO BIAS DA CHUVA

Fonte: O autor (2014)

MODELO	ENTRADAS	SAÍDA
1	$P_{sim}(t) T_{sim}(t)$	$T_{cor}(t)$
2	$P_{sim}(t-1) P_{sim}(t) T_{sim}(t-1) T_{sim}(t)$	$T_{cor}(t)$
3	$P_{sim}(t-2) P_{sim}(t-1) P_{sim}(t) T_{sim}(t-2) T_{sim}(t-1) T_{sim}(t)$	$T_{cor}(t)$

Quadro 8- MODELOS RNA PARA CORREÇÃO DO BIAS DA TEMPERATURA

Fonte: O autor (2014)

O terceiro método foi uma variação do segundo método. As séries de dados (observados e simulados) foram divididas em dois grandes períodos, de igual tamanho (180 valores para cada período) e meses consecutivos. A Figura 31 e a Figura 32 apresentam as precipitações observadas médias mensais para cada estação pluviométrica estudada para a região Sudeste e Sul respectivamente, a curva em preto representa a precipitação média de todas as estações. Nota-se que, para a região Sudeste (Figura 31), o período mais úmido compreende os meses de outubro a março e o período mais seco os meses de abril a setembro. Já a região Sul (Figura 32) não apresenta um regime bem definido como a região Sudeste e por esta razão foi considerado o mesmo período seco e úmido da região Sudeste.




Figura 31 – ANÁLISE DA SAZONALIDADE DA PRECIPITAÇÃO MÉDIA MENSAL (01/61 A 12/91) PARA REGIÃO SUDESTE

Fonte: O autor (2014)

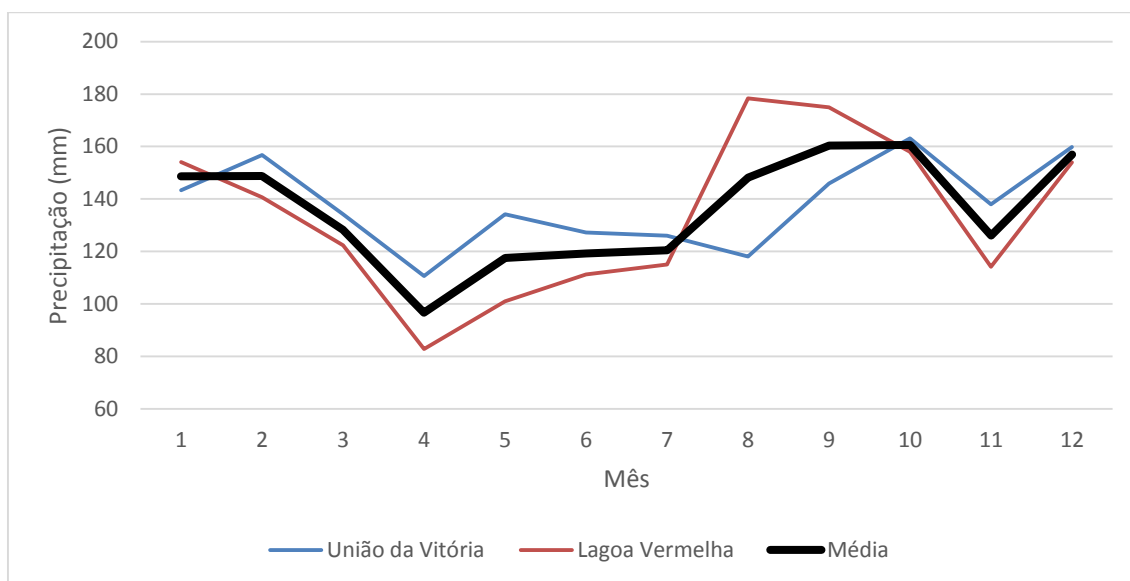


Figura 32 – ANÁLISE DA SAZONALIDADE DA PRECIPITAÇÃO MÉDIA MENSAL (01/61 A 12/91) PARA REGIÃO SUL

Fonte: O autor (2014)

Com esta mudança, obteve-se para cada variável (temperatura e precipitação) duas RNA's (período seco e período úmido) totalizando quatro RNA's por local de estudo. Portanto, cada RNA foi "especializada" para descrever um período do ano para uma variável: período úmido precipitação, período úmido temperatura, período seco precipitação e período seco temperatura.

As entradas utilizadas para o terceiro método são as mesmas utilizadas para o segundo método (Quadro 7 e Quadro 8), porém as extensões dos dados utilizados para o treinamento e validação foram diferentes. Enquanto no segundo método utilizaram-se três tipos de entradas com: 60, 120 e 180 registros para treino e 300, 240 e 180 registros para validação, no terceiro método as extensões das entradas foram: 30, 60 e 90 e para treino e 150, 120 e 90 registros para validação respectivamente.

Foram calculadas cinco medidas estatísticas: a média [Equação (57)], o desvio padrão [Equação (58)] o coeficiente de variação [Equação (59)] o coeficiente de determinação [Equação (51)] e o coeficiente de Nash-Sutcliffe [Equação (50)]. A escolha do método mais eficaz foi baseada no coeficiente de Nash- Sutcliffe.

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (57)$$

$$S = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (58)$$

$$CV = \frac{S}{\bar{X}} \quad (59)$$

onde:

\bar{X} : Média da amostra;

X_i : Valor de um evento na posição i ésima;

N : Número total de elementos na amostra;

S : Desvio padrão;

CV : Coeficiente de variação.

6.6.1 Resultados

Neste tópico apresentam-se os resultados obtidos da correção do *bias* para os nove locais de estudo (Tabela 2 a Tabela 19).

As estatísticas das séries observadas, simuladas pelos RCM's e pelos RCM's com *bias* corrigido para precipitação e temperatura encontram-se apresentados na Tabela 2 à Tabela 19. A primeira linha de cada tabela representa os valores médios das séries (\bar{X}), a segunda linha o desvio padrão (S) a terceira linha o coeficiente de variação (CV), a quarta o coeficiente de determinação (R^2) e a quinta linha o coeficiente de Nash-Sutcliffe (NS). A segunda coluna apresenta as estatísticas obtidas para a série observada, a terceira coluna para a série simulada pelo modelo PROMES, a quarta pelo modelo RCA, a quinta e a sexta as séries geradas pelos PROMES e RCA corrigidas pelo método 1, a sétima e oitava as séries corrigidas pelo método 2 e a nona e a décima as séries corrigidas pelo método 3.

A Tabela 2 apresenta os resultados obtidos para a Bacia Hidrográfica do Alto Paranaíba para as séries de chuva e a Tabela 3 os resultados obtidos para para as séries de temperatura.

Tabela 2- RESULTADOS CORREÇÃO DO *BIAS* MONTE CARMELO - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	121,09	152,62	98,09	121,09	121,09	137,96	259,56	147,74	81,87
S	125,61	154,10	118,13	126,43	145,83	80,30	29,30	156,32	101,42
<i>C. V.</i>	1,04	1,01	1,20	1,04	1,20	0,58	0,12	1,06	1,24
R^2	-	0,39	0,34	0,39	0,34	0,12	0,00	0,13	0,00
<i>NS</i>	-	-0,03	0,19	0,27	0,03	0,02	-1,27	-0,69	-0,65

Fonte: O autor (2014)

Tabela 3- RESULTADOS DA CORREÇÃO DO *BIAS* GOIÂNIA - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	22,33	24,23	25,76	23,30	23,33	23,16	23,16	22,18	25,80
S	1,42	2,32	0,21	2,23	0,21	2,21	2,21	1,44	0,19
<i>C. V.</i>	0,06	0,09	0,01	0,09	0,01	0,09	0,09	0,06	0,00
R^2	-	0,505	0,334	0,505	0,334	0,87	0,90	0,08	0,01
<i>NS</i>	-	-0,81	-2,78	-0,25	0,15	-4,48	-21,23	-0,61	-0,57

Fonte: O autor (2014)

A Tabela 4 apresenta os resultados obtidos para a Bacia Hidrográfica do Baixo Paranaíba para as séries de chuva e a Tabela 5 para as séries de temperatura.

Tabela 4- RESULTADOS DA CORREÇÃO DO *BIAS* MONTE ALEGRE DE MINAS - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	122,65	185,87	106,11	122,65	122,65	120,02	128,22	150,63	88,26
S	114,67	177,32	123,69	117,01	142,98	87,57	99,68	159,71	110,04
<i>C. V.</i>	0,93	0,95	1,17	0,95	1,17	0,73	0,78	1,06	1,24
R^2	-	0,45	0,39	0,45	0,39	0,17	0,16	0,03	0,01
<i>NS</i>	-	-0,62	-0,92	0,45	0,15	0,04	-0,06	-1,55	-0,85

Fonte: O autor (2014)

Tabela 5- RESULTADOS DA CORREÇÃO DO BIAS CATALÃO - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	22,02	24,30	25,76	22,02	22,02	21,82	21,91	21,70	25,78
S	1,80	2,32	0,21	2,32	0,21	2,20	1,42	1,55	0,20
$C.V.$	0,08	0,10	0,01	0,11	0,01	0,10	0,06	0,07	0,01
R^2	-	0,47	0,30	0,47	0,30	0,00	0,00	0,03	0,03
NS	-	-1,51	-4,21	0,09	0,11	-1,31	-1,31	-0,77	-0,71

Fonte: O autor (2014)

A Tabela 6 apresenta os resultados obtidos para a Bacia Hidrográfica do Alto Rio Grande para as séries de chuva e a Tabela 7 para as séries de temperatura.

Tabela 6- RESULTADOS DA CORREÇÃO DO BIAS FRANCA - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	140,73	140,82	101,03	140,72	140,72	260,24	180,81	124,75	68,80
S	128,13	119,67	108,40	113,37	150,99	14,90	77,09	107,00	72,23
$C.V.$	0,91	0,85	1,07	0,81	1,08	0,06	0,42	0,86	1,05
R^2	-	0,33	0,38	0,33	0,38	0,16	0,00	0,10	0,00
NS	-	0,07	-0,06	0,08	-0,34	-0,87	-0,46	-0,20	-0,67

Fonte: O autor (2014)

Tabela 7- RESULTADOS CORREÇÃO DO BIAS FRANCA - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	19,03	23,62	24,40	19,03	19,03	25,31	24,01	21,03	24,41
S	3,15	2,68	0,21	2,68	0,17	2,19	0,62	1,70	0,21
$C.V.$	0,17	0,11	0,01	0,14	0,01	0,09	0,03	0,08	0,01
R^2	-	0,70	0,41	0,70	0,41	0,00	0,02	0,12	0,04
NS	-	-1,42	-2,83	0,70	0,07	-4,39	-2,60	-0,86	-0,83

Fonte: O autor (2014)

A Tabela 8 apresenta os resultados obtidos para a Bacia Hidrográfica do Baixo Rio Grande para as séries de chuva e a Tabela 9 para as séries de temperatura.

Tabela 8- RESULTADOS DA CORREÇÃO DO BIAS USINA COURO CERVO - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	115,78	149,48	65,80	115,79	115,79	101,34	104,37	441,24	58,40
S	107,80	128,14	76,57	99,25	134,74	54,32	66,50	186,42	72,88
$C.V.$	0,93	0,86	1,16	0,86	1,16	0,53	0,63	0,42	1,24
R^2	-	0,29	0,28	0,29	0,28	0,00	0,00	0,44	0,04
NS	-	-0,22	-0,19	0,15	-0,61	-0,52	-0,43	-9,84	-0,99

Fonte: O autor (2014)

Tabela 9- RESULTADOS DA CORREÇÃO DO BIAS LAVRAS - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	20,38	24,07	23,70	19,34	20,38	21,78	21,89	124,38	23,71
S	1,77	23,95	0,21	2,42	0,18	0,20	0,21	105,15	0,20
$C.V.$	0,08	0,99	0,09	0,12	0,01	0,01	0,01	0,84	0,09
R^2	-	0,70	0,41	0,70	0,41	0,01	0,01	0,45	0,03
NS	-	-2,00	-3,40	-0,59	0,13	-0,68	-0,76	0,42	-0,73

Fonte: O autor (2014)

A Tabela 10 apresenta os resultados obtidos para a Bacia Hidrográfica do Rio Tiête para as séries de chuva e a Tabela 11 para as séries de temperatura.

Tabela 10- RESULTADOS DA CORREÇÃO DO BIAS FAZENDA BARREIRINHO - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	106,55	160,68	77,76	106,55	106,55	74,86	99,39	124,47	63,79
S	96,47	140,42	85,13	93,12	116,66	48,80	56,04	104,69	69,48
$C.V.$	0,90	0,87	1,09	0,87	1,09	0,65	0,57	0,84	1,09
R^2	-	0,26	0,28	0,26	0,28	0,07	0,00	0,02	0,00
NS	-	-0,93	0,07	0,07	-0,18	-0,09	-0,27	-0,89	-0,62

Fonte: O autor (2014)

Tabela 11- RESULTADOS DA CORREÇÃO DO BIAS CATANDUVA - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	22,81	23,24	23,66	22,81	22,81	13,64	27,73	12,04	12,01
S	2,38	2,74	0,22	2,69	0,21	2,39	2,60	6,43	6,41
$C.V.$	0,10	0,12	0,01	0,11	0,01	0,17	0,09	0,53	0,53
R^2	-	0,64	0,40	0,64	0,40	0,10	0,01	0,40	0,37
NS	-	0,50	-0,014	0,52	0,11	-15,09	-4,88	-1,01	-1,07

Fonte: O autor (2014)

A Tabela 12 apresenta os resultados obtidos para a Bacia Hidrográfica do Rio Paranapanema para as séries de chuva e a Tabela 13 para as séries de temperatura.

Tabela 12- RESULTADOS DA CORREÇÃO DO BIAS TOMAZINA - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	115,23	125,75	70,45	114,44	114,51	125,34	101,84	103,56	44,48
S	80,31	107,88	69,70	98,18	113,28	34,68	20,62	88,47	43,75
$C.V.$	0,70	0,86	0,99	0,86	0,99	0,27	0,20	0,85	0,98
R^2	-	0,07	0,08	0,07	0,08	0,08	0,02	0,01	0,01
NS	-	-1,10	-0,58	-0,84	-1,22	0,05	-0,21	-1,01	-1,18

Fonte: O autor (2014)

Tabela 13- RESULTADOS DA CORREÇÃO DO BIAS CASTRO - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	16,70	21,66	18,01	16,27	16,72	11,41	8,72	16,72	18,03
S	3,11	3,26	0,19	2,44	0,17	0,35	4,08	110,44	0,18
$C.V.$	0,18	0,15	0,01	0,15	0,01	0,03	0,47	6,60	0,01
R^2	-	0,09	0,27	0,09	0,27	0,06	0,21	0,67	0,01
NS	-	-1,77	0,11	0,72	0,06	-2,87	-67,69	-0,79	-1,47

Fonte: O autor (2014)

A Tabela 14 apresenta os resultados obtidos para a Bacia Hidrográfica do Rio Paraná para as séries de chuva e a Tabela 15 para as séries de temperatura.

