

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE RECURSOS HÍDRICOS E
SANEAMENTO AMBIENTAL

**PREVISÃO CONTÍNUA DE NÍVEIS FLUVIAIS
COM REDES NEURAIS UTILIZANDO
PREVISÃO DE PRECIPITAÇÃO**

Investigação Metodológica da Técnica

Dissertação de Mestrado

Fernando Dornelles

Porto Alegre, novembro de 2007.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

INSTITUTO DE PESQUISAS HIDRÁULICAS

**PREVISÃO CONTÍNUA DE NÍVEIS FLUVIAIS COM REDES NEURAIIS
UTILIZANDO PREVISÃO DE PRECIPITAÇÃO
Investigação Metodológica da Técnica**

Fernando Dornelles

Orientador: Olavo Correa Pedrollo

Co-orientador: Joel Avruch Goldenfum

Banca Examinadora:

Prof. Dr. André Luiz Lopes da Silveira	IPH/UFRGS
Prof. Ph.D. Carlos André Bulhões Mendes	IPH/UFRGS
Profª Ph.D. Cíntia Bertacchi Uvo	Lund University/Suécia

Dissertação submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para a obtenção do título de Mestre em Engenharia.

Novembro de 2007

I. Apresentação

Este trabalho foi desenvolvido no Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul, sob a orientação do Professor Olavo Correa Pedrollo da Universidade Federal do Rio Grande do Sul e co-orientado pelo Professor Joel Avruch Goldenfum da Universidade Federal do Rio Grande do Sul.

Agradeço ao CNPQ (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo fornecimento da bolsa de estudo que possibilitou minha conclusão de mais esta etapa da minha formação acadêmica.

Igualmente, agradeço aos professores do IPH que me transmitiram ensinamentos valiosos durante meu mestrado na instituição, em especial aos meus orientadores que sempre estiveram presentes e acessíveis, Olavo Correa Pedrollo e Joel Avruch Goldenfum.

Reconheço a disponibilização de dados de previsão meteorológica, níveis e demais auxílios prestados pelo CPTEC (Centro de Previsão de Tempo e Estudos Climáticos) e pelo DNH (Dirección Nacional de Hidrologia / Uruguay).

Aos meus colegas de convivência no IPH, exalto as boas e frutíferas conversas que colaboraram para a elaboração deste trabalho.

Previsão

(Adair de Freitas)

O tempo se armou de fato
Lá pra o lado do Uruguai
Vai chover barbaridade
E sem poncho ninguém sai
É por isso que o campeiro se agasalha
Porque sabe que não falha a previsão de vaqueano
Mesmo aragano sabe que é dura a peleia
Quando o tempito se enfeia pro lado dos castelhanos
Isso é costume da gente lá da fronteira
Gente boa sem fronteira que observa a natureza
É sutileza do peão e está provado
Se armando pra aquele lado chove chuva com certeza
A vida é um tempo temporal vento maleva
E a vida que a gente leva, leva o tempo pela mão
Meu bom patrão que alegria se eu previsse
Que a chuva do amor caísse nos ranchos do meu rincão

Adair de Freitas: cantor e compositor, natural de São Gabriel/RS.

II. Resumo

Os sistemas de alerta de cheias exigem dos modelos de previsão de níveis, precisão e antecipação adequadas. Especialmente em bacias pequenas com resposta rápida, estas necessidades são atendidas com modelos de previsão contínua, e que utilizam a previsão hidrometeorológica como dado de entrada.

Nesta pesquisa, é proposta uma exploração de recursos matemáticos na modelagem empírica de redes neurais progressivas de múltiplas camadas, abordando-se as dificuldades corriqueiras desta técnica, tais como problemas de convergência, eleição da arquitetura ótima, particionamento da amostra e índices de avaliação da qualidade do modelo. Estas dificuldades são pouco discutidas, ou até mesmo totalmente ignoradas, em grande parte dos trabalhos.

A aplicação da metodologia utilizou dados da bacia do rio Quaraí, onde as cidades fronteiriças de Quaraí (Br) e Artigas (Uy) sofrem com inundações ribeirinhas. A área da bacia de contribuição é de 4.500 km², salientando-se que a bacia apresenta uma rápida resposta aos eventos de precipitação, decorrente de uma baixa capacidade de armazenamento e infiltração.

O modelo proposto de previsão de níveis por redes neurais tem como entradas, níveis observados nos 2 dias anteriores e previsão numérica de precipitação (ETA-CPTEC) para até 5 dias à frente.

O provável ganho em qualidade ao utilizar-se previsão de precipitação no modelo de previsão de nível foi analisado, comparando-se os resultados do modelo completo de redes neurais com os obtidos, também por um modelo de redes neurais, porém, sem o emprego de previsão de precipitação, pois assim, a avaliação deste ganho não tem a influência das características do modelo utilizado. Foi verificado um pequeno ganho ao utilizar-se a previsão de precipitação, mesmo com a baixa capacidade em acertar a magnitude da precipitação.

Para efeitos de experimentação da técnica de aglutinação dos índices de qualidade dos resultados da modelagem, foram obtidas e comparadas as previsões de níveis de um modelo de regressão com as de um modelo por redes neurais. Foi analisado o comportamento do índice de erro associado à frequência de ocorrência, que indica a magnitude do erro de modo absoluto, o qual, devido a seu significado intuitivo, dispensa a comparação com modelos alternativos. A técnica de aglutinação foi importante para a comparação dos resultados das modelagens, tendo indicado a vantagem das redes neurais sobre a regressão.

Os recursos desenvolvidos nesta pesquisa, para contornar as dificuldades expostas, podem contribuir para a correta utilização de redes neurais progressivas de múltiplas camadas, em especial na área de recursos hídricos. Observa-se, ainda, que a delimitação dos limites de abrangência da amostra de dados tem uma importante influência na escolha do correto modelo a ser utilizado.

III. Abstract

Flood alert systems require appropriate anticipation and accuracy from level forecasting models. Particularly for small basins with quick response these requirements are fulfilled by continuous forecasting models that use rain forecasting data as input.

The purpose of this research is an analysis of mathematical resources in the multi-layer feedforward neural networks empirical modelling. Usual limitations to adapt these techniques, such as convergence problems, optimum architecture selection, sample partitions and indexes for the models quality evaluation are presented and analyzed. These difficulties are rarely discussed and often disregarded by networks literature.

The data employed for the methodology application refers to the Quaraí River basin where the neighboring cities of Quaraí (Brazil) and Artigas (Uruguay) are subjected to river floods. The contribution basin area is 4,500km² and the basin responds quickly to precipitation events since it has low infiltration and storage capacity.

The adopted level forecasting model using neural network techniques was applied to two previous observed levels and the rainfall forecasting data (ETA-CPTEC) up to five days ahead as input.

The potential gain on quality by using rainfall forecasting on the level forecasting model was analyzed by comparing results from the neural network model using precipitation forecasting with results from the neural network model that did not use it. On this approach the gain valuation isn't influenced by the models characteristics. A small improvement was obtained by using the rainfall forecasting, even considering the low performance to estimate rainfall values.

Level forecasting data generated by a regression model was compared with the level forecasting obtained from the neural network model in order to test the gathering techniques of the models results quality indexes,. The behavior of the error index associated with the frequency index, which indicates the error magnitude in the absolute mode and do not need any further comparisons because of its intuitive meaning, was analysed. The use of gathering techniques was important to compare the model results, indicating an advantage of the neural networks techniques when compared to the regression model.

The resources developed to solve the difficulties found in this research can give indication for the correct use of multi-layer feedforward neural networks, specially when applied to hydraulic resources. It was also observed that the determination of the sample's valid range can present important role in the choice of the adequate model for use in each case.