Tabela 14- RESULTADOS DA CORREÇÃO DO BIAS CAIUÁ - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	97,19	153,15	71,27	97,09	97,38	91,03	79,02	131,50	44,31
S	87,71	138,47	79,40	87,78	108,48	33,01	32,56	113,41	48,28
$C.V.$	0,90	0,90	1,14	0,90	1,14	0,36	0,41	0,86	1,09
R^2	-	0,10	0,14	0,10	0,14	0,09	0,00	0,86	1,09
NS	-	-1,87	-0,22	-0,35	-0,19	-0,48	-0,64	-1,49	-0,76

Fonte: O autor (2014)

Tabela 15- RESULTADOS DA CORREÇÃO DO BIAS PRESIDENTE PRUDENTE -
TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	16,90	22,87	21,76	16,91	16,81	6,06	0,96	20,55	21,74
S	3,05	2,92	0,21	2,16	0,17	1,31	0,00	2,43	0,20
$C.V.$	0,18	0,12	0,01	0,12	0,16	0,22	0,00	0,12	0,09
R^2	-	0,61	0,22	0,61	0,22	0,00	0,00	0,02	0,10
NS	-	-3,24	-2,45	0,60	0,05	-12,39	-34,33	-0,76	-0,75

Fonte: O autor (2014)

A Tabela 16 apresenta os resultados obtidos para a Bacia do Rio Iguaçu para as séries de chuva e a Tabela 17 para as séries de temperatura.

Tabela 16- RESULTADOS DA CORREÇÃO DO BIAS UNIÃO DA VITÓRIA - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	138,15	118,61	117,83	137,34	137,61	137,35	138,28	114,86	90,14
S	81,26	84,02	93,48	97,29	109,18	0,00	6,46	82,74	69,53
$C.V.$	0,58	0,71	0,79	0,70	0,79	0,00	0,04	0,72	0,77
R^2	-	0,00	0,01	0,00	0,01	0,00	0,04	0,00	0,13
NS	-	-1,11	-1,15	-1,42	-1,54	0,00	0,00	-0,99	-0,87

Fonte: O autor (2014)

Tabela 17- RESULTADOS DA CORREÇÃO DO BIAS CURITIBA - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	16,52	20,58	18,05	16,49	16,43	16,04	13,23	23,13	18
S	3,56	3,14	0,19	2,39	0,17	3,39	0,00	1,12	0,18
$C.V.$	0,22	0,15	0,01	0,15	0,01	0,21	0,00	0,05	0,01
R^2	-	0,12	0,23	0,12	0,23	0,00	0,00	0,05	0,09
NS	-	-3,03	-0,24	-1,29	-0,46	-0,09	-0,07	-2,70	-2,20

Fonte: O autor (2014)

A Tabela 18 apresenta os resultados obtidos para a Bacia Hidrográfica do Rio Uruguai para as séries de chuva e a Tabela 19 para as séries de temperatura.

Tabela 18- RESULTADOS DA CORREÇÃO DO BIAS ESTAÇÃO LAGOA VERMELHA - CHUVA (mm)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	132,91	110,92	83,80	132,91	132,91	102,46	140,47	74,57	60,10
S	80,26	72,40	65,87	85,75	104,47	29,27	14,34	49,00	46,36
$C.V.$	0,60	0,65	0,79	0,65	0,79	0,28	0,11	0,65	0,77
R^2	-	0,00	0,01	0,00	0,01	0,05	0,01	0,01	0,01
NS	-	-0,78	-0,93	-1,03	-1,51	-0,12	-0,01	-0,77	-1,12

Fonte: O autor (2014)

Tabela 19- RESULTADOS DA CORREÇÃO DO BIAS ESTAÇÃO LAJES - TEMPERATURA (°C)

	OBSERVAD O (2)	PROME S (3)	RCA (4)	MET.1 PROME S (5)	MET.1 RCA (6)	MET.2 PROME S (7)	MET.2 RCA (8)	MET.3 PROME S (9)	MET.3 RCA (10)
\bar{X}	22,60	20,84	17,87	22,60	22,60	20,77	-0,01	19,09	17,88
S	2,52	3,78	0,17	4,11	4,11	1,25	0,00	3,16	0,16
$C.V.$	0,11	0,18	0,01	0,18	0,18	0,06	-0,23	0,16	0,01
R^2	-	0,68	0,28	0,68	0,28	0,12	0,04	0,15	0,15
NS	-	-1,58	-0,35	0,68	0,04	-2,01	-20,19	-2,07	-2,13

Fonte: O autor (2014)

O Quadro 9 resume os métodos selecionados para correção do *bias* para cada Bacia Hidrográfica em estudo. Ao analisar os resultados do Quadro 9, pode-se notar que as correções apresentaram melhoras para todas as séries de precipitações e temperaturas simuladas pelo modelo PROMES, enquanto que as séries simuladas pelo modelo RCA apresentaram melhoras para cinco dos nove postos estudados para precipitação e oito dos nove postos estudados para temperatura. Como citado anteriormente, a escolha do método mais eficaz foi baseada no coeficiente de Nash-Sutcliffe. O apêndice 2 apresenta os gráficos comparando as séries observadas, simuladas e corrigidas para todos os postos estudados.

c	BACIA HIDROGRÁFICA	CHUVA								TEMPERATURA							
		PROMES				RCA				PROMES				RCA			
		SEM	MET. 1	MET. 2	MET. 3	SEM	MET. 1	MET. 2	MET. 3	SEM	MET. 1	MET. 2	MET. 3	SEM	MET. 1	MET. 2	MET. 3
1-	ALTO PARANAÍBA (M. CARMELO/GOIÂNIA)		X			X					X				X		
2-	BAIXO PARANAÍBA (M. A. DE MINAS/CATALÃO)		X				X				X				X		
3-	ALTO RIO GRANDE (FRANCA/FRANCA)		X			X					X				X		
4-	BAIXO RIOGRANDE (U. C. DO CERVO/LAVRAS)		X			X							X		X		
5-	RIO TIÊTE (F. BARREIRINHO/CATANDUVA)		X			X					X				X		
6-	RIO PARANAPANEMA (TOMAZINA/CASTRO)			X				X			X			X			
7-	RIO PARANÁ (CAIUÁ/PRESIDENTE PRUDENTE)		X					X			X				X		
8-	RIO IGUAÇU (UNIÃO DA VITÓRIA/CURITIBA)			X				X				X				X	
9-	RIO URUGUAI (LAGOA VERMELHA/LAJES)			X				X			X				X		

Quadro 9 - MÉTODOS DE CORREÇÕES SELECIONADOS
 Fonte: O autor (2014)

7. MODELAGEM CHUVA-VAZÃO

7.1 POTENCIAL DAS RNA's NO PROCESSO CHUVA-VAZÃO MENSAL COM DADOS OBSERVADOS

Como descrito nas seções 4.2 e 4.3 foram criados 1296 modelos de RNA's para cada local de estudo e por esta razão foi definido uma notação para identificar qual modelo conseguiu descrever melhor o processo chuva-vazão. O critério aplicado para a nomenclatura de cada RNA segue a seguinte regra:

1. Primeiro caractere: Letra R para representar a sigla RNA;
2. Segundo caractere: Número que varia de 1 a 6. Este representa o tipo de modelo escolhido (Quadro 2);
3. Terceiro caractere: Número que se refere à quantidade de neurônios presentes na camada intermediária. Varia de 1 a 4 sendo 1 para 3 neurônios, 2 para 5 neurônios, 3 para 8 neurônios e 4 para 10 neurônios;
4. Quarto caractere: Letra que caracteriza o número de inicializações da RNA. Varia de "A" para 1 inicialização até "F" 6 inicializações;
5. Quinto e sexto caracteres: Número que simboliza o número de *epochs* da RNA. Este pode ser 30, 60 ou 90;
6. Sétimo caractere: Letra E que representa a palavra entrada. Os caracteres que precedem este representam o tipo de entrada da RNA;
7. Oitavo caractere: é um número que varia de 1 a 6. Este representa o tipo de modelo (Quadro 2);
8. Nono caractere: Número que varia de 1 a 3. Os números 1, 2 e 3 representam uma série de entrada para treinamento com extensão de 60, 120 e 180 meses respectivamente.

Após gerar os 1296 resultados para cada local de estudo, foi selecionada a rede com melhor desempenho. A escolha da melhor entre as 1.296 RNA's foi baseada no melhor coeficiente de Nash-Sutcliffe durante a validação. Em casos que mais de uma RNA apresentaram o mesmo valor do coeficiente de Nash-Sutcliffe, então foi considerado como critério de desempate o melhor coeficiente de determinação na validação. Se os coeficientes continuassem semelhantes, era então escolhida a RNA de arquitetura mais simples. A Tabela 20 apresenta as RNA's selecionadas para cada bacia hidrográfica estudada.

Tabela 20 - RNA SELECIONADA E SEUS COEFICIENTES DE DESEMPENHO (01/61 a 12/90)

	BACIA HIDROGRÁFICA	RNA	TREINAMENTO			VALIDAÇÃO		
			NS	R ²	DV(%)	NS	R ²	DV(%)
1	Alto Paranaíba	'R24B30E22'	0,80	0,80	0,00	0,81	0,80	2,30
2	Baixo Paranaíba	'R42D30E42'	0,79	0,79	0,00	0,76	0,79	-3,50
3	Alto Rio Grande	'R44A60E42'	0,37	0,61	-0,11	0,27	0,58	5,75
4	Baixo Rio Grande	'R43D90E42'	0,82	0,75	0,02	0,75	0,75	-1,90
5	Tietê	'R64C30E62'	0,70	0,73	0,04	0,68	0,73	1,03
6	Paranapanema	'R64C30E63'	0,79	0,78	0,01	0,75	0,78	-5,09
7	Paraná	'R41A30E43'	0,48	0,69	0,41	0,42	0,72	-2,08
8	Iguaçu	'R22F90E23'	0,61	0,63	0,00	0,64	0,63	2,40
9	Uruguai	'R41A60E42'	0,61	0,82	0,00	0,72	0,82	0,66

Fonte: O autor (2014)

Na Tabela 20 “NS” representa o coeficiente de Nash-Sutcliffe, “R²” o coeficiente de determinação e “DV” a diferença percentual entre os volumes observados e os volumes calculados. Ao analisar os dados da Tabela 20, pode-se notar que apenas os modelos para as bacias do Alto Rio Grande e do Paraná ficaram muito abaixo do esperado com resultados do coeficiente de Nash-Sutcliffe abaixo de 0,5 no treinamento e validação. Os modelos para as bacias dos rios Iguaçu e Tietê comportaram-se de maneira razoável visto que seus coeficientes de Nash-Sutcliffe ficaram entre de 0,60 e 0,70. O restante dos modelos foi considerado como satisfatório visto que os coeficientes de Nash-Sutcliffe ficaram acima de 0,70.

As Figuras 33 a 41 apresentam gráficos de dispersão comparando as vazões observadas com as geradas pelo modelo de RNA durante o período de treinamento e validação. No mesmo gráfico também é apresentada uma reta com coeficiente angular de 45° que representa o ajuste perfeito entre as vazões observadas e as geradas. Conseqüentemente, quanto mais próximos os pontos se encontrarem da reta, melhor o modelo conseguiu descrever o evento.




Figura 33 – BACIA DO ALTO PARANAÍBA (EMBORAÇÃO)

Fonte: O autor (2014)

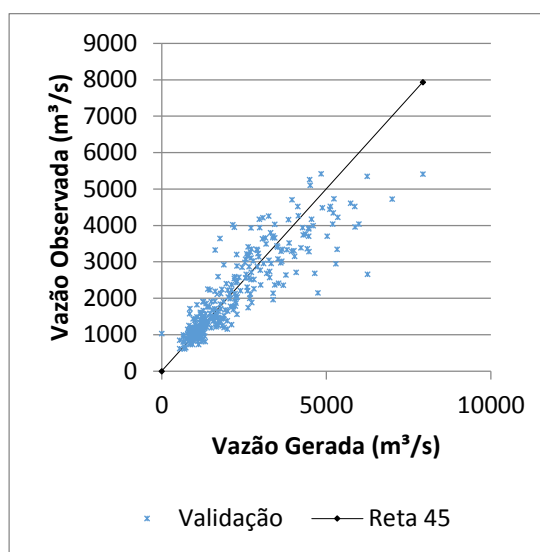


Figura 34– BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)

Ao analisar a Figura 33, Bacia do Alto Paranaíba, pode-se verificar que, de modo geral, o modelo descreveu bem o evento, pois a maioria dos pontos encontram-se próximos à reta. O modelo comportou-se melhor para descrever as vazões baixas, de 0 a 1.500 m^3/s , e para vazões maiores a dispersão de pontos em relação a reta foi maior. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,81, valor considerado bom.

Assim como no Alto Paranaíba, o Baixo Paranaíba (Figura 34) também apresenta baixa dispersão de pontos. O modelo comportou-se melhor para baixas vazões, até 2.500 m^3/s e a dispersão aumenta para vazões maiores. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,76, valor considerado bom.

O modelo obtido para a bacia do Alto Rio Grande, Figura 35, não conseguiu descrever o processo chuva-vazão. Nota-se grande dispersão dos pontos sobre a reta, fato que já era esperado devido ao baixo coeficiente de Nash-Sutcliffe para o período de validação que foi de 0,27, valor considerado ruim.

Diferente do Alto Rio Grande, os resultados obtidos para o Baixo Rio Grande, Figura 36, foram satisfatórios. Observa-se que para vazões entre 5.000 a 20.000 m³/s o modelo consegue descrever o processo com maior precisão. Já para vazões acima 20.000 m³/s, a dispersão dos pontos em relação a reta aumenta. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,75, valor considerado bom.

Na bacia do Tietê, Figura 37, os resultados foram satisfatórios apenas no intervalo de 0 a 800 m³/s. Para vazões maiores que 800 m³/s observa-se uma grande dispersão dos pontos. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,68, valor considerado razoável.