Índice:

Apresentação	III
Resumo	V
Abstract	VI
Índice	VII
Lista de Figuras	X
Lista de Tabelas	XIV
Lista de Símbolos	XVII
Lista de Siglas	XIX
1. Introdução	1
1.1 Motivação	1
1.2 Objetivos	4
1.3 Estudo de caso	4
2. Revisão Bibliográfica	6
2.1 Alerta de Cheias	6
2.1.1 Sistemas de Alerta	6
2.1.2 Modelos de Previsão de Nível	7
2.2 Previsão Meteorológica	9
2.2.1 Conceitos Básicos	9
2.2.2 O Modelo de Previsão Meteorológica ETA	10
2.3 Redes Neurais Artificiais	11
2.3.1 Introdução	11
2.3.2 Rede Neural Booleana de McCulloch e Pitts	12
2.3.3 Métodos de Aprendizagem das Redes Neurais	13
2.3.4 Regra Delta	15
2.3.5 Convergência, Passo Variável de Aprendizado e o Termo <i>momentum</i>	15
2.3.6 Escalonamento dos Dados de Entrada	17
2.3.7 Método da Retropropagação do Erro	18
2.3.8 Arquitetura das Redes Neurais Artificiais	19
2.3.9 Validação Cruzada	20
2.3.10 Mínimos Locais	21
2.3.11 Aplicações Usando Redes Neurais em Recursos Hídricos	21
2.4 Regressão Linear Multivariada	23
3. Área de Estudo e Dados Disponíveis	25

3.1	Área de Estudo	25
3.1.1	Bacia do Rio Quaraí	25
3.1.2	A Bacia a Montante das Cidades de Quaraí e Artigas	26
3.1.3	Inundações no trecho próximo às cidades de Artigas e Quaraí	27
3.2	Dados Disponíveis	28
3.2.1	Dados Hidrológicos Observados	28
3.2.2	Dados de Previsão Meteorológica	29
4.	Metodologia	31
4.1	Análise da Qualidade da Previsão Hidrometeorológica do modelo ETA.....	31
4.1.1	Sincronização dos Dados.....	31
4.1.2	Índices para Análise da Qualidade da Previsão Hidrometeorológica	33
4.1.3	Resíduos da Previsão Hidrometeorológica.....	34
4.2	Modelo de Redes Neurais com uso de Previsão de Precipitação	35
4.2.1	Amostras de Dados para a Rede Neural.....	35
4.2.2	Índices para Análise da Qualidade do Modelo de Previsão de Nível	37
4.2.3	Recursos Utilizados.....	38
4.2.4	Definição do número mínimo de treinamentos	41
4.2.5	Aglutinação dos índices de avaliação do modelo	42
4.2.6	Eleição da arquitetura ótima do modelo de rede neural	42
4.3	Modelo de Redes Neurais sem uso de Previsões de Precipitação	44
4.4	Modelagem por Regressão Linear Multivariada	44
4.4.1	Amostras de Dados para o Modelo de Regressão Multivariada.....	45
4.4.2	Eleição do modelo de regressão.....	45
5.	Resultados e Análises	47
5.1	Qualidade da Previsão Hidrometeorológica.....	47
5.1.1	“Alerta Falso” e “Incapacidade de Previsão”	47
5.1.2	Previsões e Observações Não Nulas	50
5.2	Análise dos Resultados do Modelo de Redes Neurais com uso de Previsão de Precipitação	53
5.2.1	Resultados da definição do número mínimo de treinamentos das redes neurais..	53
5.2.2	Resultados da eleição da arquitetura da rede neural COM uso de previsão de precipitação	54
5.2.3	Resultados do modelo de previsão de nível COM previsão e chuva para as arquiteturas ótimas	57

5.3	Análise da Influência do Uso de Previsão de Precipitação no Modelo de Redes Neurais	66
5.3.1	Resultados da eleição da arquitetura da rede neural SEM uso de previsão de chuva	66
5.3.2	Resultados do modelo de previsão de nível SEM previsão de chuva para as arquiteturas ótimas	69
5.4	Análise Comparativa dos Resultados do Modelo de Regressão Multivariada com o de Redes Neurais.....	75
5.4.1	Resultados da eleição da configuração ótima do modelo de regressão	75
5.4.2	Resultados do modelo de regressão	76
5.5	Análise da aplicabilidade do Modelo Proposto de Previsão de Níveis Fluviais	83
6.	Conclusões	85
7.	Recomendações.....	89
8.	Referências Bibliográficas.....	90
	ANEXO 1 – Superfícies de Resultado das Redes Neurais COM o uso de Previsão de Precipitação	93
	ANEXO 2 – Superfícies de Resultado das Redes Neurais SEM o uso de Previsão de Precipitação	97

Lista de Figuras:

Figura 2.1 – Neurônio Biológico.	12
Figura 2.2 - Processamento Explícito e Implícito.....	13
Figura 2.3 - Superfície da Função de Erro	16
Figura 2.4 - Função Tamanho do Passo x N° Iterações.....	16
Figura 2.5 - Função Erro Quadrático x N° Iterações.....	16
Figura 2.6 - Funções Sigmóides, Bi-polar e Unipolar.....	17
Figura 2.7 - Escalonamento dos dados.....	18
Figura 2.8 - Esquema do treinamento por retropropagação do erro.	19
Figura 2.9 - Estrutura de uma Rede Neural Genérica.	19
Figura 2.10 - Resultados de ajustamentos.	20
Figura 2.11 - Função do Erro Quadrático da amostra de Treinamento e de Validação.....	20
Figura 3.1 – Vista aérea do rio Quaraí e as cidades de Quaraí e Artigas.	25
Figura 3.2 - Localização da Bacia do Rio Quaraí e a sub-bacia em estudo.	26
Figura 3.3 - Seção do Rio Quaraí e as cotas para extravasar a calha principal e para atingir a população	28
Figura 3.4 - Postos da rede telemétrica do DNH (Uruguai).	29
Figura 3.5 - Polígonos de Thiesen para os pontos de previsão hidrometeorológica na bacia do Quaraí.	30
Figura 4.1 – Fluxograma de etapas	32
Figura 4.2 – Fluxograma de possibilidades de erros na previsão hidrometeorológica.....	34
Figura 4.3 – Particionamento seqüencial das amostras.....	36
Figura 4.4 – Função de ativação Sigmóide TANSIG.	38
Figura 4.5 – Função de ativação Linear SATLINS.	39
Figura 4.6 – Função de ativação Linear POSLIN.....	39
Figura 4.7 – Comportamento do índice em função do número de treinamentos.....	41
Figura 4.8 – Redes Neurais para verificar o ganho usando previsão hidrometeorológica.....	44
Figura 5.1 – Acerto de previsão de chuva nula e as falhas de “Incapacidade de Previsão” e “Alerta Falso”	48
Figura 5.2 – Curvas de permanência do resíduo do “Alerta Falso”	48
Figura 5.3 – Curvas de permanência do resíduo da “Incapacidade de Previsão”	49
Figura 5.4 – Curva de permanência dos resíduos de previsão e observação não nulas.	51
Figura 5.5 – Previsões e observações para horizonte de 1 dia.....	51
Figura 5.6 – Previsões e observações para horizonte de 2 dias.	51
Figura 5.7 – Previsões e observações para horizonte de 3 dias.	52

Figura 5.8– Previsões e observações para horizonte de 4 dias.....	52
Figura 5.9– Previsões e observações para horizonte de 5 dias.....	52
Figura 5.10 – Previsões e observações para horiz. de 1 dia – ordem original – COM previsão de chuva.....	58
Figura 5.11 – Previsões e observações para horiz. de 2 dias – ordem original – COM previsão de chuva.....	59
Figura 5.12 – Previsões e observações para horiz. de 3 dias – ordem original – COM previsão de chuva.....	59
Figura 5.13 – Previsões e observações para horiz. de 4 dias – ordem original – COM previsão de chuva.....	59
Figura 5.14 – Previsões e observações para horiz. de 5 dias – ordem original – COM previsão de chuva.....	60
Figura 5.15 – Previsões e observações para horiz. de 1 dia – ordem crescente – COM previsão de chuva.....	60
Figura 5.16 – Previsões e observações para horiz. de 2 dias – ordem crescente – COM previsão de chuva.....	61
Figura 5.17 – Previsões e observações para horiz. de 3 dias – ordem crescente – COM previsão de chuva.....	61
Figura 5.18 – Previsões e observações para horiz. de 4 dias – ordem crescente – COM previsão de chuva.....	61
Figura 5.19 – Previsões e observações para horiz. de 5 dias – ordem crescente – COM previsão de chuva.....	62
Figura 5.20 – Histogramas para as amostras de treinamento e verificação.....	63
Figura 5.21 – Histograma bidimensional da contagem de combinações entre os níveis anteriores observados (entrada do modelo).....	65
Figura 5.22 - Previsões e observações para horiz. 1 dia – ordem original – COM e SEM previsão de chuva.....	70
Figura 5.23 - Previsões e observações para horiz. 2 dias – ordem original – COM e SEM previsão de chuva.....	71
Figura 5.24 - Previsões e observações para horiz. 3 dias – ordem original – COM e SEM previsão de chuva.....	71
Figura 5.25 - Previsões e observações para horiz. 4 dias – ordem original – COM e SEM previsão de chuva.....	71
Figura 5.26 - Previsões e observações para horiz. 5 dias – ordem original – COM e SEM previsão de chuva.....	72