Figura 35– BACIA DO ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 36– BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)

Observa-se baixa dispersão de pontos na bacia do Rio Paranapanema, (Figura 38). Os resultados obtidos foram considerados bons em praticamente todo o intervalo de vazões analisadas. Nota-se apenas um ponto mais distante

da reta, ponto de maior vazão registrada. O fato deste ponto estar mais distante da reta pode ser justificado por ser um *outlier*, de pouca frequência na série observada. Devido a sua baixa ocorrência não houve muitos casos para a RNA ser treinada para este tipo de situação. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,75, valor considerado bom.

O modelo obtido para a bacia do rio Paraná (Figura 39) reproduziu de forma razoável o processo chuva-vazão. O baixo coeficiente de Nash-Sutcliffe obtido (NS=0,42) pode ser explicado por inconsistência em poucas vazões.




Figura 37– BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 38- BACIA DO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)

A bacia do Rio Iguaçu (Figura 40) apresentou dispersão de pontos em relação à reta para todo o intervalo de vazões analisado. Porém o modelo comportou-se melhor para o intervalo de 0 a 10.000 m³/s. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,64, valor considerado razoável.

Os resultados obtidos para a bacia do Rio Uruguai (Figura 41) foram razoáveis para o intervalo de 0 a 1.500 m³/s. Nota-se que a dispersão dos pontos aumenta consideravelmente para vazões acima deste intervalo. O coeficiente de Nash-Sutcliffe para o período de validação foi de 0,72, valor considerado bom.




Figura 39- BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 40 – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (20134)




Figura 41- BACIA RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

Foram também elaborados fluviogramas de vazões mensais. As Figuras 42 a 50 apresentam esses fluviogramas das vazões mensais observadas (em preto) com as geradas pela RNA (tracejado em azul) para o período observado. De maneira geral, as conclusões feitas aqui podem ser as mesmas que as obtidas das Figuras 33 a 41. Os modelos obtidos para a Bacia do Alto Rio Grande (Figura 44) e para a Bacia do Rio Paraná (Figura 48) foram os modelos

que obtiveram o pior desempenho. Salvo para vazões muito altas, o restante dos modelos, de maneira geral, conseguiu explicar o processo chuva-vazão, logo conclui-se que as RNA's têm potencial para a simulação de vazões mensais, tal como já afirmado por MACHADO *et al.* (2011)

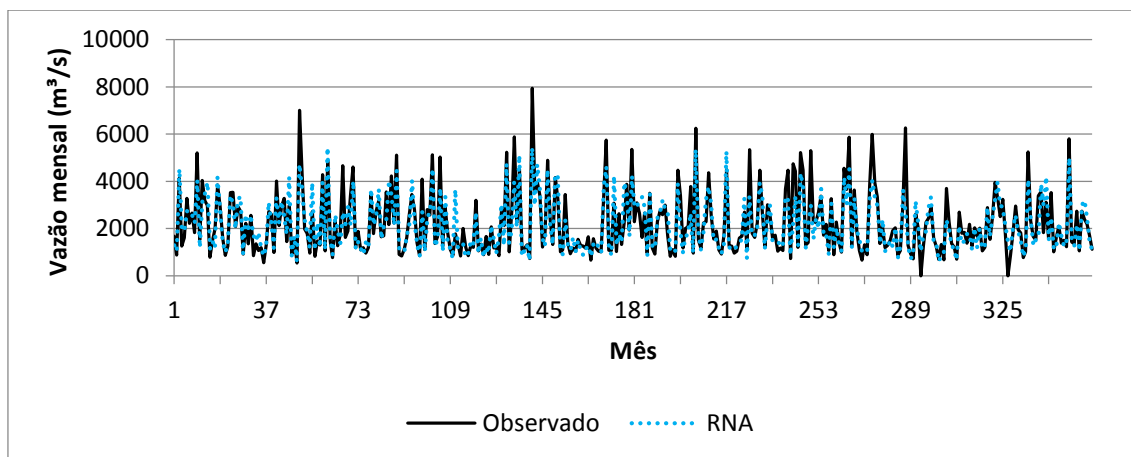


Figura 42- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – ALTO PARANAÍBA (EMBORCAÇÃO)

Fonte: O autor (2014)




Figura 43- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)




Figura 44- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 45- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)




Figura 46- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 47- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)




Figura 48- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 49- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)




Figura 50- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA – BACIA DO RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

7.2 POTENCIAL DAS RNA's NO PROCESSO CHUVA-VAZÃO MENSAL COM CENÁRIOS DE RCM's

Este tópico apresenta os resultados do uso das RNA's selecionadas para cada Bacia Hidrográfica estudada (Tabela 20) utilizando como dados de entrada as séries de precipitações e temperaturas simuladas pelos RCM's (PROMES e RCA) corrigidas. Os resultados são comparados com as vazões observadas no período de janeiro de 1991 a dezembro de 2006.

A Tabela 21 apresenta os coeficientes de Nash-Sutcliffe (NS), determinação (R^2) e a diferença percentual de volume escoado (DV) obtidos para cada Bacia Hidrográfica. Observa-se que nenhum modelo apresentou resultados satisfatórios.

As Figuras 51 a 59 apresentam os gráficos de dispersão dos pontos vazão observada *versus* vazão calculada através da RNA com séries do PROMES. Ao analisar os gráficos se observa que de modo geral os modelos não apresentaram bons resultados, pois os pontos ficaram bastante dispersos sobre a reta de 45°. Os melhores resultados obtidos foram para a bacia do Alto e Baixo Paranaíba (Figura 51 e Figura 52) e Paranapanema (Figura 56) com coeficientes de Nash-Sutcliffe de -0,19; 0,09 e 0,01 respectivamente. Os piores resultados obtidos foram para a Bacia do Alto Rio Grande (Figura 53) e a bacia do Paraná (Figura 57), com coeficientes de Nash-Sutcliffe de -0,51 e 5,29

respectivamente, estes resultados já eram esperados visto que os modelos RNA's criados não apresentaram bons resultados durante o treino e a validação (Tabela 20).

Tabela 21 – DESEMPENHO DAS RNA COM USO DAS SÉRIES SIMULADAS PELO PROMES E RCA (01/91 a 12/06)

	BACIA HIDROGRÁFICA	RNA	PROMES			RCA		
			NS	R ²	DV(%)	NS	R ²	DV(%)
1	Alto Paranaíba	'R24B30E22'	-0,19	0,42	0,01	-2,04	0,48	-68,65
2	Baixo Paranaíba	'R42D30E42'	0,09	0,30	27,02	-0,50	0,03	24,89
3	Alto Rio Grande	'R44A60E42'	-0,51	0,08	-49,26	-0,83	0,17	-62,13
4	Baixo Rio Grande	'R43D90E42'	-0,23	0,24	-9,87	-1,51	0,01	-7,45
5	Tietê	'R64C30E62'	-0,08	0,25	30,21	-0,77	0,10	30,21
6	Paranapanema	'R64C30E63'	0,01	0,08	-5,49	-0,48	0,02	18,35
7	Paraná	'R41A30E43'	-5,29	0,00	86,44	-5,81	0,51	90,10
8	Iguaçu	'R22F90E23'	-0,58	0,00	38,84	-0,28	0,01	36,28
9	Uruguai	'R41A60E42'	-0,61	0,00	-1,84	-0,65	0,02	-14,95

Fonte: O autor (2014)




Figura 51 – OBSERVADA VERSUS RNA (PROMES) – BACIA DO ALTO PARANAÍBA (EMBORÇAÇÃO)

Fonte: O autor (2014)




Figura 52 – OBSERVADA VERSUS RNA (PROMES) – BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)




Figura 53– OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 54– OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)




Figura 55 – OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 56- OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)




Figura 57- OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 58 – OBSERVADA *VERSUS* RNA (PROMES) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)




Figura 59- OBSERVADA *VERSUS* RNA (PROMES) – BACIA RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

As Figuras 60 a 68 apresentam os gráficos de dispersão dos pontos vazão observada *versus* vazão calculada através da RNA utilizando-se como dados de entrada as séries de precipitação e temperatura simuladas pelo RCA.




Figura 60 – OBSERVADA *VERSUS* RNA (RCA) – BACIA DO ALTO PARANAÍBA (EMBORAÇÃO)

Fonte: O autor (2014)




Figura 61– OBSERVADA *VERSUS* RNA (RCA) – BACIA DO BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)




Figura 62– OBSERVADA *VERSUS* RNA (RCA) – BACIA DO ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 63– OBSERVADA *VERSUS* RNA (RCA) – BACIA DO BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)




Figura 64 – OBSERVADA *VERSUS* RNA (RCA) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 65- OBSERVADA *VERSUS* RNA (RCA) – BACIA DO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)




Figura 66- OBSERVADA *VERSUS* RNA (RCA) – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 67 – OBSERVADA *VERSUS* RNA (RCA) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)




Figura 68- OBSERVADA *VERSUS* RNA (RCA) – BACIA RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

Observa-se que de modo geral os modelos não apresentaram bons resultados, os pontos ficaram bastante dispersos sobre a reta de 45°. Os melhores resultados obtidos foram para a bacia do Baixo Paranaíba (Figura 61) e Baixo Rio Grande (Figura 63), com coeficientes de Nash-Sutcliffe de -0,50 e -1,51 respectivamente. Os piores resultados obtidos foram para a Bacia do Alto Rio Grande (Figura 62) e a bacia do Paraná (Figura 66) com coeficientes de Nash-Sutcliffe de -0,83 e -5,81 respectivamente. Assim como no caso anterior, estes resultados já eram esperados visto que os modelos RNA's criados não apresentaram bons resultados durante o treino e a validação (Tabela 20).

7.3 COMPARAÇÃO DOS MODELOS RNA E VIC

Uma comparação entre os resultados obtidos pelo modelo RNA com os resultados do modelo VIC (SAURRAL, 2010 e CLARIS LPB, 2009) é apresentada neste item. A análise foi feita para dois períodos distintos: período com dados observados e período futuro. O período com dados observados compreende janeiro de 1991 a dezembro de 2006 já o período futuro compreende janeiro de 2007 a dezembro de 2095.

A Tabela 22 apresenta os coeficientes de Nash-Sutcliffe entre a vazão observada e as vazões calculadas com o uso do modelo RNA e VIC utilizando

como dados de entrada as precipitações e temperaturas simuladas pelos modelos climáticos PROMES e RCA.

Ao analisar os resultados da Tabela 22, pode-se concluir que nenhum modelo (RNA e VIC) apresentou coeficientes de Nash-Sutcliffe satisfatório. A bacia que apresentou o pior resultado para as RNA's foi a Bacia do Rio Paraná tanto com o uso das séries do PROMES quanto com as do RCA (Nash-Sutcliffe -5,289 e -5,819 respectivamente) e o pior resultado obtido para o modelo VIC foi na Bacia do Alto Paranaíba para o modelo PROMES e a Bacia do Rio Paranapanema para o modelo RCA (Nash-Sutcliffe -4,22 e -3,08 respectivamente).

Tabela 22 – COMPARAÇÃO DO DESEMPENHO MODELO RNA E VIC COM USO DAS SÉRIES GERADAS PELOS RCM's (01/1991 A 12/2006)

BACIA HIDROGRÁFICA	PROMES		RCA	
	RNA	VIC	RNA	VIC
1- Alto Paranaíba (Emborcação)	-0,19	-4,22	-2,04	-0,86
2- Baixo Paranaíba (São Simão)	0,09	-3,33	-0,50	-0,62
3- Alto Rio Grande (Furnas)	-0,51	-2,00	-0,83	-1,75
4- Baixo Rio Grande (Água Vermelha)	-0,23	-2,14	-1,51	-1,86
5-Tiête (Nova Avanhandava)	-0,08	-2,46	-0,77	-1,23
6- Paranapanema (Capivara)	-0,01	-1,79	-0,48	-3,08
7- Paraná (Itaipu)	-5,29	-2,23	-5,81	-1,24
8- Iguaçu (Salto Osório)	-0,58	-1,01	-0,28	-1,72
9- Uruguai (Itá)	-0,61	-1,42	-0,65	-1,18

Fonte: O autor (2014)

Outra análise que se pode inferir da Tabela 22 é qual modelo (RNA ou VIC) foi melhor para descrever a vazão quando usadas as séries de precipitações e temperaturas simuladas pelo PROMES e RCA. Quando usadas as séries simuladas pelo modelo PROMES, pode-se concluir que, apesar do baixo valor do coeficiente de Nash-Sutcliffe o modelo RNA foi melhor que o VIC em oito dos nove locais de estudo, sendo inferior apenas na Bacia do Rio Paraná. Já para os resultados obtidos com as séries de temperatura e precipitação simuladas pelo modelo RCA a RNA foi melhor em sete dos nove

locais de estudo, apenas nas Bacias do Alto Paranaíba e Paraná o modelo VIC foi melhor.

As Figuras 69 a 77 apresentam fluviogramas das vazões mensais geradas para o período histórico pelo modelo RNA utilizando-se das séries corrigidas do PROMES, o modelo VIC utilizando-se das séries do PROMES e o fluviograma dos dados observados.




Figura 69- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – ALTO PARANAÍBA (EMBORCAÇÃO)

Fonte: O autor (2014)




Figura 70- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)




Figura 71- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 72- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)




Figura 73- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 74- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)




Figura 75- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 76- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)




Figura 77- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (PROMES) PERÍODO OBSERVADO – BACIA DO RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

Os fluviogramas (Figura 69 a 77) comprovam o que foi concluído previamente da análise da Tabela 22 que nenhum modelo foi capaz de descrever o processo chuva-vazão de modo satisfatório quando utilizado as séries simuladas pelo modelo PROMES como dados de entrada. Conforme já observado anteriormente durante a validação dos modelos, nenhuma das RNA's foi capaz de descrever os picos de vazões. Já o modelo VIC apresentou picos de vazão que não ocorreram.

Nas Figuras 78 á 86 são apresentados fluviogramas das vazões mensais geradas para o período histórico pelo modelo RNA utilizando-se das séries corrigidas do RCA, o modelo VIC utilizando como dados de entradas as séries simuladas pelo RCA e os fluviogramas para os dados observados.

Ao analisar o Alto Paranaíba (Figura 78) observa-se que a RNA superdimensiona a quantidade de água quando comparados com os dados observados. Já as bacias do Alto Rio Grande e Paraná (Figura 80 e Figura 84) apresentaram resultados ruins, podendo-se notar pequena amplitude nas séries de vazões geradas. Já o modelo VIC de modo geral, conseguiu apresentar vazões pequenas e médias coerentes com os valores observados, porém apresentou picos de vazão que não foram observados.




Figura 78- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – ALTO PARANAÍBA (EMBORCAÇÃO)

Fonte: O autor (2014)




Figura 79- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)




Figura 80- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 81- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)




Figura 82- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 83- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)




Figura 84- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)




Figura 85- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)




Figura 86- FLUVIOGRAMA VAZÃO OBSERVADA E GERADA POR RNA E VIC (RCA)
PERÍODO OBSERVADO – BACIA DO RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

Os resultados apresentados a seguir referem-se ao período futuro (janeiro de 2006 a dezembro de 2095).