Figura 5.27 - Previsões e observações para horiz. 1 dia – ordem crescente – COM e SEM previsão de chuva.	72
Figura 5.28 - Previsões e observações para horiz. 2 dias – ordem crescente – COM e SEM previsão de chuva.	73
Figura 5.29 - Previsões e observações para horiz. 3 dias – ordem crescente – COM e SEM previsão de chuva.	73
Figura 5.30 - Previsões e observações para horiz. 4 dias – ordem crescente – COM e SEM previsão de chuva.	73
Figura 5.31 - Previsões e observações para horiz. 5 dias – ordem crescente – COM e SEM previsão de chuva.	74
Figura 5.32 - Previsões e observações para horiz. 1 dia – ordem original – RN e REGRE COM previsão de chuva.	77
Figura 5.33 - Previsões e observações para horizonte de 2 dias – ordem original – RN e REGRE COM previsão de chuva.	77
Figura 5.34 - Previsões e observações para horizonte de 3 dias – ordem original – RN e REGRE COM previsão de chuva.	78
Figura 5.35 - Previsões e observações para horizonte de 4 dias – ordem original – RN e REGRE COM previsão de chuva.	78
Figura 5.36 - Previsões e observações para horizonte de 5 dias – ordem original – RN e REGRE COM previsão de chuva.	78
Figura 5.37 - Previsões e observações para horizonte de 1 dia – ordem crescente – RN e REGRE COM previsão de chuva.	79
Figura 5.38 - Previsões e observações para horizonte de 2 dias – ordem crescente – RN e REGRE COM previsão de chuva.	79
Figura 5.39 - Previsões e observações para horizonte de 3 dias – ordem crescente – RN e REGRE COM previsão de chuva.	80
Figura 5.40 - Previsões e observações para horizonte de 4 dias – ordem crescente – RN e REGRE COM previsão de chuva.	80
Figura 5.41 - Previsões e observações para horizonte de 5 dias – ordem crescente – RN e REGRE COM previsão de chuva.	80

Lista de Tabelas:

Tabela 3.1 - Tempo de retorno, vazão máxima e cota, na seção Quaraí/Artigas (PPGICBRQ, 2005).....	27
Tabela 3.2 - Localização dos postos de monitoramento telemétrico	28
Tabela 3.3 - Coordenadas dos pontos de previsão hidrometeorológica.....	29
Tabela 4.1 – Amostra para treinamento da rede neural.....	35
Tabela 4.2 – Médias das variáveis de entrada para os 3 grupos.....	36
Tabela 4.3 – Médias das variáveis de saída para os 3 grupos.....	36
Tabela 4.4 – Interpretações para o índice CP.	37
Tabela 4.5 – Ponderadores para nota da qualidade dos resultados da rede neural.	42
Tabela 4.6 – Parâmetros que foram experimentados na segunda etapa da eleição.....	43
Tabela 5.1 – Contagem de observações e/ou previsões de precipitação nula.	48
Tabela 5.2 – Índices estatísticos para o resíduo de “Alerta Falso”.....	48
Tabela 5.3 – Índices estatísticos para o resíduo de “Incapacidade de Previsão”.....	49
Tabela 5.4 – Índices estatísticos para dados com chuva prevista e observada não nula.....	50
Tabela 5.5 – Melhor índice para os conjuntos com 30 e 100 repetições do treinamentos e para os 5 horizontes de previsão.....	54
Tabela 5.6 – Resultados para cada configuração de rede neural (horiz. 1 dia) COM previsão de chuva	54
Tabela 5.7 – Resultados para cada configuração de rede neural (horiz. 2 dias) COM previsão de chuva	55
Tabela 5.8 – Resultados para cada configuração de rede neural (horiz. 3 dias) COM previsão de chuva	55
Tabela 5.9 – Resultados para cada configuração de rede neural (horiz. 4 dias) COM previsão de chuva	56
Tabela 5.10 – Resultados para cada configuração de rede neural (horiz. 5 dias) COM previsão de chuva	56
Tabela 5.11 – Arquiteturas ótimas de rede neural para o modelo COM uso de previsão de chuva.....	57
Tabela 5.12 – Resultado para a amostra de verificação – Modelo RN COM previsão de chuva.	57
Tabela 5.13 - Maiores erros por “Alerta Falso” – Horiz. 1 dia – COM previsão de chuva.	63
Tabela 5.14 - Maiores erros por “Incapacidade de Previsão” – Horiz. 1 dia – COM previsão de chuva.....	63
Tabela 5.15 - Maiores erros por “Alerta Falso” – Horiz. 2 dias – COM previsão de chuva....	63

Tabela 5.16 - Maiores erros por “Incapacidade de Previsão” – Horiz. 2 dias – COM previsão de chuva.	63
Tabela 5.17 - Maiores erros por “Alerta Falso” – Horiz. 3 dias – COM previsão de chuva....	64
Tabela 5.18 - Maiores erros por “Incapacidade de Previsão” – Horiz. 3 dias – COM previsão de chuva.	64
Tabela 5.19 - Maiores erros por “Alerta Falso” – Horiz. 4 dias – COM previsão de chuva....	64
Tabela 5.20 - Maiores erros por “Incapacidade de Previsão” – Horiz. 4 dias – COM previsão de chuva.	64
Tabela 5.21 - Maiores erros por “Alerta Falso” – Horiz. 5 dias – COM previsão de chuva....	64
Tabela 5.22 - Maiores erros por “Incapacidade de Previsão” – Horiz. 5 dias – COM previsão de chuva.	64
Tabela 5.23 - Resultados para cada configuração de rede neural (horiz. 1 dia) – SEM previsão de chuva.	66
Tabela 5.24 - Resultados para cada configuração de rede neural (horiz. 2 dias) – SEM previsão de chuva.	67
Tabela 5.25 - Resultados para cada configuração de rede neural (horiz. 3 dias) – SEM previsão de chuva.	67
Tabela 5.26 - Resultados para cada configuração de rede neural (horiz. 4 dias) – SEM previsão de chuva.	68
Tabela 5.27 - Resultados para cada configuração de rede neural (horiz. 5 dias) – SEM previsão de chuva.	68
Tabela 5.28 – Arquiteturas ótimas de rede neural para o modelo SEM uso de previsão de chuva.	69
Tabela 5.29 - Resultados para a amostra de verificação – modelo RN SEM previsão de chuva.	69
Tabela 5.30 – Resultados para a amostra de verificação – modelos RN COM e SEM previsão de chuva.	70
Tabela 5.31 – Resultados para cada modelo de previsão por regressão linear multivariada. ..	75
Tabela 5.32 - Resultado para a amostra de verificação – modelo Regressão COM previsão de chuva.	76
Tabela 5.33 – Resultados para a amostra de verificação – modelos Regressão e RN COM previsão de chuva.	76
Tabela 5.34 - Maiores erros por “Alerta Falso” – horiz. 1 dia – REGRE COM previsão de chuva.	81

Tabela 5.35 - Maiores erros por “Incapacidade de Previsão” – horiz. 1 dia – REGRE COM previsão de chuva.	81
Tabela 5.36 - Maiores erros por “Alerta Falso” – horiz. 2 dias – REGRE COM previsão de chuva.....	81
Tabela 5.37 - Maiores erros por “Incapacidade de Previsão” – horiz. 2 dias – REGRE COM previsão de chuva.	81
Tabela 5.38 - Maiores erros por “Alerta Falso” – horiz. 3 dias – REGRE COM previsão de chuva.....	82
Tabela 5.39 - Maiores erros por “Incapacidade de Previsão” – horiz. 3 dias – REGRE COM previsão de chuva.	82
Tabela 5.40 - Maiores erros por “Alerta Falso” – horiz. 4 dias – REGRE COM previsão de chuva.....	82
Tabela 5.41 - Maiores erros por “Incapacidade de Previsão” – horiz. 4 dias – REGRE COM previsão de chuva.	82
Tabela 5.42 - Maiores erros por “Alerta Falso” – horiz. 5 dias – REGRE COM previsão de chuva.....	82
Tabela 5.43 - Maiores erros por “Incapacidade de Previsão” – horiz. 5 dias – REGRE COM previsão de chuva.	82

Lista de Símbolos

α	coeficiente de declividade da função de ativação SATLIN
a_0, a_1, a_2 e a_3	parâmetros do modelo de regressão linear multivariada
b	tendência do neurônio matemático (<i>bias</i>)
CE	coeficiente de eficiência (Nash Sutcliffe)
CP	coeficiente de persistência
D	série de dados não escalonada (chuva e nível)
D_E	dado escalonado (chuva e nível)
D_i	dado a ser escalonado (chuva e nível)
E	erro entra dados calculados e alvo de uma rede neural
EMA	erro médio quadrático
EMQ	erro médio quadrático
EPA	erro padrão absoluto
g	gradiente da função de erro nos algoritmos de treinamento
h	cota do rio
H	horizonte de previsão
H_e	matriz <i>Hessiana</i>
I	vetor com o conjunto de resultados dos índices a serem ponderados
J	matriz <i>Jacobiana</i>
μ	coeficiente <i>momentum</i> para treinamento da rede neural
η	taxa de aprendizado no treinamento da rede neural
n	número de amostras
N	nível do rio Quaraí
NP	nota ponderada dos resultados dos índices
O	vetor de dados de saída da rede neural
P	vetor de entrada na rede neural

P_C	precipitação observada
P_O	precipitação observada
Q_{\max}	vazão máxima
N_{prev}	nível previsto pelo modelo de regressão linear multivariada
R	coeficiente de correlação ou de Pearson
R^2	coeficiente de determinação
SEMQ	função objetivo da soma do erro médio quadrático
$SEMQ_{\text{REG}}$	função objetivo da soma do erro médio quadrático com regularização <i>Bayesiana</i>
T	vetor de dados alvo da rede neural
Tr	período de retorno
U	ponderador da precipitação em função da magnitude do nível médio observado nos dois dias anteriores ao dia quando a previsão de nível é efetuada.
V	valor escalonado dos índices
V_C	volume total de precipitação observada
V_O	volume total de precipitação observada
w	peso de ponderação para notas de resultados de índices
W	pesos sinápticos dos neurônios
x	variável independente nas funções de ativação dos neurônios matemáticos
x_1	nível do rio em (i-2) “anteontem”
x_2	nível do rio em (i-1) “ontem”
x_3	previsão de chuva do modelo ETA acumulada até o horizonte de previsão
y	variável dependente nas funções de ativação dos neurônios matemáticos
Y	variável dependente do modelo de regressão linear multivariada

Lista de Siglas

ANA	Agência Nacional de Águas
Br	Brasil
BRAMS	Brazilian Regional Atmospheric Modeling System
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CPRM	Companhia de Pesquisa de Recursos Minerais
CTM	Comision Técnico Mixta de Salto Grande / Uruguay
DNH	Dirección Nacional de Hidrologia / Uruguay
ETA	modelo regional de previsão meteorológica numérica
IPH	Instituto de Pesquisas Hidráulicas
INPE	Instituto Nacional de Pesquisas Espaciais
MCGA	Modelo de Circulação Geral Atmosférico
NEC- SX3	super computador instalado no CPTEC em 1994
PPGIPH	Programa de Pós-graduação do Instituto de Pesquisas Hidráulicas
REGRE	modelo de regressão linear multivariada
RN	rede neural
SAISP	Sistema de Alerta de Inundações de São Paulo
UFRGS	Universidade Federal do Rio Grande do Sul
UTC	Universal Time (Hora universal)
Uy	Uruguai

1. Introdução

1.1 Motivação

As inundações são fenômenos naturais que existem desde antes do surgimento do homem no planeta Terra. Ao deixar de ser nômade, o homem preferencialmente ocupou as áreas próximas a cursos d'água, pois ali ele poderia ter acesso fácil a outros locais através de embarcações, água para o seu consumo e mesmo onde dispor seus dejetos. Esta preferência humana ainda prevalece nos dias de hoje e a grande maioria das cidades está próxima a cursos d'água, suscetíveis a inundações.

Nestas cidades, às margens de mananciais hídricos, a população mais antiga, que já presenciou eventos de inundação no passado, procura construir suas casas em locais mais altos para evitar inundações no futuro. Contudo, famílias de baixa renda e pouca experiência com as elevações dos níveis de água ocupam zonas baixas, onde podem ser atingidos com mais facilidade. Às vezes, um grande período sem ocorrência de inundação encoraja a população a ocupar estas áreas, pois é da natureza humana e animal aprender com experiências vividas. Como a experiência de uma inundação ainda não foi experimentada, atitudes deste tipo são tomadas freqüentemente.

Dentre as atividades para proteção contra inundações, existem as medidas estruturais e as não estruturais. As medidas estruturais são caracterizadas por intervenções físicas que modificam o escoamento, confinam o fluxo ou amortecem a onda de cheia.

Proteções estruturais, tais como diques, pôlderes e represas, sempre são projetadas para um determinado tempo de recorrência dos eventos de inundação, sendo que, para situações além do projetado, os prejuízos são amplificados, pois nas zonas “protegidas” a ocupação é intensificada pela falsa segurança de que a inundação nunca chegará àquela região.

Medidas de caráter não-estrutural são geralmente menos onerosas, sendo constituídas de regras para o convívio com as inundações sem intervenção física nos corpos d'água. Os exemplos mais comuns são zoneamentos e remoções, definitivas ou não, das áreas de risco de inundação.

A convivência com as inundações tornou-se uma exigência para muitas comunidades, que organizam-se de forma a minimizar os prejuízos causados pelas elevações das águas. Algumas das soluções são a construção de habitações elevadas (palafitas), e o deslocamento para zonas mais altas durante as cheias, o que não evita, nem definitiva e nem

eficazmente, alguns dos principais malefícios que uma inundação causa à população, tais como: doenças, perda de bens e interrupção das atividades profissionais.

Nas remoções não-definitivas, os órgãos governamentais criam uma equipe de Defesa Civil para gerenciar esta tarefa, que fica então encarregada de alertar, remover, fornecer auxílio médico, alimentos e abrigo aos atingidos por inundações. Assim, modelos de previsão de nível são de suma importância, para que estas ações possam ser planejadas e executadas em tempo hábil.

Sistemas de alerta de cheias, com antecedência de previsão suficiente para a ação da Defesa Civil, podem ser implantados com custos relativamente baixos, em comparação com os custos usuais das medidas estruturais, podendo ser muito importantes para a minimização dos prejuízos materiais e de perdas de vidas humanas.

Fornecer uma previsão diária, ao invés de prever o nível somente quando o evento de chuva já tiver iniciado, pode ser uma informação mais proveitosa para os tomadores de decisão, que podem então antecipar-se ao fenômeno, deixando de sobreaviso uma equipe treinada para agir em situação de inundação iminente.

Em bacias com resposta rápida, a previsão de precipitação é de grande importância na previsão da elevação do nível d'água, pois o simples monitoramento de níveis a montante não permite prever o nível com a antecipação suficiente para a emissão do alerta de inundação.

As técnicas de modelagem empírica permitem a assimilação de erros sistemáticos nas avaliações das entradas de precipitação prevista, sendo uma preocupação pertinente, no caso de comporem um sistema de alerta de cheias, porém apresentam restrições nos casos de necessidade de extrapolação de previsão fora dos limites de abrangência da amostra de calibração.

Nas modelagens conceituais, por sua vez, apresentam dificuldades de representação, com o detalhamento e a abrangência suficientes, das características físicas da bacia, o que introduz, inevitavelmente, incertezas no processo de previsão de nível.

Comparar o efeito de utilizar-se uma variável a mais em modelos conceituais exige a calibração de dois modelos distintos, comprometendo assim, a comparação pura do efeito da informação agregada, uma vez que os modelos também não são os mesmos. No caso de redes neurais, trabalha-se com duas redes, as quais são, teoricamente, igualmente capazes de aproximação, sendo que uma trabalha com mais informações. Sendo assim, a técnica de redes neurais é uma candidata adequada para a avaliação imparcial do ganho de qualidade na previsão de níveis fluviais ao utilizar a previsão de precipitação.

As redes neurais artificiais, em síntese, são aproximadores ótimos de funções, e apresentam boa robustez para filtrar ruídos nos dados de entrada, porém observam-se algumas limitações, tais como:

- Alta dependência das condições iniciais para o ajustamento correto, sendo que este aspecto não tem sido abordado para aplicações hidrológicas;
- Limitação ao domínio utilizado no treinamento. No caso das aplicações hidrológicas, a amostragem nos extremos é, em geral, menos densa, prejudicando as respostas para as entradas nestas faixas. Uma metodologia para a constatação e identificação deste domínio de utilização, especialmente para aplicações práticas de engenharia, é uma carência constatada;
- A capacidade de generalização, ou extrapolação no domínio, é dependente, além da arquitetura da rede, das técnicas utilizadas para o treinamento, especialmente quanto aos critérios para a interrupção. A identificação ou isolamento da banda aleatória, neste caso, é fundamental, para evitar-se o superajustamento, e depende em grande medida da amostragem. As formas usuais de partição da amostragem, no entanto, exigem dados com quantidade e representatividade muitas vezes impraticáveis.

A etapa conclusiva e fundamental de toda modelagem hidrológica é a avaliação da qualidade dos resultados, onde são tradicionalmente utilizados índices de comparação relativa. Estas avaliações comparativas muitas vezes são contraditórias, pois avaliam aspectos diferentes do comportamento do modelo, podendo ocorrer o interesse em mais de um destes aspectos, havendo necessidade de ponderação ou conciliação de objetivos, para então, proceder-se à execução de uma avaliação mais integral e menos reducionista.

Assim, nesta pesquisa utilizou-se, além dos índices tradicionais de avaliação da qualidade de modelo, um índice absoluto, com significado imediato e intuitivo. Este índice informa a magnitude do erro que não foi ultrapassado em um certo percentual do tempo, tendo a vantagem de possuir uma interpretação não meramente comparativa com o desempenho de outros modelos hipotéticos, a exemplo do coeficiente de permanência, ou o índice de Nash.

Portanto, julgou-se oportuno executar, nesta pesquisa, uma análise mais rigorosa dos aspectos de aplicação hidrológica de redes neurais progressivas, tendo-se em conta que essa ferramenta ainda não foi alvo de um aprofundamento, que abordasse adequadamente os riscos e as possibilidades que ela proporciona para esta aplicação específica.