As Figuras 87 a 95 apresentam fluviogramas das vazões médias mensais geradas pela RNA com as séries corrigidas do PROMES e pelo VIC utilizando-se das séries simuladas pelo PROMES.




Figura 87- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – ALTO PARANAÍBA (EMBORÇAÇÃO)

Fonte: O autor (2014)

A Figura 87 apresenta uma comparação das vazões mensais geradas pela RNA (azul) e o modelo VIC (vermelho) para a Bacia do Alto Paranaíba. Pode-se notar que o modelo VIC apresenta picos de vazões consideravelmente superiores aos apresentados pela RNA. Para vazões médias e baixas os modelos apresentaram comportamentos parecidos. As séries de vazões geradas pela RNA apresentaram um intervalo de variação de aproximadamente 0 a 2.000 m³/s enquanto as séries geradas pelo modelo VIC apresentaram variações próximas de 0 a 12.000 m³/s. O modelo VIC apresentou um cenário futuro com mais água na bacia, quando comparado com a RNA, devido aos picos de vazões.




Figura 88- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)

Pode-se notar na Figura 88, Baixo Paranaíba, que a amplitude da série de vazões mensais geradas pelo modelo VIC foram maiores que as geradas pela RNA. O intervalo da série de vazões geradas pela RNA ficou entre 2.000 a 7.000 m³/s enquanto o VIC ficou próximo de 0 a 52.500 m³/s. Nota-se também que o modelo VIC apresentou um cenário futuro com mais água na bacia que o gerado por uma RNA.

Ao analisar a Figura 89, Alto Rio Grande, pode-se observar a diferença da amplitude dos resultados gerados. Os resultados obtidos pela RNA oscilaram próximos a 1.750 m³/s enquanto os resultados gerados pelo VIC apresentaram um intervalo de variação de aproximadamente 0 a 10.000m³/s. Esta incapacidade da RNA em descrever as vazões já era esperada, visto que o modelo já apresentou resultados ruins no treinamento e validação. A RNA descreve um futuro com vazões mais regulares e menores enquanto o modelo VIC descreve um futuro com vazões menos homogêneas. Outra evidência que se pode notar é a incapacidade da RNA de descrever as variações das vazões.




Figura 89- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)




Figura 90- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)

A partir da análise da Figura 90, Baixo Rio Grande, pode se observar fenômeno parecido com o ocorrido no Baixo Paranaíba (Figura 88). A RNA apresentou vazões pequenas e médias próximas ao modelo VIC, porém o modelo VIC apresentou picos de vazões consideravelmente maiores que a RNA. As vazões simuladas pela RNA apresentaram um intervalo de variação de aproximadamente 200 a 5.200 m³/s enquanto que o as geradas pelo modelo VIC ficaram no intervalo de 0 a 30.000 m³/s. Baseados nas previsões, o modelo RNA descreve um cenário futuro com menos água na bacia em relação ao modelo VIC.




Figura 91 FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)

Para a Bacia do Rio Tietê, Figura 91, os resultados obtidos pela RNA e VIC apresentaram resultados semelhantes para vazões pequenas e médias, porém como no caso anterior, o modelo VIC apresentou picos de vazão superiores aos da RNA. O intervalo de variação das vazões simuladas pelo modelo RNA variou entre de 0 a 1.900 m³/s enquanto que as simuladas pelo VIC ficaram contidas no intervalo de 0 a 8.000 m³/s. Baseados nas previsões, o modelo RNA descreve um cenário futuro com menos água na bacia em relação ao modelo VIC.




Figura 92- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)

A Figura 92 apresenta as simulações para a Bacia do Rio Paranapanema. Diferentemente do caso anterior (Figura 91) pode-se observar que as vazões geradas pela RNA apresentaram valores diferentes tanto para pequenas, médias e altas vazões. Nota-se que a série de vazões simulada pela RNA apresentou menos água na bacia quando comparada com o modelo VIC. A RNA apresentou intervalo de variação das vazões entre de 100 a 2.000 m³/s enquanto a série gerada pelo modelo VIC variou no intervalo de aproximado de 0 a 12.000 m³/s.




Figura 93- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES)
(01/2006 – 12/2095) – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)

Observa-se para Bacia do Rio Paraná, Figura 93, a grande diferença de ordem de grandeza dos resultados obtidos. Enquanto que o intervalo de variação das vazões geradas pelos modelo RNA variaram entre 100 a 2.500 m³/s as vazões simuladas pelo VIC variaram no intervalo de 100 a 15.000 m³/s.




Figura 94- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)

A Figura 94 apresenta os resultados para a Bacia do Rio Iguaçu. Pode-se notar que para vazões pequenas e médias os modelos apresentaram comportamentos parecidos, porém o modelo VIC apresentou picos de vazões que não foram observados no modelo RNA. Enquanto as séries simuladas pela RNA apresentam intervalo de 100 a 2.000m³/s a séries de vazões geradas pelo VIC apresentou variação de valores próximos de 0 a 13.500 m³/s.




Figura 95- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (PROMES) (01/2006 – 12/2095) – BACIA DO RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

Os resultados obtidos para a Bacia do Rio Uruguai estão apresentados na Figura 95. Observa-se que as vazões apresentadas pelo modelo RNA apresentaram valores mais elevados para pequenas e médias vazões, porém o

modelo apresenta picos de vazões maiores que a RNA. O intervalo de variação das vazões geradas pelo modelo RNA está contido entre 0 a 4.500 m³/s e as vazões simuladas pelo VIC variaram no intervalo de 0 a 15.000 m³/s.

Das Figuras 96 a 104 são apresentados os fluviogramas das vazões médias mensais geradas pela RNA com as séries corrigidas do RCA e pelo VIC utilizando-se das séries simuladas pelo RCA.

Os resultados para o Alto Paranaíba estão apresentados na Figura 96. Nota-se, salvo para os picos de vazão, que o modelo RNA apresentou vazões maiores que o VIC. O intervalo de variação das vazões simuladas pela RNA ficou entre 200 a 2.000 m³/s enquanto a série gerada pelo VIC ficou entre 0 a 11.000 m³/s.




Figura 96- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2009) – ALTO PARANAÍBA (EMBORCAÇÃO)

Fonte: O autor (2014)

A Figura 97 apresenta os resultados para o Baixo Paranaíba. Como para o Alto Paranaíba (Figura 96) as séries de vazões mensais ficaram parecidas, salvo para os picos de vazões. As vazões simuladas pela RNA estão contidas no intervalo de 100 a 5.500 m³/s enquanto que para o modelo VIC ficaram entre 100 a 47.000 m³/s.




Figura 97 FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2009) – BAIXO PARANAÍBA (SÃO SIMÃO)

Fonte: O autor (2014)

No Alto Rio Grande (Figura 96) pode-se notar a diferença das séries geradas. A série gerada pela RNA apresenta pequena amplitude enquanto a gerada pelo VIC apresenta alta amplitude. As vazões geradas pela RNA oscilaram em valores próximos a 1.800 m³/s enquanto que as vazões geradas pelo VIC ficaram contidas no intervalo de 100 a 8.000 m³/s.




Figura 98- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2009) – ALTO RIO GRANDE (FURNAS)

Fonte: O autor (2014)

Ao analisar os resultados do Baixo Rio Grande (Figura 99) nota-se uma semelhança nos resultados simulados para as pequenas e médias vazões, porém os picos de vazão são mais acentuados no modelo VIC. Enquanto as vazões simuladas pela RNA encontram-se no intervalo de 100 a 12.500 m³/s as vazões do VIC encontram-se no intervalo de 0 a 20.000 m³/s.




Figura 99- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BAIXO RIO GRANDE (ÁGUA VERMELHA)

Fonte: O autor (2014)

A Figura 100 apresenta os resultados das simulações para a Bacia do Rio Tietê. Pode-se notar que o modelo VIC simulou mais água na bacia que o modelo RNA. O intervalo de variação das vazões geradas pelo modelo RNA ficou entre 200 a 1.500 m³/s enquanto o modelo VIC ficou entre valores próximos de 0 a 3.000 m³/s.




Figura 100- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO TIÊTE (NOVA AVANHANDAVA)

Fonte: O autor (2014)




Figura 101- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO RIO PARANAPANEMA (CAPIVARA)

Fonte: O autor (2014)

Ao analisar os resultados sobre a Bacia do Rio Paranapanema (Figura 101), pode-se notar a baixa variação das vazões geradas pela RNA em relação ao VIC. As vazões geradas pela RNA ficaram contidas no intervalo de 100 a 2.000m³/s enquanto as vazões geradas pelo VIC estão contidas no intervalo de 0 a 30.000m³/s. Outro fato que se pode notar é a falha da série simulada pelo modelo VIC para os meses 650 a 775.




Figura 102- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2095) – BACIA DO RIO PARANÁ (ITAIPU)

Fonte: O autor (2014)

A Figura 102 apresenta os resultados para a Bacia do Rio Paraná. Nota-se que o modelo RNA apresentou mais água que o VIC para vazões pequenas e médias enquanto os picos de vazão do modelo VIC são maiores. As vazões

geradas pela RNA variaram no intervalo entre 100 a 4.000 m³/s e as vazões do VIC ficaram contidas no intervalo de 0 a 19.000 m³/s.




Figura 103- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) (01/2006 – 12/2005) – BACIA DO RIO IGUAÇU (SALTO OSÓRIO)

Fonte: O autor (2014)

Os resultados para a Bacia do Rio Iguaçu estão apresentados na Figura 103. Observa-se que o modelo VIC apresentou uma previsão com mais água que o modelo RNA com picos de vazão com ordem de grandeza maior. O intervalo de vazões mensais do VIC ficou contido entre 0 a 125.000m³/s enquanto as vazões simuladas pela RNA ficaram entre 500 a 2.000m³/s.




Figura 104- FLUVIOGRAMA VAZÃO GERADA PELOS MODELOS RNA E VIC (RCA) – BACIA DO RIO URUGUAI (ITÁ)

Fonte: O autor (2014)

A Figura 104 apresenta os resultados obtidos para a Bacia do Rio Uruguai. Ao analisar a Figura 104 pode-se notar que os resultados obtido pela RNA apresentaram mais água para as vazões pequenas e médias enquanto que o modelo VIC apresentou picos de vazão maiores que os da RNA. O intervalo de variação das vazões simuladas pelas RNA's estão compreendidas entre 100 a 4.000 m³/s enquanto as vazões geradas pelo VIC ficaram entre 100 a 19.000 m³/s.

8. CONCLUSÕES E RECOMENDAÇÕES

O objetivo geral deste trabalho foi modelar o processo de transformação de chuva em vazão em escala mensal através da utilização de uma RNA. Foi adotada esta técnica devido a dois fatores. O primeiro é a capacidade de uma RNA em descrever processos não lineares e o segundo devido ao sucesso em trabalhos anteriores que utilizaram RNA para descrever o processo chuva-vazão. Para se chegar à configuração mais próxima do ideal, foram testados 1.296 diferentes tipos de RNA's variando o tipo de entrada (Quadro 2), a extensão da entrada, a quantidade de neurônios na camada intermediária e o número de *epochs* para cada bacia hidrográfica estudada.

Ao fim desta etapa inicial, pode-se perceber que as RNA's foram capazes de descrever o processo chuva-vazão para 7 das 9 regiões estudadas. Obteve-se um coeficiente de Nash-Sutcliffe de 0,27 para a bacia do Alto Rio Grande, 0,42 para a Bacia do Rio Paraná e para o restante das bacias, o coeficiente variou entre 0,64 a 0,81. Justifica-se a obtenção de resultados ruins para as Bacias do Alto Rio Grande e do Rio Paraná devido ao uso de apenas uma estação climatológica e uma estação pluviométrica. As Bacias possuem grandes extensões, 52.000 e 822.150 km² respectivamente, e o uso de apenas uma estação pluviométrica e climatológica não foi suficiente para representar a chuva e a temperatura das bacias.

Definido o modelo de RNA para cada região, o passo seguinte foi analisar a tendência das séries simuladas pelos RCM's (PROMES e RCA). Esta investigação foi feita através de uma comparação das séries simuladas pelos RCM's e os dados observados de chuva para um período em comum. Foram comparadas as frequências, curvas de permanência e função de distribuição acumulada para as mínimas e máximas. Ao fim desta comparação, pode-se concluir que as séries simuladas pelos RCM's possuíam *bias*.

Foram propostos três métodos para correção do *bias* das séries de precipitação e temperatura. O primeiro modelo chamado de método da correção linear e outros dois métodos baseados em correção por RNA. De modo geral, o método de correção linear foi o mais efetivo para correção do *bias* das séries. Ainda que as correções aplicadas apresentaram melhora nos coeficientes de Nash-Sutcliffe na maioria das séries simuladas, estas ainda

continuaram ruins. Com os dados dos *bias* corrigidos e os modelos (RNA's) definidos para cada região, a próxima etapa foi gerar as séries de vazões. Estas séries foram geradas com as séries de precipitação e temperatura dos RCM's corrigidas e divididas em dois períodos: o período histórico e o futuro. A série do período histórico foi comparada com os dados de vazões observadas e as vazões simuladas pelo VIC com o uso das séries de precipitações e temperaturas simuladas pelos RCM's. Já para o período futuro foram comparados os resultados gerados pelo modelo VIC com os gerados pela RNA's.

Diferentemente dos resultados obtidos pelas RNA's quando utilizados registros observados, os resultados obtidos para as RNA's com as séries simuladas pelos RCM's podem ser considerados ruins. Este fato ocorreu devido a dois fatores. O primeiro é referente à má qualidade das séries de entrada e o segundo ocorreu devido à extensão do período treinado e a baixa capacidade das RNA's de extrapolar os resultados para conjunto de entradas muito diferentes dos utilizados para o treinamento e validação. Por se tratar de uma simulação longa (2006-2095) apareceram valores de chuva e temperatura menores e maiores que os utilizados para o treinamento das RNA's. A incapacidade das RNA's em descrever vazões altas já foi constatada desde os períodos de validações dos modelos.