1.2 Objetivos

O objetivo geral, a ser atingido com esta pesquisa, é investigar se a previsão de níveis fluviais com uso de técnicas de redes neurais artificiais pode ter algumas de suas deficiências, observadas para este tipo de aplicação, superadas através de investigações de recursos de natureza estratégica ou matemática, de forma a viabilizar o uso desta técnica. Estas deficiências são geralmente ignoradas pela maioria dos autores, deixando dúvidas sobre a aplicabilidade de muitos trabalhos.

Este objetivo pode ser detalhado nos itens específicos:

- Verificar a praticabilidade do isolamento da banda aleatória dos dados, para efeito de validação cruzada, por uma partição seqüencialmente alternada das amostras de séries hidrológicas;
- Investigar as possíveis diferenças, na convergência, pelo uso de um método, assemelhado ao Método de Monte Carlo, para contornar a tendência ao mínimo local, no treinamento de redes neurais para modelagem de previsão;
- Utilizar um recurso para avaliação da qualidade absoluta dos modelos, que não requer comparação com outros modelos alternativos, uma vez que tem um significado intuitivo e direto;
- Experimentar, paralelamente, a aglutinação ponderada de diversos índices para avaliação comparativa, verificando a qualidade relativa, em termos de ordem de grandeza, do modelo por redes neurais, quando comparado com um modelo tradicional;

Um segundo objetivo proposto nesta pesquisa é de verificar os ganhos obtidos (ou, por outro lado, as perdas de desempenho) na previsão de nível, com uso de previsões de precipitação, comparando-se os resultados de redes neurais treinadas com e sem esta informação adicional, tendo-se em conta suas propriedades de aproximação. Neste caso, como o modelo é um aproximador universal, constitui-se uma oportunidade para a verificação da relevância da informação, uma vez que se pode supor que possíveis deficiências de representação não estão prejudicando o aproveitamento integral deste dado.

1.3 Estudo de caso

Nas cidades de Quaraí (Brasil) e Artigas (Uruguai), às margens do Rio Quaraí (Cuareim, para os uruguaios), os habitantes da região têm convivido com as cheias do rio, sendo removidos quando o nível da água já atinge as suas habitações, causando problemas de saúde pública, prejuízos materiais e até perdas humanas. Esta situação ocorre por motivo de insegurança, uma vez que a população atingida freqüentemente reluta em abandonar suas

casas com seus pertences, por falta de credibilidade nos avisos de evacuação emitido pela defesa civil, e também por receio do reassentamento forçado em áreas sem risco de inundação, pois essa população ocupa esta área há muitos anos e ali encontra condições socioeconômicas adequadas às suas aspirações.

O custo de medidas estruturais para amenizar o problema das inundações nas cidades fronteiriças de Quaraí e Artigas é elevado, inviabilizando este tipo de solução.

Para o caso em questão da bacia do rio Quaraí, a medida com maior probabilidade de ser implantada, em curto prazo, seria um sistema de alerta de cheias, conjuntamente com a criação de uma equipe responsável pela evacuação dos possíveis atingidos pela cheia do rio. Para que um sistema de alerta funcione corretamente é necessário que o modelo de previsão de nível seja confiável e preciso.

O estudo e a aplicação de um modelo para a previsão de níveis fluviais em Quaraí apresenta os seguintes obstáculos :

- A grande incerteza existente nas previsões de precipitação;
 - A compreensão incompleta das leis físicas que regem a formação de chuvas;
 - A não-linearidade, reconhecidamente presente em todos os processos de transformação da chuva em vazão.
- A possibilidade de falha ou perturbações na aquisição de dados de entrada, à medida que ocorre possível degradação do sistema, com a progressão da situação de calamidade.

Tendo-se em conta as características do comportamento hidrológico da bacia do rio Quaraí, vislumbrou-se a oportunidade de aplicar as metodologias propostas nesta pesquisa a este caso de estudo, já que redes neurais artificiais são candidatas interessantes para a aplicação em previsões de fenômenos naturais, e, por extensão, aos níveis de rios.

2. Revisão Bibliográfica

2.1 Alerta de Cheias

2.1.1 Sistemas de Alerta

As previsões, bem como as tomadas de decisões, para atendimento às emergências causadas pelas inundações, são, ou deveriam ser, executadas no âmbito de sistemas de alerta de inundações. Estas inundações ocorrem distribuídas no tempo de forma aparentemente aleatória, o que pode exigir grande complexidade destes sistemas, devido à manipulação de incertezas.

Os sistemas de alerta, conforme Krzysztofowicz (1993), são compostos basicamente por três módulos, que funcionam em “cascata”: o primeiro é o monitoramento, o segundo a previsão, e o terceiro a decisão.

Uma descrição de sistemas de alerta de previsão em tempo real, de um ponto de vista funcional e hidrológico, é apresentada por Tucci (2003), e consiste nos seguintes aspectos:

- Sistema de coleta e transmissão de informações;
- Sistema de processamento de informações;
- Modelo de previsão de vazões e níveis;
- Procedimentos para acompanhamento e transferência de informação para a Defesa Civil e Sociedade;
- Planejamento das situações de emergência por parte do órgão de Defesa Civil.

Um exemplo de sistema de alerta sofisticado é o da SAISP (Sistema de Alerta de Inundações de São Paulo) que gera a cada cinco minutos boletins sobre as chuvas e suas conseqüências para a cidade de São Paulo. Estas previsões são obtidas com o auxílio de uma rede telemétrica bem distribuída, constituída por linígrafos, pluviógrafos e radar meteorológico, para previsão empírica estocástica do incremento de afluências para o próximo estágio de tempo, baseado numa combinação linear de chuvas passadas nas isócronas e incrementos passados de afluências.

Um sistema de alerta de cheias eficiente e confiável é ferramenta essencial para a ação da Defesa Civil. Estes sistemas devem ser capazes de prever o evento com antecedência suficiente para que ações cabíveis possam ser executadas, tais como a remoção da população, de animais e de bens materiais.

A utilização de sistemas de alerta de cheias, como medida não estrutural, envolve investimentos relativamente reduzidos, e os resultados, de controle e redução dos impactos das inundações, são obtidos em curto prazo.

2.1.2 Modelos de Previsão de Nível

Os modelos matemáticos hidrológicos podem ser classificados, quanto aos fundamentos lógicos, em empíricos ou conceituais e, quanto às incertezas de natureza estatística, em determinísticos ou estocásticos.

Modelos matemáticos empíricos são ajustes de funções baseados em dados observados, e não pretendem reproduzir a natureza física dos fenômenos, sendo também chamados de modelos tipo “caixa preta” (Tucci, 1998). Estes modelos podem não responder corretamente quando utilizados fora dos limites investigados por ocasião de seu ajustamento, efetuado com dados observados.

Modelos matemáticos conceituais descrevem os processos físicos, teoricamente permitindo extrapolações. As dificuldades encontradas por estes modelos são a variabilidade espacial dos processos físicos, a estimação correta dos parâmetros e a incapacidade de atualizar automaticamente seus parâmetros em processos com mudança de comportamento (Tucci, 1998).

Modelos determinísticos não utilizam conceitos probabilísticos em suas respostas, ou seja, respondem sempre com valores exatos, e para a mesma entrada sempre apresentam a mesma saída. Modelos estocásticos, por sua vez, apresentam respostas probabilísticas, em forma de intervalos de confiança, e, para a mesma entrada, respondem com saídas diferentes, de natureza aleatória (Tucci, 1998).

No caso específico de previsões de níveis d'água em rios, os principais dados utilizados nos modelos são níveis a montante, chuva precipitada e previsão de precipitação, que podem ser utilizados como insumo, tanto para modelos conceituais como para modelos empíricos.

A maior parte dos modelos para previsões de níveis são ajustados e verificados com base em eventos, quando o usuário já sabe que está em presença de uma ocorrência de cheia. Nestes casos, podem-se obter reproduções com grande precisão, uma vez que o que os modelos estão fazendo é reproduzir as formas dos hidrogramas ou linigramas, condicionadas a que realmente aconteçam. Segundo Pedrollo (2000), a utilidade destes modelos é discutível, uma vez que o tomador de decisões não sabe, em situações reais, se terá futuramente uma ocorrência do tipo que os modelos, empíricos ou conceituais, reproduzem, e não pode obter esta informação destes modelos.

Previsões de curto prazo, ou previsões em tempo atual, são baseadas na premissa de que os cenários futuros são influenciados fortemente pelas condições atuais das suas variáveis independentes.

Os modelos de previsão de nível baseados em leituras de níveis a montante são feitos baseados em conceitos de propagação de onda de cheia no canal principal de drenagem da bacia. Para trechos com contribuição lateral de pequena significância, apenas o monitoramento da calha principal é suficiente. Caso a contribuição lateral tenha significância, os afluentes também devem ser monitorados e adicionados aos resultados do modelo de propagação de onda.