Por fim, foram comparadas as séries de vazão geradas pelos modelos RNA e VIC para o período observado e futuro. A comparação entre o período observado foi baseada em análises de fluviogramas e o cálculo do coeficiente de Nash-Sutcliffe. De modo geral, nem o modelo VIC nem a RNA obtiveram resultados satisfatórios. Observou-se que o principal problema foi na representação dos picos de vazão, pois o modelo VIC, na maioria dos casos, superdimensionou enquanto que as RNA's subdimensionaram. Para o caso do uso das séries simuladas pelo PROMES a RNA obteve coeficientes de Nash-Sutcliffe melhores que o modelo VIC em oito das nove regiões estudadas, apenas na Bacia do Rio Paraná o modelo VIC foi melhor. Já com o uso das séries simuladas pelo RCA a RNA apresentou resultados melhores em sete dos nove locais estudados, apenas na Bacia do Alto Paranaíba e Paraná o modelo VIC foi melhor. Os resultados não foram melhores para ambos os

modelos devido à má qualidade das precipitações e temperatura simuladas pelos RCM's (Apêndice 2).

Para o período futuro pode-se notar que, na maioria dos casos analisados, houve comportamentos parecidos dos modelos para vazões pequenas e médias, porém o modelo VIC apresentou picos de vazões muito superiores aos observados pela RNA. As regiões do Alto Rio Grande, Nova Avanhandava, Capivara e Itá com usos das séries do PROMES e as regiões do Alto Paranaíba, Alto Rio Grande, Paraná e Itá com os usos das séries geradas pelo RCA apresentaram um cenário com mais água para as vazões pequenas e médias para RNA enquanto os picos de vazões maiores para o modelo VIC.

Pode-se concluir deste estudo, de modo geral, que as RNA's funcionam bem quando são utilizados como dados de entrada observados. Quando utilizadas as RNA's para previsões de médio e longo prazo não se obteve resultados bons, devido a baixa qualidade dos dados simulados pelos modelos climáticos.

Para estudos futuros, recomenda-se o uso de mais estações pluviométricas e climatológicas para bacias com grandes extensões e uma maior atenção na correção do *bias* das séries simuladas pelos modelos PROMES e RCA. Aconselha-se a utilização de métodos mais refinados de correção e de séries com menor escala temporal, como por exemplo, a escala diária. Uma sugestão para estudos futuros é a utilização das próprias séries simuladas e corrigidas pelos RCM's para treino e validação dos modelos chuva-vazão.

REFERÊNCIAS BIBLIOGRÁFICAS

- BAO, Z., FU, G., WANG, G., JIN, J., HE, R., YAN, X., LIU, C. Hydrological projection for the Miyun Reservoir basin with the impact of climate change and human activity. **Quaternary International**, v. 282, p. 96-103, 2012.
- BERG, P., FELDMANN, H., PANITZ, H., J. Bias correction of high resolution regional climate model data. **Journal of Hydrology**, 448-449, 2012.
- BLACK, T. L. The new NMC mesoscale Eta model: Description and forecast examples. **Weather and Forecasting**, 9: 265-278, 1994.
- BLODIN, C., Parametrization of land-surface process in numerical weather prediction, in land surface evaporation: measurements and parametrization, edited by T.J. Schumegge e J.C. André, pp 31-54, **Springer Verlag**, Nova York, 1991.
- BROOKS, R.H., e COREY A. T, Hydraulic properties of porous media, **Hydrol. Pap.3**, Colo State Univ., Ft. Collins, 1964.
- BRONSON, R. **Pesquisa Operacional**. São Paulo: McGraw-Hill do Brasil, 1985.
- BUCHIR, L. M. S. T. Método proposto para analisar a influência de mudanças climáticas nas precipitações. *Dissertação* - Universidade Federal do Paraná, 2012.
- CARCANO, E. C., BARTOLINI, P., MUSELLI, M., PIRODDI, P. L. Jordan recurrent neural network versus IHACRES in modelling daily streamflows. **Journal of Hydrology**, v. 362, n. 3-4, p. 291-307, dez. 2008.
- CASTRO, M., FERNÁNDEZ, C., GAERTNER, M. A. Description of a mesoscale atmospheric numerical model. In Díaz J.L., Lions J.L. (Eds). *Mathematics, climate and environment*. **Rech. Math. Appl. Serv. Manson**, pp: 230-253, 1993.
- CHADWICK, R., COPPOLA, E., GIORGI, F. An artificial neural network technique for downscaling GCM outputs to RCM spatial scale. **Nonlinear Processes in Geophysics**, vol. 18, 1013-1028, 2001.
- COLLINS, W. D., BITZ, C. M., BLACKMON, M. L., BONAN, G. B., BREHERTORNN C. S., CARTON. J. A., CHANG, P., DONEY, S., HACK, J. J., HENDERSON, T. B., KIEHL, J. T., LARGE, W. G., MCKENNA, D. S., SANTER, D. B., SMITH, R. S. The community Climate System Model Version 3 (CCSM3). **Journal of Climate**, v 19, p 2122-2143, set. 2005.
- DEARDOFF, J. W., Efficient prediction of ground surface temperature and moisture, with inclusion of a layer of vegetation. **Geophy. Res.**, 83, 1889-1903, 1978

DERECZYNSKI, C. P; PRISTO, M. V. J; CHOU, S. C; CAVALCANTI, I. F. A; ROZANTE, J. R. Avaliação das previsões do modelo ETA na região da serra do mar (estado de são paulo). **Anuário do Instituto de Geociências** – Universidade Federal do Rio de Janeiro. Brasil. Outubro de 2010. Disponível em:

www.anuario.igeo.ufrj.br. Acesso em: Novembro de 2012.

DICKINSON, R. E., Modelling evapotranspiration of three-dimensional global climatic models in climate processes and climate sensitivity, **Geophys. Monogr. Ser.**, vol 29, editada por Hansen e T. Takahashi, pp 58-72, AGU, Whasinton, D.C., 1984

DUCONDRE, N.I., LAVAL, K. e PERRIER, A. A new set of parametrizations of the hydrologic exchanges at the land-atmosphere interface within the LMD atmospheric general circulation model. **J. Clim**, 6, 248-273, 1993.

ELGUINDI, N., BI, X., NAGARAJAN, F. G. B., PAL, J., SOLMON, F., RAUSCHER, S. e ZARKEY, A. RegCM Version 3.1 User's Guide. Trieste, Itália 2007. Disponível em:

<http://users.ictp.it/RegCNET/regcm.pdf>. Acessado em 27/03/2013

FERNANDES, L. G. L., NAVAUUX, P. O. A. PORTUGAL, M. S. (1996) Previsão de séries de tempo: redes neurais artificiais e modelos estruturais. Pesquisa e Planejamento Econômico, **PPE** 26(2), 253–276.

FERREIRA, L. F. N. Modelo de redes neurais artificiais para transformação chuva-vazão mensal. 2012. **Trabalho de conclusão de curso** – Universidade Federal do Paraná, Curitiba, 2012.

FRANC, O. L; FAIRHEAD, L; HOURDIN, F. The stratospheric version of LMDZ: dynamical climatologies, arctic oscillation, and impact on the surface climate. **Climate Dynamics**, 25: 851–868. 2005. Disponível em:

http://www.lmd.jussieu.fr/~flott/articles/CDYN_05.pdf. Acesso em: novembro de 2012.

FRANCHINI, M.; PACCIANI, M. Comparative Analysis of several conceptual rainfall-runoff models. **Journal of Hydrology**. v. 122, p. 161-219, jan. 1990.

FRANCIANI, M., PACCIANI, M. Comparative analysis of several conceptual rainfall-runoff models. **Journal of Hydrology**, 122, 161-219, 1991

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

GARRIDO, J. E.; CAZORLA, E. A. D., CUARTERO, F., FERNÁNDEZ, I., GALLARDO, C. A parallel implementation of the regional atmospheric model PROMES proceedings of the world. **In Congress on engineering**. Volume I. London, U.K. July 1 – 3. 2009. Disponível em:

http://www.iaeng.org/publication/WCE2009/WCE2009_pp774-779.pdf. Acesso em: novembro de 2012.

GIORGI, F., HEWITSON B., CHRISTENSEN J., Fu C., JONES R., HULME M., MEARNS L., VON STORCH H., WHETTON P. Regional climate information - evaluation and projections. In IPCC WG1 TAR, 2001.

GIORGI, F., WHETTON, P.H., JONES, R.G., CHRISTENSEN, J.H., MEARNS, L.O., HEWITSON, B., VONSTORCH, H., FRANCISCO, R., JACK, C. (2001). Emerging patterns of simulated regional climatic changes for the 21st century due to anthropogenic forcings. **Geophysical Research Letters** vol. 28 p.3317-3320

GORNI, A. A. Redes neurais artificiais: uma abordagem revolucionária em inteligência artificial. **Micro Sistemas**, nº 133, nov. dez. 1993

GUO, J., GUO, S., LI, T. Daily runoff simulation in Poyang Lake Intervening Basin based on remote sensing data. **Procedia Environmental Sciences** v. 10, n. Esiat, p. 2740-2747, 2011.

HAYKIN, S. **Neural Networks – a comprehensive foundation**. New York: Macmillan College Publishing Co, 1994.

HOURLIN, F., MUSAT, I., BONY, S., BRACONNOT, P., CODRON, F., DUFRESNE, J. L., FAIRHEAD, L., FILIBERTI, M. A., FRIENDLINGSTEIN, P., GRANDPEIX, J., KRINNER, G., VAN, L. P., LI, Z., LOTT, F. The LMDZ4 general circulation model: climate performance and sensitivity to parametrized physics with emphasis on tropical convection. **Clim. Dyn.** 27:787-813. 2006

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. 25517-2530, Out. 1995.

IPCC. INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE IPCC 2001a: Climate Change 2001: Impacts, adaptation and vulnerability- contribution of working group 2 to the ipcc third assessment report. **Cambridge univ. press**. 2001.

IPCC. INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE IPCC 2001b: Climate Change 2001: Impacts, adaptation and vulnerability- contribution of working group 2 to the ipcc third assessment report. **Cambridge univ. press**. 2001.

IPCC . INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE IPCC 2001c: Climate Change 2001: The scientific basis-summary for policymakers and technical summary of the working group i report. **Cambridge Univ. Press**. 2001. 98 pp.

IPCC – Intergovernmental Panel on Climate Change. Cambridge University Press 1996. Disponível em:

http://www.ipcc.ch/index.htm#.T_RnTPJj0T0. Acesso em: 04 de Julho de 2012.

JOURDAIN, L; BEKKI, S; LOTT, F; LEFÉVRE, F. The coupled chemistry-climate model LMDZ-reprobus: description and evaluation of a transient simulation of the period 1980–1999. **Annales Geophysicae**, 26, 1391–1413. June 2008. Disponível em: <http://www.ann-geophys.net/26/1391/2008/angeo-26-1391-2008.pdf> . Acesso em: novembro de 2012.

JU, Q., YU, Z., HAO, Z., , ZHAO, J., LIU D. Neurocomputing Division-based rainfall-runoff simulations with BP neural networks and Xinanjiang model. **Neurocomputing**, v. 72, n. 13-15, p. 2873-2883, 2009.

KADIR, K., HALIM C., HARUN, K. O. Modeling and prediction of Turkey's electricity consumption using Artificial Neural Networks. **Energy Conversion and Management**, v. 50, p. 2719-2727, 2009.

KISI, O. Constructing neural network sediment estimation models using a data-driven algorithm. **Mathematics and Computers in Simulation**, v. 79, n. 1, p. 94-103, out. 2008.

KISI, O., SHIRI, J., NIKOOFAR, B. Forecasting daily lake levels using artificial intelligence approaches. **Computers and Geosciences**, v. 41, p. 169-180, 2012.

KISI, O. SHIRI, J., TOMBUL, M. Modeling rainfall-runoff process using soft computing techniques. **Computers and Geosciences**, v. 51, p. 108-117, 2013.

LEE, H., MCINTYRE, N., WHEATER, H., YOUNG, A. Selection of conceptual models for regionalisation of the rainfall-runoff relationship. **Journal of Hydrology**, v. 312, n. 1-4, p. 125-147, out. 2005.

LENDERINK, G., BUIHAND, A., DEURSEN, W. Estimative of future discharges of the river Rhine using two scenario methodologies: direct versus delta aproach, **Hydrological Earth System Science**, vol. 11, 1145-1159, 2007.

LIANG, X., LETTERMAIN, d. P. A simple hydrologically based model of land surface water and energy fluxes for general circulation models. **Journal of geophysical research**, v. 99, p. 14415-14428, 1994.

LIMA, C.H.R., FERREIRA 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.

LOUIS, J., A parametric model of the vertical eddy fluxes in the atmosphere, Boundary Layer. **Meteorol.**, 17, 187-202,1979.

MACHADO, F., MINE, M., KAVISKI, E., FILL, H. Monthly rainfall–runoff modelling using artificial neural networks. **Hydrological Sciences Journal** . v.53:3, p.349-361, 2011.

MACHADO, F. W. Modelagem chuva-vazão mensal utilizando redes neurais artificiais. **Dissertação de mestrado**- Universidade Federal do Paraná, 2005.

MARENGO, J. A. Mudanças Climáticas Globais e Regionais: Avaliação do Clima Atual do Brasil e Projeções de Cenários Climáticos do Futuro. **Revista Brasileira de Meteorologia** 16: p 1-18. 2001.

MATLAB. Neural network toolbox documentantion. Disponível em:<<http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/nnet.shtml?BB=1>> nov. 2012.

MESINGER, F. A blocking technique for representation of mountains in atmospheric models. **Meteor. Aeronautica**, 44: 195-202. 1984.

MISHRA, V. CHERKAUER, K. A., BOWLING, L. C. Changing thermal dynamics of lakes in the Great Lakes region : Role of ice cover feedbacks. **Global and Planetary Change**, v. 75, n. 3-4, p. 155-172, 2011.

MONTEITH, J. L., UNSWORTH, M.H. *Principle of environmental physics*, 291 pp., 2 ed., Routledge, Chapman e Hall, Nova York, 1990.

MULLER, I. I. Uma previsão de redes neurais artificiais na previsão do mercado acionário. Florianópolis, 1996, **Dissertação de mestrado** – Universidade Federal de Santa Catarina (UFSC).

MINE, M. R. M. ; FILL, H D ; KAVISKI, E. ; BESSA, M. R. ; FERNANDES, C V S ; SANTOS, I. ; CUNHA, L. M. . WATER RESOURCES IN LA PLATA BASIN IN THE CONTEXT OF CLIMATE CHANGE: Impact of the climate changes in hydropower. Partial report. CURITIBA: UFPR, 2009.

PNUD - PROGRAMA DAS NAÇÕES UNIDAS PARA O DESENVOLVIMENTO. A cooperação internacional em uma encruzilhada: ajuda, comércio e segurança num mundo desigual. Informe sobre desenvolvimento humano 2005. Madrid: **Mundi-Prensa**, 2005. Disponível em: <http://www.pnud.org>.

ROECKNER, E., BAUM, G., BONAVENTURA, L., BROKOP, R., ESCH, M., GIORGETTA, M., HAGEMANN, S., KIRCHNER, I., KORNBLUEH, L., MANZINI, E., RHODIN, A., SCHLESE, U., SCHULZWEIDA, U., TOMPKINS, A. **The atmospheric circulation model ECHAM5 part 1**. Hamburg, 2003.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review** vol 6 386-408, 1958.

RUMMUKAINEM, M., RAISANEM, B., BRINFELT, B., ULERSTIG, A. OMSTEDT, A., WILLEN, U., HANSSON, U., JONES, C. A regional climate

model for northern Europe : model description and results from the downscaling of two GCM control simulations. **Climate Dynamics**, v. 17, p. 339-359, 2001.

SAMUELSON, P., JONES, G. C., WILLEM, U., ULLERSTING A., GOLLVIK, S., HANSSON, U., JANSSON, C., KJELLSTROM, E., NIKULIN, G., WYSER, K. The Rossby Centre Regional Climate model RCA3: model description and performance. **Tellus** 63A, 4-23. 2010.

SAURRAL, R. I. The Hydrologic Cycle of the La Plata Basin in the WCRP-CMIP3 Multimodel Dataset. **Journal of Hydrometeorology**, v. 11, n. 5, p. 1083-1102, out. 2010.

SHIRI, J., NAZEMI, A. H., SADRADDINI, A. A., LANDERAS, G., KISI, O., FARD, A. F., MARTI, P. Global cross-station assessment of neuro-fuzzy models for estimating daily reference evapotranspiration. **Journal of Hydrology**, v. 480, p. 46-57, fev. 2013.

SHIRI, J.; KISI, O.; YOON, H. Predicting groundwater level fluctuations with meteorological effect implications - A comparative study among soft computing techniques. **Computers and Geosciences**. Artigo Aceito 2012.

SHUTTLEWORTH, W. J., Evaporation, in **Handbook of hydrology**, pp. 4.1-4.53, McGraw-Hill, Nova York, 1993.

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 previsão de enchentes baseado em redes neurais. **SIMPOSIO BRASILEIRO DE RECURSOS HÍDRICOS**, 13., 1999, Belo Horizonte. Relação de trabalhos. Belo Horizonte: ABRH, 1999. 1CD ROOM.

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

TEUTSCHBEIN, C., SEIBER, J. Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. **Journal of Hydrology** 456-457, 2012.

VICTORIA, D. C. Simulação hidrológica de bacias amazônicas utilizando o modelo de capacidade de infiltração variável (VIC). 2010. 84f. **Tese de Doutorado** em Ciências - Centro de Energia Nuclear na Agricultura, Universidade de São Paulo, Piracicaba, 2010.

WATANABE, S., KANAE, S., SETO, S., YEH, J. F., HIRABAYASHI, Y., OKI, T. Intercomparison of bias correction and precipitation simulated by multipli climate models. **Journal of Geophysical Research**, vol 117 d23114, 2012.

WERBOS, P.J. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Ph.D. Thesis, Committee on Applied Mathematics, Harvard U., 1974.

WILBY, R. L., WIGLEY, T. M. L. Downscaling general circulation model output. A review of methods and limitations. *Prog. Phys. Geogr.* Vol. 21, pag. 530-548, 1997.

WILBY, R. L., HASSAN, H., HANAKI, K. Statistical downscaling of hydrometeorological variables using general circulation model output. **Journal of Hydrology** vol.205, pag. 1-19, 1998

WILBY, R.L., WIGLEY, T.M.L., CONWAY, D., JONES, P.D., HEWITSON, B.C., MAIN, J., WILKS, D.S. Statistical downscaling of general circulation model output: a comparison of methods. **Water Resources Research**, Washington, v.34, n.11, p.2995-3008, 1998.

WOOD, E.F., LETTENMAIER, D.P., ZARTARIAN, V.G. A land-surface hydrology parametrization with subgrid variability for general circulation models, **Journal of Geophysical Research**, 97(D3), 2717-2728, 1992.

WU, C,L. CHAU K. W. Rainfall–runoff modeling using artificial neural network coupled with singular. **Journal of Hydrology**, v. 399, p. 394-409, 2011.

ZHANG, X., LIU, Y., FANG, Y., LIU, B., XIA, D. Modeling and assessing hydrologic processes for historical and potential land-cover change in the Duoyingping watershed, southwest China. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 53-54, p. 19-29, jan. 2012.

ZHANG, B., GOVINDARAJU, S. Prediction of watershed runoff using bayesian concepts and modular neural networks. **Water Resour. Res.** 36 (3), 753–762, 2000.

ZHAO, R. J., ZHANG, Y. L., FANG, L. R. The Xinajiang model. In: Paper presented at Hydrological Forecasting Proceeding Oxford Symposium, IASH 129, pag. 351-356, 1980.

APÊNDICE

APÊNDICE 1 – ANÁLISE DO “BIAS” NAS SÉRIES SIMULADAS PELO PROMES E RCA

APÊNDICE 2 – COMPARATIVO DAS PRECIPITAÇÃO E TEMPERATURA OBSERVADAS, SIMULADAS E CORRIGIDAS

**APÊNDICE 1 – ANÁLISE DO “BIAS” NAS SÉRIES SIMULADAS PELO
PROMES E RCA**




Figura 1a - HISTOGRAMA DE CHUVAS MENSAIS OBSERVADAS - MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2013)




Figura 1e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS - ESTAÇÃO MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 1i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS ACUMULADAS - ESTAÇÃO MONTE ALEGRE DE MINAS

Fonte: O autor (2014)




Figura 2a - HISTOGRAMA DE CHUVAS MENSAIS OBSERVADAS - ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 2b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 2c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 2d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 2e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 2f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)





Figura 2g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO USINA COURO DO CERVO (REGIÃO SUDESTE)

Figura 2h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS - ESTAÇÃO DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)

Fonte: O autor (2014)




Figura 2i- FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS ACUMULADAS - ESTAÇÃO MONTE ALEGRE DE MINAS

Fonte: O autor (2014)




Figura 3a - HISTOGRAMA DE CHUVAS MENSAIS OBSERVADAS - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)

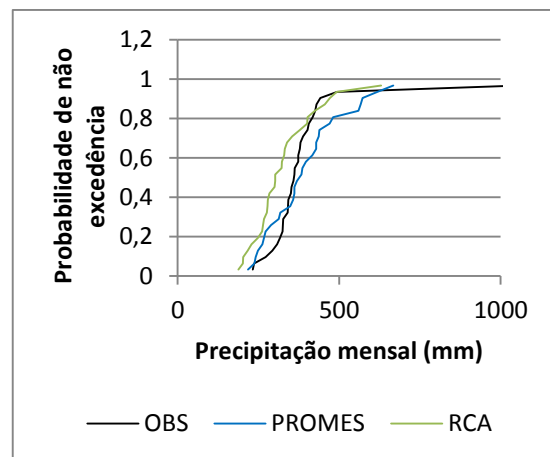


Figura 3h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS - FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 3i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS ACUMULADAS - ESTAÇÃO FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2013)




Figura 4a - HISTOGRAMA DE CHUVAS MENSAS OBSERVADAS - ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 4b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 4c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 4d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 4e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 4f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)





Figura 4g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)

Fonte: O autor (2014)




Figura 4i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS ACUMULADAS - ESTAÇÃO FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 5a - HISTOGRAMA DE CHUVAS MENSAS OBSERVADAS - ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)

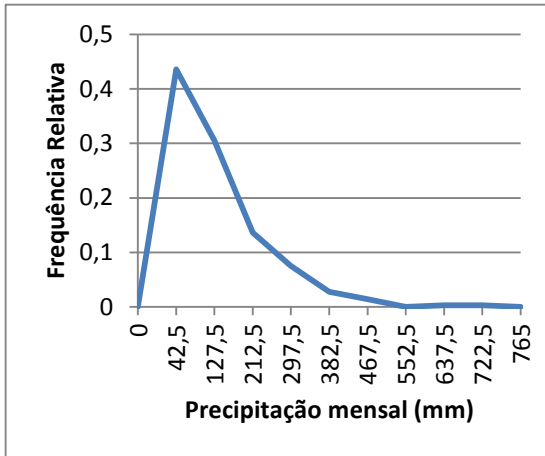


Figura 5e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS – TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 5i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS ACUMULADAS - ESTAÇÃO TOMAZINA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6a - HISTOGRAMA DE CHUVAS MENSAIS OBSERVADAS - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 6f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)


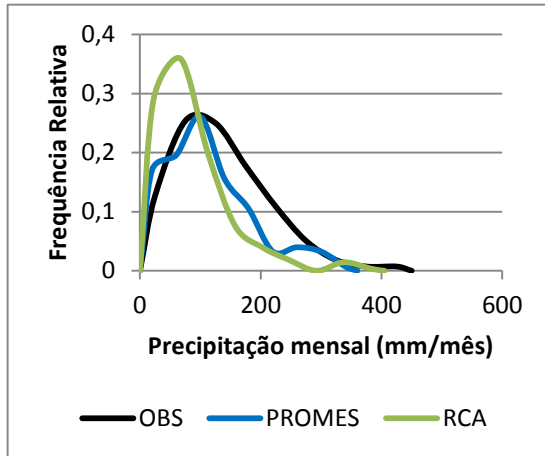


Figura 6g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Figura 6h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)

Fonte: O autor (2014)




Figura 6i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 7a - HISTOGRAMA DE CHUVAS MENSAIS OBSERVADAS - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 7b - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO PROMES - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 7c - HISTOGRAMA DE CHUVAS GERADAS PELO MODELO RCA - ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 7d - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS- ESTAÇÃO LAGOA VERMELHA (REGIÃO SUL)

Fonte: O autor (2014)




Figura 7e - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO PROMES – ESTAÇÃO CAIUÁ (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 7f - POLÍGONO DE FREQUÊNCIA DAS PRECIPITAÇÕES GERADAS PELO MODELO RCA – ESTAÇÃO CAIUÁ (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 7g - POLÍGONOS DE FREQUÊNCIA DAS PRECIPITAÇÕES OBSERVADAS E GERADAS PELOS MODELOS PROMES E RCA - ESTAÇÃO CAIUÁ (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 7h - FDA DAS PRECIPITAÇÕES MÁXIMAS ANUAIS – ESTAÇÃO CAIUÁ (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 7i - FDA DAS PRECIPITAÇÕES MÍNIMAS ANUAIS - ESTAÇÃO CAIUÁ (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 8a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) - MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 8b - CURVA DE PERMANÊNCIA (OBSERVADO E RCA) - MONTE ALEGRE DE MINAS (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 9a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 9b - CURVA DE PERMANÊNCIA (OBSERVADO E RCA) USINA COURO DO CERVO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 10a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) - FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 10b - - CURVA DE PERMANÊNCIA (OBSERVADO E RCA) FRANCA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 11a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) - FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 11b - CURVA DE PERMANÊNCIA (OBSERVADO E RCA) - FAZENDA BARREIRINHO (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 12a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) - TOMAZINA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 12b - CURVA DE PERMANÊNCIA (OBSERVADO E RCA) - TOMAZINA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 13a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) – LAGOA VERMELHA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 13b - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) – LAGOA VERMELHA (REGIÃO SUDESTE)

Fonte: O autor (2014)




Figura 14a - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) – CAIUÁ (REGIÃO SUL)

Fonte: O autor (2014)




Figura 14b - CURVA DE PERMANÊNCIA (OBSERVADO E PROMES) – CAIUÁ (REGIÃO SUL)

Fonte: O autor (2014)

**APÊNDICE 2 – COMPARATIVO DAS PRECIPITAÇÕES E TEMPERATURAS
OBSERVADAS, SIMULADAS E CORRIGIDAS**




Figura 1 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – ALTO PARANAÍBA (GOIÂNIA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 2 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – ALTO PARANAÍBA (MONTE CARMELO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 3– SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – BAIXO PARANAÍBA (GOIÂNIA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 4 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – ALTO PARANAÍBA (MONTE CARMELO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 5 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – BAIXO PARANAÍBA (CATALÃO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 6 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – BAIXO PARANAÍBA (MONTE ALEGRE DE MINAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 7 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – BAIXO PARANAÍBA (CATALÃO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 8 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – BAIXO PARANAÍBA (MONTE ALEGRE DE MINAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 9 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – ALTO RIO GRANDE (FRANCA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 10 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – ALTO RIO GRANDE (FRANCA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 11 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – ALTO RIO GRANDE (FRANCA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 12 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – ALTO RIO GRANDE (FRANCA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 13 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – BAIXO RIO GRANDE (LAVRAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 14– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – BAIXO RIO GRANDE (USINA COURO DO CERVO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 15 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – BAIXO RIO GRANDE (LAVRAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 16 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – BAIXO RIO GRANDE (USINA COURO DO CERVO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 17 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – BAIXO RIO GRANDE (LAVRAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 18– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO TIETÊ (CATANDUVAS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 19 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO TIETÊ (CATANDUVÁS) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 20 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO TIETÊ (FAZENDA RIBEIRINHO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 21 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO PARANAPANEMA (CASTRO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 22– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO PARANAPANEMA (TOMAZINA) - REGIÃO SUDESTE

Fonte: O autor (2014)

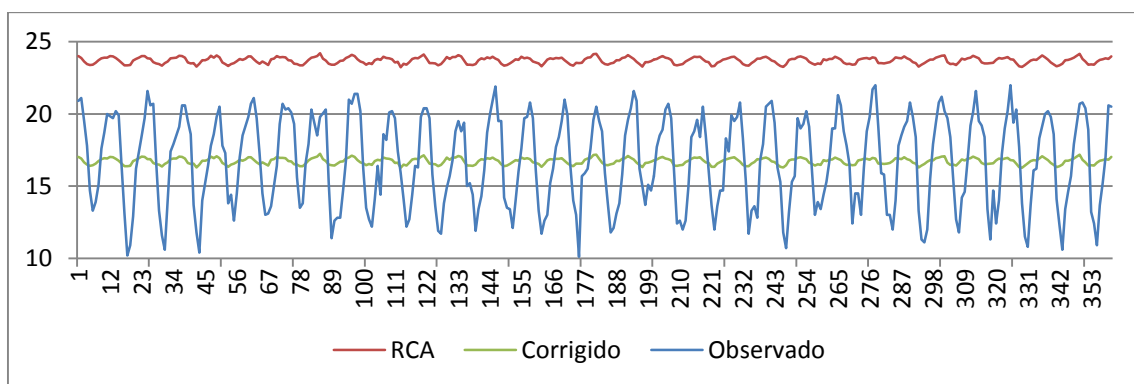


Figura 23 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO PARANAPANEMA (CASTRO) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 24 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO PARANAPANEMA (TOMAZINA) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 25 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO PARANÁ (PRESIDENTE PRUDENTE) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 26– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO PARANÁ (CAIUÁ) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 27 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO PARANÁ (PRESIDENTE PRUDENTE) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 28 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO PARANÁ (CAIUÁ) - REGIÃO SUDESTE