Dentre os modelos de propagação de onda mais conhecidos e utilizados, Tucci (1998) apresenta o desenvolvimento de alguns modelos de regressão, linear e não linear, a partir de modelos conceituais de propagação (Muskingun-Cunge), recomendando o uso fundamentado destes modelos para a previsão propagativa em tempo atual. Estes modelos são aplicáveis a casos onde o intervalo de tempo entre a leitura (a montante) e a previsão do nível no ponto de interesse (a jusante) é suficiente para as ações cabíveis, seja para evacuações, navegação ou operação de comportas de reservatórios.

Os modelos chuva-vazão, baseados em precipitações observadas, possuem a desvantagem de as chuvas terem de ser transformadas em escoamento, o que implica em uma série de incertezas nos parâmetros de entrada, como coeficientes de permeabilidade, declividades, cobertura do solo, distribuição espacial e temporal das chuvas e curva-chave. Sua grande vantagem é de que o dado de precipitação é geralmente mais abundante e promove uma antecedência maior para bacias pequenas, onde o tempo de concentração é pequeno e não permite uma previsão em tempo atual por observação de níveis a montante do ponto desejado.

A escolha do modelo mais adequado ao problema da bacia pode ser feita com base na área de contribuição da bacia. Para bacias com área maior que 10.000 km², o uso da teoria da propagação da onda de cheia com coleta de dados de níveis a montante é suficiente para se ter uma previsão com boa antecedência e precisão. Para bacias de médio porte a previsão deve ser feita com os dados de precipitação observados, e para bacias com área menor que 1.000 km², somente com previsão de precipitação é possível desenvolver um modelo que forneça tempo razoável de antecedência à inundação (Pedrollo, 2000).

Na previsão de nível com uso de precipitação prevista consegue-se, via de regra, uma antecedência ainda maior, porém, é acrescentada em sua resposta a incerteza do próprio modelo de previsão de chuva, cujos resultados por vezes não são de boa qualidade, prejudicando os resultados finais.

Praticamente todas as previsões apresentam imprecisões, geradas pelas incertezas naturais dos parâmetros e dos processos que regem a sua dinâmica.

Em geral, os resultados das previsões são apresentados de forma determinística, o que não corresponde à realidade. Uma apresentação mais adequada dos resultados é realizada, por exemplo, pela representação da incerteza através de intervalos de confiança, com os seus limites de erro e o grau de significância associado, o que implica em uso de modelos estocásticos, ou com componentes de natureza estocástica.

2.2 Previsão Meteorológica

2.2.1 Conceitos Básicos

A previsão meteorológica sempre despertou forte interesse para o homem. Nos primórdios, as condições meteorológicas eram frequentemente atribuídas a decisões divinas, devido ao comportamento aleatório (imprevisível) da atmosfera.

A observação sistemática, na superfície terrestre, de algumas variáveis, tais como temperatura, pressão atmosférica, vento, umidade relativa do ar, permite prever a tendência futura do comportamento do tempo, embora com incertezas. No sentido de diminuir as incertezas de previsão, as informações destas variáveis, obtidas em vários postos por todo o planeta, são analisadas em conjunto, o que possibilita a determinação de suas variações espaciais e, assim, as previsões dos deslocamentos de massas de ar, que são os principais responsáveis pelas mudanças meteorológicas.

Mesmo assim, com a disponibilidade de dados observados em vários locais do planeta, a previsão meteorológica não era confiável para alcances maiores que 1 dia, e dependia fortemente da experiência do meteorologista.

A exigência de mais dados, para produzir previsões de tempo menos subjetivas, incentivou a evolução dos instrumentos de medição: além das observações de superfície, iniciou-se o uso de radiosondagens, que registram os valores das variáveis meteorológicas e as transmitem, por ondas de rádio, a um receptor em terra. Desde a década de 1970, a utilização de satélites artificiais fornece imagens dos estados das massas de ar. Juntamente com informações provenientes de bóias oceânicas, navios e aviões, são geradas cartas sinópticas, e a análise destas cartas resulta na previsão do tempo (Ferreira e Camargo, sd.).

Com a utilização de supercomputadores, como o NEC- SX3, instalado no CPTEC em 1994, é possível gerar previsões objetivas, também chamadas de previsões numéricas, que são os resultados da aplicação de modelos físicos de conservação de energia, massa e momento (Ferreira e Camargo, sd.).

A previsão hidrometeorológica é a que tem maior importância para a sociedade em geral, tanto para fins econômicos como sociais, mas também é a variável que apresenta a

maior dificuldade de previsão, devido à exigência de combinação correta entre as 3 variáveis principais responsáveis pela instabilidade atmosférica (pressão, temperatura e umidade).

Na moderna meteorologia, as previsões são feitas através de modelos numéricos, que são sofisticados programas de computador que assimilam toda a informação meteorológica e integram equações diferenciais parciais que representam basicamente a equação do momento, a equação da energia termodinâmica e a equação da continuidade da massa atmosférica. Com as facilidades da Internet — velocidade e acessibilidade — o acesso aos dados pré-processados de forma rápida tem viabilizado as previsões numéricas que são feitas hoje no Brasil.

A percepção de John von Neumann da potencial evolução da previsão meteorológica com o emprego da computação confirmou-se; a partir do início das previsões numéricas, ocorrido na década de 1950, houve uma intensa busca por melhores resultados, de forma que na década de 1990 já era possível a obtenção de previsões numéricas para toda a área dos Estados Unidos com 24h de antecedência, com um índice de acerto de 97% (Moura, 1996).

Atualmente, existem em operação no Brasil diversos modelos de previsão numérica, com uma variada utilização de resoluções de cálculo, horizontes de previsão, e variáveis de entrada e saída. Os modelos mais conhecidos são o ETA-CPTEC, MCGA-CPTEC e o BRAMS, e seus resultados podem ser acessados pela página eletrônica do CPTEC/INPE (Centro de Previsão do Tempo e Estudos Climáticos/Instituto Nacional de Pesquisas Espaciais) e do INMET (Instituto Nacional de Meteorologia), ambas instituições vinculadas ao governo federal brasileiro.

Como, no presente trabalho, foram utilizados os dados de previsão hidrometeorológica do modelo regional ETA, este é descrito, sucintamente, no item seguinte.

2.2.2 O Modelo de Previsão Meteorológica ETA

O ETA é um modelo de área limitada, implementado no CPTEC/INPE com o objetivo de detalhar (*downscaling*) a previsão meteorológica numérica, realizada com o modelo de circulação geral atmosférica. O modelo ETA usa como condições de contorno os valores da previsão numérica global, discretizada em uma grade de 200 km × 200 km. As condições iniciais, para integração do modelo global, são obtidas de observações no horário sinótico. Este modelo prevê fenômenos de mesoescala (tais como efeitos orográficos, brisas marítimas, tempestades) cobrindo a maior parte da América do Sul.

Uma das características principais desse modelo é a coordenada vertical (Mesinger, 1984). A vantagem desta coordenada é que as superfícies correspondentes são aproximadamente horizontais, o que reduz os erros nos cálculos de variáveis obtidas a partir de derivadas horizontais. Estes erros são significativos em regiões de montanhas íngremes,

como é o caso dos Andes na América do Sul. Devido à grande importância desta coordenada, o modelo foi batizado de ETA, pois esta foi a letra grega empregada para simbolizar tal coordenada.

A teoria física empregada pelo modelo para prever precipitações é o esquema de Betts-Miller modificado para parametrizar a convecção (Janjic, 1994). A condensação em larga escala ocorre quando a umidade relativa excede 95%.

O modelo ETA é estruturado em uma grade, cuja resolução horizontal pode ser de 40 km × 40 km ou 80 km × 80 km. Para cada ponto dessa grade, o modelo fornece os valores de previsão de precipitação, temperatura, pressão, umidade e outros. A orografia é representada por “degraus”, sendo a altura de cada degrau obtida através do valor médio das máximas topográficas existentes em cada célula da grade. A temperatura da superfície do mar é mantida constante durante a integração, e é obtida a partir da média da semana anterior; já o albedo inicial é função de uma climatologia sazonal.

Devido à maior não-linearidade dos sistemas nesta escala, o horizonte de antecedência é menor, permitindo apenas previsões de curto prazo. No caso do ETA, as previsões se estendem até 120 h (5 dias) e cobrem a maior parte da América do Sul. Essas previsões são fornecidas duas vezes ao dia, em uma grade regular com resolução de 40 km.

O modelo ETA tem sido constantemente melhorado, e previsões com horizontes maiores do que 5 dias estão sendo disponibilizados na página eletrônica do CPTEC (www.inpe.cptec.br).

2.3 Redes Neurais Artificiais

2.3.1 Introdução

As redes neurais artificiais são fruto da tentativa de representar matematicamente o funcionamento do neurônio biológico.

A descoberta do neurônio biológico (Figura 2.1) e as primeiras conclusões sobre seu funcionamento foram feitas no século XIX, pelo neurologista espanhol Ramón y Cajal (Cajal, 1894), que retrata o neurônio com notável detalhamento. Ainda no século XIX, seu funcionamento foi estudado por Dubois Reymond, com o auxílio de galvanômetros para observar as manifestações elétricas do neurônio (Katz, 1966). No entanto, seu funcionamento foi mais bem compreendido por Erlanger e Gasser (1924) após a invenção do tubo de raios catódicos na década de 20, quando o neurônio passou a ser entendido como o “dispositivo computacional elementar” do sistema nervoso dos seres vivos.

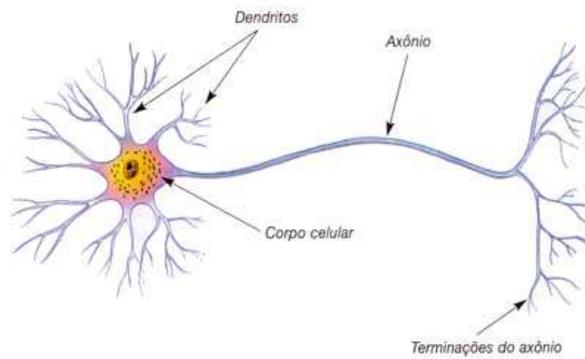


Figura 2.1 – Neurônio Biológico.

A partir de então, vários pesquisadores dedicaram-se à tentativa de representar matematicamente o funcionamento do neurônio biológico, onde podemos destacar como precursores McCulloch e Pitts, em 1943, Hebb em 1949 e Rosenblatt em 1958 (Kovacs, 1996).

O interesse em pesquisar redes neurais foi muito reduzido durante a década de 70, devido a fortes limitações encontradas no processo de treinamento de redes neurais. Somente em 1980 o assunto voltou a causar interesse na comunidade científica, com o trabalho de Hopfield com memórias associativas. Em 1986 houve o maior avanço no tema, com o método de retropropagação implementado por Rumelhart, Hilton e Williams (Rumelhart *et. al.*, 1986). Desde então, o uso de redes neurais vem sendo cada vez mais utilizado para diversos fins, tais como aproximação de funções complexas, classificação de padrões, previsão de séries temporais, minimização de funções e outras aplicações.

A utilização das redes neurais artificiais em diversas áreas é devido ao fato deste método extrair informação dos dados e generalizar sua resposta para cenários diferentes dos já ocorridos, de forma eficiente.

2.3.2 Rede Neural Booleana de McCulloch e Pitts

A representação matemática proposta na década de 40 por McCulloch e Pitts, publicada em um artigo no Bulletin of Mathematical Biophysics, foi o marco inicial em redes neurais. Apesar de ser extremamente simples, este estudo abriu campo para que outros pesquisadores também investissem no desenvolvimento de técnicas para refinar cada vez mais a representação matemática do funcionamento do elemento fundamental do sistema nervoso dos seres vivos, o neurônio. Assim, foi lançada a idéia para a criação da “inteligência artificial”.

O neurônio booleano de McCulloch e Pitts era um dispositivo binário: sua saída poderia ser pulso ou não-pulso, e as suas várias entradas possuíam ganho arbitrário e podiam ser excitatórias ou inibitórias (Kovacs, 1996).

O processo realizado em cada neurônio é uma operação matricial da forma:

$$y = H\left(\sum_{i=1}^n w_i p_i - b\right)$$

Onde : y é a resposta pulso (1) ou não-pulso (0 ou -1) de cada neurônio;
 H é a função de ativação degrau unitário;
 w são os pesos sinápticos de entrada de cada neurônio;
 p são as entradas a serem processadas no neurônio;
 b é a tendência de saída para cada neurônio.

Assim, o funcionamento de um neurônio pode ser resumido da seguinte forma:

- 1- Os sinais de entradas são fornecidos ao neurônio;
- 2- Cada entrada é multiplicada pelo seu ponderador, que influencia no sinal de saída;
- 3- O resultado destas multiplicações é somado;
- 4- O resultado da soma é aplicado à função de ativação que dará o sinal de saída “1”

se a soma ficar acima de um certo valor, e “0” ou “-1”, se ficar abaixo.

Este processo normalmente é usado na forma implícita, em que é acrescentada uma entrada unitária $P_{(i+1)} = -1$, e a tendência b é acrescentada como um peso $w_{(i+1)} = b$. A (Figura 2.2) mostra esquematicamente esta modificação sutil que simplifica a escrita em programação.

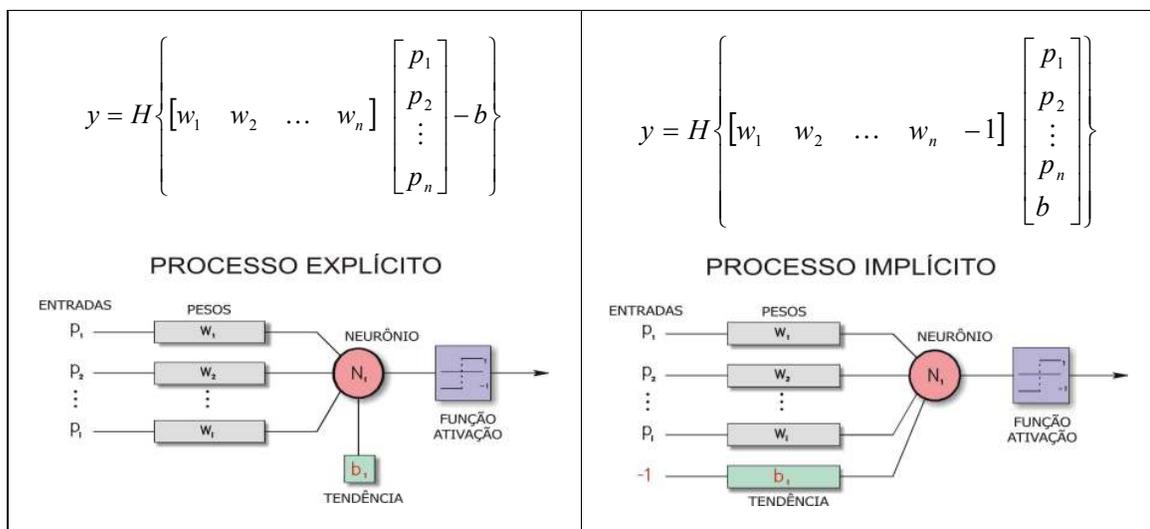


Figura 2.2 - Processamento Explícito e Implícito.

2.3.3 Métodos de Aprendizagem das Redes Neurais

As redes neurais propostas por McCulloch e Pitts no início da década de 40 não tinham uma regra de aprendizado definida, e os estudos posteriores foram dedicados ao problema do treinamento destas redes, surgindo então vários métodos para o aprendizado conforme classificações e descrições seguintes:

Método não-supervisionado: é usado quando a formulação do problema não contempla dados de saída e tem como objetivo, explicitamente, o agrupamento. A rede é treinada através de excitações ou padrões de entrada e então, o processo identifica e organiza as amostras em grupos. Se um novo padrão é identificado e este não possui uma classe, uma nova classe pode ser criada para associá-lo. Exemplos de redes que utilizam este método são as redes Kohonen (Demuth e Beale, 2004).

Este método de treinamento não é aplicável ao modelo proposto nesta pesquisa, tendo uma possível aplicação, apenas, em uma fase preliminar de redução da dimensionalidade do problema.

Método supervisionado: é o método normalmente usado para aproximação de funções e é utilizado freqüentemente em problemas de recursos hídricos, inclusive para previsão de níveis, que são casos onde ocorre o mapeamento entre os dados de entrada e os dados de saída.

Neste método o valor de saída obtido da rede é comparado à resposta desejada, e o algoritmo de treinamento tem como objetivo minimizar o erro, ajustando os pesos das entradas sinápticas até que este erro seja menor que do que o erro máximo tolerado pelo programador. O treinamento supervisionado pode ser feito em dois modos, conforme se deseje um modelo completamente ajustado, ou um modelo com atualização contínua (em "tempo atual") dos pesos sinápticos, o que seria interessante em sistemas com modificações em curso. Estes modos de treinamento são:

Treinamento por Batelada: usando o método por batelada, o treinamento é feito por ciclos, no qual cada ciclo corresponde à passagem de todos os dados pela rede neural, gerando um valor de saída para cada ciclo. Com essa saída o erro é calculado e então todos os pesos sinápticos são reajustados. Assim, a ordem dos dados de entrada não influencia no resultado final do treinamento.

Treinamento Seqüencial: com este método, a correção dos pesos sinápticos é feita para cada unidade amostral dos dados de entrada. Muitos autores (Kosko, 1992) consideram este método mais eficiente que o por batelada, mas, como é influenciado pela ordem em que os dados de entrada são fornecidos, recomenda-se, em geral, que o treinamento seja feito com diferentes ordenamentos dos dados de entrada, o que é uma dificuldade adicional.