Fonte: O autor (2014)




Figura 29 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO IGUAÇÚ (CURITIBA) - REGIÃO SUL

Fonte: O autor (2014)




Figura 30– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO IGUAÇÚ (UNIÃO DA VITÓRIA) - REGIÃO SUL

Fonte: O autor (2014)




Figura 31 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO IGUAÇÚ (CURITIBA) - REGIÃO SUL

Fonte: O autor (2014)




Figura 32 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO IGUAÇÚ (UNIÃO DA VITÓRIA) - REGIÃO SUL

Fonte: O autor (2014)




Figura 33 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO URUGUAI (LAJES) - REGIÃO SUL

Fonte: O autor (2014)




Figura 34– SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO PROMES E CORRIGIDA (01/61 A 12/91) – RIO URUGUAI (LAGOA VERMELHA) - REGIÃO SUL

Fonte: O autor (2014)




Figura 35 – SÉRIE DE TEMPERATURA OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO URUGUAI (LAJES) - REGIÃO SUL

Fonte: O autor (2014)




Figura 36 – SÉRIE DE PRECIPITAÇÃO OBSERVADA, SIMULADA PELO RCA E CORRIGIDA (01/61 A 12/91) – RIO URUGUAI (LAGOA VERMELHA) - REGIÃO SUL

Fonte: O autor (2014)

ANEXO

ANEXO 1 – DESCRIÇÃO MODELO *VARIABLE INFILTRATION CAPACITY*

ANEXO 1 – DESCRIÇÃO MODELO *VARIABLE INFILTRATION CAPACITY*

Apresenta-se a seguir uma descrição de como o modelo *Variable Infiltration Capacity* (VIC) contabiliza a evapotranspiração, balanço hídrico na camada dossel, escoamento superficial da camada do solo exposto, escoamento superficial e escoamento subsuperficial para solo com cobertura vegetal.

EVAPOTRANSPIRAÇÃO

Três tipos de evaporações são consideradas no modelo: evaporação da camada dossel, transpiração da vegetação e evaporação através do solo exposto.

A evapotranspiração total é computada como a soma da evaporação da camada dossel, da vegetação e do solo exposto, ponderados pela sua respectiva fração de área coberta.

O máximo valor de evaporação da camada dossel para enésima classe de cobertura da superfície, $E_c^*[n]$, é dado pela Equação (60).

$$E_c^*[n] = \left(\frac{W_i[n]}{W_{im}[n]} \right)^{2/3} E_p[n] \frac{r_w[n]}{r_w[n] + r_0[n]} \quad (60)$$

onde:

$E_c^*[n]$: Máximo valor de evaporação da camada dossel para enésima classe de cobertura da superfície;

$W_i[n]$: Quantidade de água que foi armazenada na camada dossel;

$W_{im}[n]$: Quantidade máxima de água que a camada dossel pode interceptar;

n : Índice da classe da cobertura vegetal;

$E_p[n]$: Evaporação potencial para uma superfície baseada na Equação de Penman-Monteih com uma resistência da camada dossel ajustada como zero (SHUTTLEWORTH, 1993);

$r_w[n]$: Resistência aerodinâmica da transferência de água;

$r_0[n]$: Resistência de superfície.

A quantidade máxima de água que a camada dossel pode interceptar é calculada através da Equação (61) (DICKINSON, 1984):

$$W_{im}[n] = K_L LAI[n, m] \quad (61)$$

onde:

$LAI[n, m]$: Índice de área foliar para a enésima classe de cobertura da superfície em um dado mês m ;

K_L : Constante assumida como 0,2 mm conforme DICKINSON, 1984.

A resistência aerodinâmica da transferência de água ($r_w[n]$) é calculada segundo MONTEITH e UNSWORTH, 1990 (Equação (62)):

$$r_w[n] = \frac{1}{C_w[n]u_n(z_2)} \quad (62)$$

onde:

$u_n(z_2)$: Velocidade do vento para enésima classe de cobertura para o nível $z_2[n]$;

$C_w[n]$: Coeficiente de transferência de água.

O coeficiente de transferência de água ($C_w[n]$) é estimado baseado na estabilidade atmosférica segundo a Equação (63) (LOUIS, 1979):

$$C_w[n] = 1,351 a^2[n] F_w[n] \quad (63)$$

onde:

$a^2[n]$: Coeficiente de arrasto para estabilidade quase neutra;

$F_w[n]$: Definido por LOUIS (1979).

O coeficiente de arrasto para estabilidade quase neutra ($a^2[n]$) é calculado através da Equação (64):

$$a^2[n] = \frac{K^2}{\left[\ln \left(\frac{z_2[n] - d_0[n]}{z_0[n]} \right) \right]^2} \quad (64)$$

onde:

K : Constante de von Karman (considerado 0,4);

$d_0[n]$: Altura de deslocamento em relação ao plano zero;

$z_0[n]$: Altura de rugosidade.

$F_w[n]$ é definido por LOUIS (1979) através das Equações (65) e (66):

$$F_w[n] = 1 - \frac{9,4 Ri_B[n]}{1 + c |Ri_B[n]|^{0.5}}, Ri_B[n] < 0 \quad (65)$$

$$F_w[n] = \frac{1}{(1 + 4.7 Ri_B[n])^2}, 0 \leq Ri_B[n] \leq 0.2, \quad (66)$$

onde:

$Ri_B[n]$: Número de Richardson;

c : coeficiente;

O coeficiente c é calculado através da Equação (67):

$$c = 49,82 a^2[n] \left(\frac{z_2[n] - d_0[n]}{z_0[n]} \right)^{0.5} \quad (67)$$

A transpiração ($E_t[n]$) é baseada na formulação de BLODIN (1991) e DUCOUNDRE *et al.*, (1993) e encontra-se apresentada na Equação (68):

$$E_t[n] = \left[1 - \left(\frac{W_i[n]}{W_{im}[n]} \right)^{2/3} \right] E_p[n] \frac{r_w[n]}{r_w[n] + r_0[n] + r_c[n]} \quad (68)$$

onde:

$r_c[n]$: Resistência do dossel.

A resistência do dossel ($r_c[n]$) é calculada através da Equação (69):

$$r_c[n] = \frac{r_{0c}[n] g_{sm}[n]}{LAI[n, m]} \quad (69)$$

onde:

$r_{oc}[n]$: Mínima resistência do dossel;

$g_{sm}[n]$: Fator de tensão de umidade do solo.

O fator de tensão de umidade do solo ($g_{sm}[n]$) depende da disponibilidade de água na zona da raiz para enésima classe da cobertura da superfície (Equações (70), (71) e (72)).

$$g_{sm}^{-1}[n] = 1, \quad W_j[n] \geq W_j^{cr} \quad (70)$$

$$g_{sm}^{-1}[n] = \frac{W_j[n] - W_j^w}{W_j^{cr} - W_j^w}, \quad \begin{aligned} W_j^w &\leq W_j[n] \\ &< W_j^{cr} \end{aligned} \quad (71)$$

$$g_{sm}^{-1}[n] = 0 \quad W_j[n] < W_j^w \quad (72)$$

onde:

$W_j[n]$: Umidade contida na camada de solo j , $j=1, 2$.

W_j^{cr} : Umidade crítica (quando a transpiração não é afetada pela tensão gerada da umidade no solo).

W_j^w : Quantidade de umidade do solo no ponto de murchamento permanente.

A água pode ser extraída da camada 1 e/ou da camada 2, dependendo da fração da raiz $f_1[n]$ e $f_2[n]$ em cada camada.

Não há tensão devido à umidade no solo, $g_{sm}[n] = 1$ na Equação (69), se:

- a) $W_2[n]$ for maior ou igual a W_2^{cr} e $f_2[n] \geq 0.5$
- b) $W_1[n]$ for maior ou igual W_1^{cr} , e $f_1[n] \geq 0.5$.

No caso "a", a transpiração ocorre pela camada 2 sem tensão no solo $E_t[n] = E_2^t[n]$ (independe da disponibilidade de água na camada 1). Já no caso "b", a transpiração ocorre através da água da camada 1, $E_t[n] = E_1^t[n]$ sem tensão no solo. Caso contrário a transpiração é calculada pela Equação (73) a seguir:

$$E_t[n] = f_1[n]E_1^t[n] + f_2[n]E_2^t[n] \quad (73)$$

onde:

$E_1^t[n]$ - Transpiração na camada 1

$E_2^t[n]$ - Transpiração na camada 2

Caso a raiz esteja apenas presente na camada 1 $f_2[n] = 0$ e a transpiração é calculada através da Equação (74):

$$E_t[n] = E_1^t[n] \quad (74)$$

Para o caso de uma chuva contínua com uma taxa menor que a evaporação na camada dossel, é importante considerar a evaporação da vegetação quando não existe água interceptada suficiente para suprir as demandas atmosféricas para um dado tempo. Neste caso a evaporação da camada do dossel ($E_c[n]$) é calculada através da Equação (75):

$$E_c[n] = f[n]E_c^*[n] \quad (75)$$

onde:

$f[n]$ - Fração do tempo do passo necessária para evaporação na camada do dossel esgotar a água armazenada na camada do dossel.

A fração do tempo do passo necessária para evaporação na camada do dossel esgotar a água armazenada na interceptação na camada do dossel ($f[n]$) é calculada através da Equação (76).

$$f[n] = \min\left(1, \frac{W_i[n] + P \Delta t}{E_c^*[n] \Delta t}\right) \quad (76)$$

onde:

P - Taxa de precipitação;

Δt - Tempo do passo.

A transpiração durante o tempo de completar um passo (Δt) é calculado através da Equação (77) a seguir:

$$E_t[n] = (1 - f[n])E_p[n] \frac{r_w[n]}{r_w[n] + r_0[n] + r_c[n]} + f[n] \left[1 - \left(\frac{W_i[n]}{W_{im}[n]} \right)^{2/3} \right] E_p[n] \frac{r_w[n]}{r_w[n] + r_0[n] + r_c[n]} \quad (77)$$

Na Equação (77) o primeiro termo do lado direito representa a fração do passo de tempo no qual nenhuma evaporação e transpiração ocorra através da água armazenada da camada do dossel. Já o segundo termo do lado direito representa a fração do passo de tempo que a evaporação e a transpiração ocorra na camada do dossel.

Evaporação do solo exposto ocorre apenas na camada 1, portanto assume-se que seja zero a evaporação para solo exposto na camada 2. Quando a camada 1 do solo está saturada, ela evapora à taxa de evaporação potencial ($E_p[N + 1]$) e é calculada através da Equação (78):

$$E_1 = E_p[N + 1] \quad (78)$$

Para a condição de não saturação da camada 1, a evaporação ocorre a uma taxa E_1 a qual varia de acordo com a área de solo exposto devido à falta de homogeneidade nas características topográficas, infiltração, e do solo. A taxa de evaporação E_1 é calculada usando a fórmula de evaporação de FRANCINI e PACCIANI (1991). Esta formulação usa a estrutura do modelo de Xinanjiang (ZHAO *et al.*, 1980) e assume que a capacidade de infiltração varia de acordo com a área e pode ser expressa conforme a Equação (79):

$$i = i_m [1 - (1 - A)^{1/b_i}] \quad (79)$$

onde:

i - Capacidade de infiltração;

i_m - Capacidade de infiltração máxima;

A - Fração da área relativa cuja capacidade de infiltração é menor que i ;

b_i - Parâmetro de forma da infiltração.

Considerando A_s como a fração de solo exposto que se encontra saturado, i_0 a capacidade de infiltração, e baseado na Figura E_1 pode ser expresso pela Equação (80):

$$E_1 = E_p[N + 1] \left\{ \int_0^{A_s} dA + \int_{A_s}^1 \frac{i_0}{i_m [1 - (1 - A)^{1/b_i}]} dA \right\} \quad (80)$$

Na Equação (80) o primeiro termo da integral representa a contribuição da evaporação da área saturada que evapora à taxa de evaporação potencial, já a segunda integral não possui solução analítica e é resolvida através de uma expansão por séries de potência conforme apresentado na Equação (81):

$$E_1 = E_p[N + 1] \left\{ A_s + \frac{i_0}{i_m} (1 - A_s) \left[1 + \frac{b_i}{1 + b_i} (1 - A_s)^{1/b_i} + \frac{b_i}{2 + b_i} (1 - A_s)^{2/b_i} + \frac{b_i}{3 + b_i} (1 - A_s)^{3/b_i} + \dots \right] \right\} \quad (81)$$

Esta aproximação é para a fração de solo exposto o qual possui variabilidade na umidade.




Figura 1 - REPRESENTAÇÃO ESQUEMÁTICA DA COMPUTAÇÃO DA EVAPORAÇÃO DE SOLO EXPOSTO

Fonte: Adaptado de LIANG e LETTERMAIN (1994)

BALANÇO HÍDRICO NA CAMADA DOSSEL

O balanço hídrico na camada dossel (interceptação) pode ser descrito pela Equação (82).

$$\frac{dW_{i[n]}}{dt} = P - E_c[n] - P_t[n], \quad 0 \leq W_i[n] \leq W_{im}[n] \quad (82)$$

onde:

$P_t[n]$ - Precipitação interceptada;

A precipitação interceptada ($P_t[n]$) ocorre quando a quantidade máxima de água interceptada na camada dossel ($W_{im}[n]$) é excedida na enésima classe de superfície.

ESCOAMENTO SUPERFICIAL DA CAMADA DE SOLO EXPOSTO

Escoamento superficial na camada de solo exposto é calculado utilizando a formulação de infiltração (Equação (79)). A Equação de Xinanjiang, a qual é descrita em maiores detalhes por WOOD *et al.* (1992) é considerada apenas para camada de solo superior. A máxima umidade contida no solo na camada 1 (W_1^c) está relacionada com a capacidade máxima infiltração (i_m) e com o parâmetro de forma da infiltração (b_i) conforme a Equação (83):

$$W_1^c = \frac{i_m}{1 + b_i} \quad (83)$$

O modelo de Xinanjiang assume que o escoamento superficial é gerado por aquelas áreas onde a precipitação, quando adicionado o armazenamento de umidade do solo no final do passo de tempo anterior, exceder a capacidade de armazenamento do solo. O escoamento superficial direto gerado por estas áreas é $Q_d[n + 1]$, onde N+1 indica a classe de solo exposto (Equações (84) e (85)).

$$Q_d[N + 1]\Delta t = P\Delta t - W_1^c + W_1^-[N + 1], \quad (84)$$

$$i_0 + P\Delta t \geq i_m$$

$$Q_d[N + 1]\Delta t = P\Delta t - W_1^c + W_1^-[N + 1] + W_1^c \left[1 - \frac{i_0 + P\Delta t}{i_m} \right]^{1+b_i}, \quad (85)$$

$$i_0 + P\Delta t \leq i_m$$

onde:

$W_1^-[N + 1]$ - Umidade contida na camada de solo 1 no início de cada passo.

Para solos expostos não há armazenamento na camada dossel e conseqüentemente a água interceptada é igual à precipitação (P). Para o solo exposto o balanço hídrico pode ser calculado através da Equação (86).

$$W_1^+[N + 1] = W_1^-[N + 1] + (P - Q_d[N + 1] - Q_{12}[N + 1] - E_1)\Delta t \quad (86)$$

onde:

$W_1^+[N + 1]$ - Umidade contida na camada de solo 1 no fim de cada passo.

$Q_{12}[N + 1]$ - Água drenada da camada 1 para 2.

Assumindo que a passagem de água da camada 1 para a camada 2 ocorre através do efeito da gravidade, utiliza-se a relação de BROOKS e COREY (1964) para estimar a condutividade hidráulica e desta maneira pode-se expressar a passagem de água da camada 1 para a camada 2 ($Q_{12}[N + 1]$) através da Equação (87).

$$Q_{12}[N + 1] = K_s \left(\frac{W_1[N + 1] - \theta_r}{W_1^c - \theta_r} \right)^{\frac{2}{B_p} + 3} \quad (87)$$

onde:

K_s - Condutividade hidráulica saturada.

θ_r - Teor de umidade residual.

B_p - Índice de distribuição do tamanho dos poros.

ESCOAMENTO SUBSUPERFICIAL DA CAMADA DE SOLO EXPOSTO

A formulação para o escoamento subsuperficial segue o modelo conceitual de Arno (FRANCINI e PACCIANI, 1991), o qual é aplicado somente para a camada de solo 2 do Modelo VIC (a água que passa da camada de solo 1 para a 2 não contribui para o escoamento superficial). O escoamento subsuperficial é dado pelas Equações (88) e (89):

$$Q_b[N + 1] = \frac{D_s D_m}{W_s W_2^c} W_2^- [N + 1], \quad (88)$$

$$0 \leq W_2^- [N + 1] \leq W_s W_2^c$$

$$Q_b[N + 1] = \frac{D_s D_m}{W_s W_2^c} W_2^- [N + 1] + \left(D_m - \frac{D_s D_m}{W_s} \right) \left(\frac{W_2^- [N + 1] - W_s W_2^c}{W_2^c - W_s W_2^c} \right)^2, \quad (89)$$

$$W_2^- [N + 1] \geq W_s W_2^c$$

onde:

$Q_d[N + 1]$ - Escoamento subsuperficial;

D_m - Vazão subsuperficial máxima;

D_s - Fração de D_m ;

W_2^c - umidade máxima na camada de solo 2;

W_s - Fração de W_2^c com $D_s \leq W_s$;

$W_2^- [N + 1]$ - Umidade contida na camada de solo 2 no início do passo.

As Equações (88) e (89) descrevem um comportamento que é linear abaixo de um limiar (Equação (88)) e não-linear para valores mais elevados de umidade do solo (Equação (89)) como mostrado na Figura abaixo. O comportamento não linear da passagem da água da camada 1 para a camada 2 é utilizado para representar situações o qual ocorre um considerável escoamento subsuperficial advindo de uma tempestade. As Equações (88) e (89) apresentam a primeira derivada contínua da transição linear para transição não linear da infiltração da camada 1 para camada 2 como mostrado na Figura




Figura 2- REPRESENTAÇÃO ESQUEMÁTICA DO FLUXO DE BASE NÃO LINEAR DE ARNO.

Fonte: Adaptado de LIANG e LETTERMAIN. (1994)

Através das Equações (88) e (89) se obtém o balanço de água para a camada 2 (Equação (90)):

$$W_2^+[N + 1] = W_2^-[N + 1] + (Q_{12}[N + 1] - Q_b[N + 1] - E_2)\Delta t \quad (90)$$

onde:

$W_2^+[N + 1]$ - Quantidade de umidade presente na camada de solo 2 no final do passo.

Caso $W_2^-[N + 1] + (Q_{12}[N + 1] - Q_b[N + 1] - E_2)\Delta t < W_2^c$, então $Q_b[N + 1]$ é calculado através das Equações (88) e (89). No caso em que $W_2^-[N + 1] + (Q_{12}[N + 1] - Q'_b[N + 1] - E_2)\Delta t > W_2^c$ (onde $Q'_b[N + 1]$ é calculado através das Equações (88) e (89)) consideram-se as seguintes relações (Equações (91) e (92))

$$W_2^+[N + 1] = W_2^c \quad (91)$$

$$Q_b''[N + 1] = W_2^-[N + 1] + (Q_{12}[N + 1] - Q'_b[N + 1] - E_2)\Delta t - W_2^c \quad (92)$$

Quando a Equação (91) é utilizada, a vazão subsuperficial total na camada 2 ($Q_b[N + 1]$) é dada pela Equação (93):

$$Q_b[N + 1] = Q'_b[N + 1] + Q_b''[N + 1] \quad (93)$$

ESCOAMENTO SUPERFICIAL E SUBSUPERFICIAL PARA SOLO COM COBERTURA VEGETAL

As equações para escoamento superficial e subsuperficial e o balanço de água em cada camada são as mesmas que as utilizadas para solos expostos, as únicas exceções são as equações para a definição da taxa de precipitação (P) e a taxa de evaporação nas camadas 1 e 2 (E_1 e E_2).

A evaporação total (E) e a vazão total (Q) são expressas pelas Equações (94) e (95) respectivamente.

$$E = \sum_{n=1}^N C_v[n](E_c[n] + E_t[n]) + C_v[N + 1]E_1 \quad (94)$$

$$Q = \sum_{n=1}^{N+1} C_v[n](Q_d[n] + Q_b[n]) \quad (95)$$

onde:

$C_v[n]$ – Fração da cobertura da enésima vegetação ($n=1, \dots, N$);

$C_v[N + 1]$ – Fração da área do solo exposto.

O somatório de todas as frações de área totaliza 1, ou seja, 100% da área analisada (Equação (96)):

$$\sum_{n=1}^{N+1} C_v[n] = 1 \quad (96)$$

REPRESENTAÇÃO DO FLUXO AERODINÂMICO

O modelo hidrológico de duas camadas descrito nas seções anteriores é utilizado em conjunto com o balanço de energia para a superfície da terra e as propriedades térmicas dos solos para calcular a temperatura da superfície e, simultaneamente, o fluxo de calor sensível e o calor do solo que depende da temperatura da superfície. A Equação do balanço de energia para uma superfície ideal de enésima classe de cobertura de solo pode ser expressa através da Equação (97):

$$R_n[n] = H[n] + \rho_w L_e E[n] + G[n] \quad (97)$$

com,

$$E[n] = E_c[n] + E_t[n], \quad n = 1, 2, \dots, N \quad (98)$$

$$E[N + 1] = E_1 \quad (99)$$

onde:

$R_n[n]$ - Radiação líquida;
 $H[n]$ - Fluxo de calor sensível;
 ρ_w - Densidade da água;
 L_e - Calor latente de vaporização;
 $G[n]$ - Fluxo de calor do solo.

Para superfícies que podem ser representadas aproximadamente como planas e homogêneas a equação do balanço de energia para uma coluna de ar delimitada pela superfície do solo na parte inferior e uma superfície de altura dada na atmosfera na parte superior, pode ser expresso através da Equação (100):

$$R_n[n] = H[n] + \rho_w L_e E[n] + G[n] + \Delta H_s[n] \quad (100)$$

onde:

$\Delta H_s[n]$ - Variação no armazenamento de energia na camada por unidade de área por unidade de tempo.

O calor sensível e os fluxos do calor latente, assim como a radiação líquida, estão associados com o topo da superfície da camada de ar e o fluxo de calor no solo. A taxa de armazenamento de energia térmica na camada é dada pela Equação (101):

$$\Delta H_s[n] = \frac{\rho_a c_p (T_s^+[n] - T_s^-[n]) z_a[n]}{2\Delta t} \quad (101)$$

onde:

ρ_a - Densidade do ar;
 c_p - Calor específico do ar;
 $T_s^+[n]$ - Temperatura no solo ao final do passo;
 $T_s^-[n]$ - Temperatura no solo no início do passo;
 $z_a[n]$ - Altura da superfície superior da camada.

A radiação líquida é dada pela Equação (102):

$$R_n[n] = (1 - \alpha[n])R_s + \epsilon[n](R_L - \sigma T_s^4[n]) \quad (102)$$

onde:

$\alpha[n]$ - Albedo para enésima classe de cobertura do solo;

R_s - Radiações de ondas curtas que atingem o solo;

$\epsilon[n]$ - Emissividade para enésima classe de cobertura do solo;

σ - Constante de Stefan-Boltzmann.

O fluxo do calor latente, o qual é o *link* entre a água e o balanço de energia, é obtido pela Equação (98) ou (99). O fluxo do calor sensível é dado pela Equação (103):

$$H[n] = \frac{\rho_a c_p}{r_h[n]} (T_s[n] - T_a[n]) \quad (103)$$

onde:

$T_s[n]$ - Temperatura na superfície;

$T_a[n]$ - Temperatura do ar;

$r_h[n]$ - Resistência aerodinâmica do fluxo do calor;

Considera-se que $r_h[n]$ seja calculado da mesma maneira que $r_w[n]$ (Equação (62)). O fluxo de calor do solo $G[n]$ é estimado usando duas camadas térmicas de solo. Para a primeira camada de solo, com profundidade D_1 tem-se (Equação (104)):

$$G[n] = \frac{k[n]}{D_1} (T_s[n] - T_1[n]) \quad (104)$$

onde:

$k[n]$ - Condutividade térmica do solo;

D_1 - Profundidade da primeira camada do solo;

$T_1[n]$ - Temperatura do solo para a profundidade D_1 .

Para a segunda camada de solo com profundidade D_2 , cuja condição de contorno inferior é a temperatura do solo constante, a lei de conservação de energia, assumindo que o armazenamento de calor na camada térmica 1 seja desprezível, fornece (Equação (105)):

$$\frac{C_s[n](T_1^+[n] - T_1^-[n])}{2\Delta t} = \frac{G[n]}{D_2} - \frac{k[n](T_1[n] - T_2)}{D_2^2} \quad (105)$$

onde:

$C_s[n]$ - Capacidade de calor do solo;

$T_1^+[n]$ - Temperatura do solo para a profundidade D_1 no fim do passo;

$T_1^-[n]$ - Temperatura do solo para a profundidade D_1 no início do passo;

T_2 - Temperatura constante para a profundidade D_2 .

Das Equações (104) e (105) pode-se definir o fluxo de calor do solo ($G[n]$) como (Equação (106)):

$$G[n] = \frac{\frac{k[n]}{D_2}(T_s[n] - T_2) + \frac{C_s[n]D_2}{2\Delta t}(T_s[n] - T_1^-[n])}{1 + \frac{D_1}{D_2} + \frac{C_s[n]D_1D_2}{2\Delta t k[n]}} \quad (106)$$

Para o caso que a variação do armazenamento de energia ($\Delta H_s[n]$) pode ser desprezado, o balanço de energia para uma superfície ideal Equação (97) pode ser usado ao invés da Equação (100). Através das Equações (98), (99), (102), (103) e (106) o calor sensível, o fluxo de calor do chão e a temperatura da superfície para enésima classe de cobertura pode ser obtido. Para o caso onde $\Delta H_s[n]$ pode ser desprezado, a temperatura na superfície $T_s[n]$ é resolvida de forma iterativa através da Equação (107):

$$\begin{aligned}
& \epsilon[n]\sigma T_s^4[n] + \left(\frac{\rho_a c_p}{r_h[n]} + \frac{\frac{k[n]}{D_2} + \frac{C_s[n]D_2}{2\Delta t}}{1 + \frac{D_1}{D_2} + \frac{C_s[n]D_1D_2}{2\Delta t k[n]}} \right) T_s[n] \\
& = (1 - \alpha[n])R_s + \epsilon[n]R_L + \frac{\rho_a c_p}{r_h[n]} T_a[n] - \rho_w L_e E[n] \quad (107) \\
& + \frac{\frac{k[n]T_2}{D_2} + \frac{C_s[n]D_2 T_1^- [n]}{2\Delta t}}{1 + \frac{D_1}{D_2} + \frac{C_s[n]D_1D_2}{2\Delta t k[n]}}
\end{aligned}$$

Quando $\Delta H_s[n]$ não pode ser desprezado então as Equações (100), (101), (102), (103) e (106) podem ser combinadas na Equação (108):

$$\begin{aligned}
& \epsilon[n]\sigma(T_s^+[n])^4 + \left(\frac{\rho_a c_p}{r_h[n]} + \frac{\rho_a c_p z_a[n]}{2\Delta t} + \frac{\frac{k[n]}{D_2} + \frac{C_s[n]D_2}{2\Delta t}}{1 + \frac{D_1}{D_2} + \frac{C_s[n]D_1D_2}{2\Delta t k[n]}} \right) T_s^+[n] \\
& = (1 - \alpha[n])R_s + \epsilon[n]R_L + \frac{\rho_a c_p}{r_h[n]} T_a[n] - \rho_w L_e E[n] \quad (108) \\
& + \frac{\rho_a c_p z_a[n] T_s^- [n]}{2\Delta t} + \frac{\frac{k[n]T_2}{D_2} + \frac{C_s[n]D_2 T_1^- [n]}{2\Delta t}}{1 + \frac{D_1}{D_2} + \frac{C_s[n]D_1D_2}{2\Delta t k[n]}}
\end{aligned}$$

$T_s[n]$ é determinado da mesma maneira como na Equação (107). A temperatura efetiva na superfície $T_s[n]$, fluxo de calor sensível H e o fluxo de calor do solo G podem ser obtidos através das Equações (109), (110) e (111) respectivamente:

$$T_s = \sum_{n=1}^{N+1} C_v[n] T_s[n] \quad (109)$$

$$H = \sum_{n=1}^{N+1} C_v[n] H[n] \quad (110)$$

$$G = \sum_{n=1}^{N+1} C_v[n] G[n] \quad (111)$$