Da mesma forma, a própria arquitetura da rede pode ser submetida a um processo matemático de adaptação, ou ser estabelecida aprioristicamente, neste caso, tem-se:

Treinamento Dinâmico: durante o treinamento a rede neural tem seu número de camadas, neurônios e/ou conexões alterado.

Treinamento Estático: é quando a configuração da rede não se altera até o término do treinamento, permanecendo com o mesmo número de camadas, neurônios e/ou conexões.

2.3.4 Regra Delta

Um método de treinamento bastante poderoso de treinamento é a Regra Delta. Esse princípio ainda hoje é utilizado na programação de redes neurais.

A Regra Delta, também chamada de Regra do Gradiente, procura por um ponto de mínimo da função do erro quadrático, fazendo o caminhamento no sentido oposto ao do gradiente da função.

Erro quadrático:

$$E(w) = \sum_{l=1}^L \left(\sum_{i=1}^n w_i p_{i,l} - y_l \right)^2$$

Cálculo do reajuste dos pesos (i+1):

$$w_{k+1} = w_k - \eta \nabla (E(w_k))$$

onde η é o tamanho do passo de aprendizado no sentido oposto.

Esta regra é o princípio básico para o treinamento de redes neurais, e é utilizado em algoritmos mais sofisticados, inclusive nos que foram empregados no presente trabalho.

2.3.5 Convergência, Passo Variável de Aprendizado e o Termo *momentum*

A convergência de uma rede neural, utilizando a Regra Delta para o aprendizado, é bastante lenta, comparada à velocidade de convergência dos métodos de aprendizagem mostrados anteriormente.

Esta velocidade de convergência é influenciada diretamente pelo ponto de partida fornecido e pelo tamanho do passo.

Caso o passo seja pequeno demais, a convergência será muito lenta. Se, por outro lado, o passo for demasiado grande, a convergência pode não ocorrer para o valor de erro máximo aceitável e resultar um sistema oscilatório indefinido.

A lentidão pode ser causada também pela ocorrência de superfícies de erro com pouca declividade em alguma região por onde o caminhamento, para o ponto de mínimo, passar (Figura 2.3, ponto 1). Caso o gradiente por onde os pontos de caminhamento são calculados seja grande, a convergência será mais rápida (Figura 2.3, ponto 2).

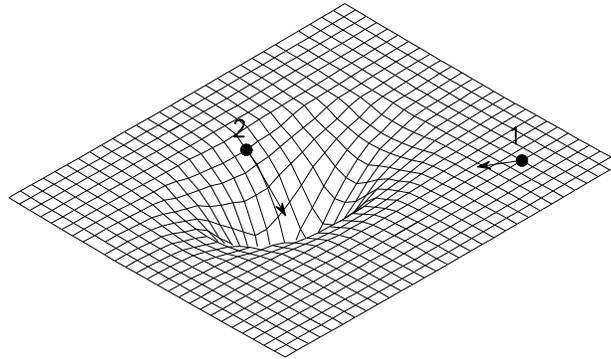


Figura 2.3 - Superfície da Função de Erro

O uso de um passo variável é uma prática que pode ser adotada para acelerar a convergência. Chamado também de termo de “taxa heurísticamente variável de aprendizado”, consiste em modificar a taxa de aprendizado em função da variação do desempenho. Assim, o tamanho do passo é aumentado caso o erro anterior seja maior que o erro atual, fazendo o caminhamento ter uma velocidade maior a cada passo que é dado na direção do ponto de mínimo. Caso o erro anterior seja menor que o atual, o tamanho do passo é reduzido, indicando que o caminhamento já passou pelo ponto de mínimo e está se distanciando.

O multiplicador para aumento do passo normalmente é entre 1,10 e 1,30, e o valor de multiplicação para a redução do passo é 0,50.

Os gráficos das Figuras 2.4 e 2.5 mostram um exemplo do comportamento do tamanho do passo e do valor do erro quadrático atual a cada iteração do processo de aprendizagem da rede neural.

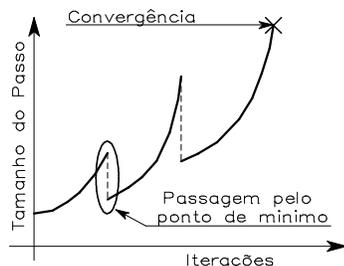


Figura 2.4 - Função Tamanho do Passo x N° Iterações

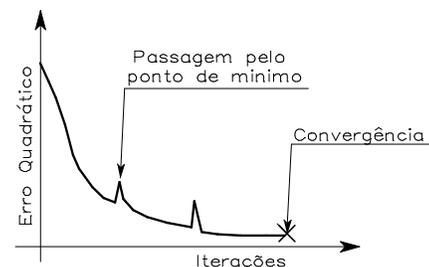


Figura 2.5 - Função Erro Quadrático x N° Iterações

Em especial, nas superfícies de erro que contêm ravinas com fundo muito agudo, é necessário que o passo de treinamento seja pequeno, causando lentidão no processo.

A observação de oscilações indesejadas na convergência do treinamento pode recomendar a incorporação de um novo termo ao método. Este termo é resultante do produto de um coeficiente chamado de *momentum* (μ) pela variação observada nos pesos, na iteração anterior. Trata-se, portanto, de um termo de inércia, pois confere uma maior estabilidade, mantendo, em uma certa medida, a tendência observada mais recentemente.

Termo de *momentum* adicionado à Regra Delta:

$$\Delta w_{k+1} = \eta \nabla (E(w_k)) + \mu \cdot \Delta w_k$$

$$\text{onde: } \Delta w_k = w_k - w_{k-1}$$

2.3.6 Escalonamento dos Dados de Entrada

Além da função de ativação linear, são usadas funções de ativação do tipo sigmóide (Figura 2.6), que permitem valores para ordenada entre -1 e 1 ou 0 e 1. Para o uso destes tipos de funções, é necessário fazer um escalonamento dos dados de entrada da rede e valores de pesos sinápticos iniciais aleatórios entre -1 e 1, para que os resultados do produto interno dos dados de entrada pelos pesos fiquem dentro do intervalo de sensibilidade da função de ativação. Se os parâmetros (pesos) forem suficientemente pequenos (~ 0), esta condição será atendida, independentemente das magnitudes das entradas, porém, se os pesos finais tiverem que ser excessivamente pequenos (caso de entradas muito grandes), podem ocorrer imprecisões de cálculo devido ao limite da representação numérica computacional.

É possível que, em muitos casos, o escalonamento dos dados de entrada previna o ajuste desigual dos pesos sinápticos, que causa convergência mais rápida junto aos nós com dados de maior magnitude, tendo-se em conta que estão sendo utilizadas taxas de aprendizado iguais para todas as conexões da rede neural.

No caso de utilização de funções sigmóides na rede neural, é aconselhado um escalonamento aquém dos limites definidos pelas suas assíntotas, pois nestas regiões da função o gradiente é próximo de zero, o que contribui para uma convergência lenta do treinamento (Sajikumar e Thandaveswara, 1999). Recomenda-se que o maior registro de cada amostra seja escalonado para um valor entre 0,80 e 0,95, e o menor registro de cada amostra seja escalonado para um valor entre 0,05 e 0,20 ou -0,95 e -0,80. Os valores intermediários são escalonados, mantendo suas proporções relativas entre si e os extremos (Figura 2.7).

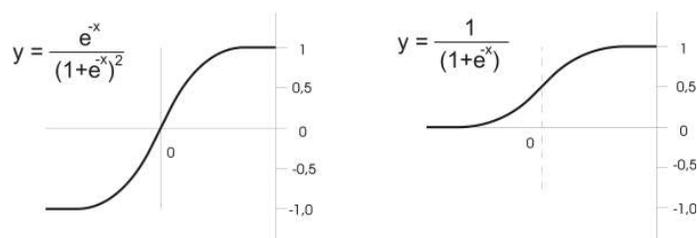


Figura 2.6 - Funções Sigmóides, Bi-polar e Unipolar.

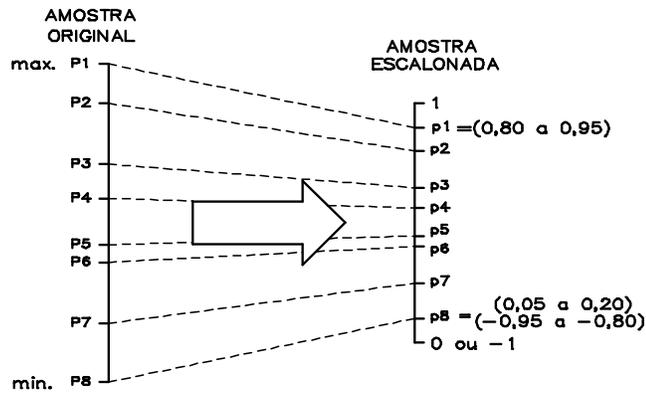


Figura 2.7 - Escalonamento dos dados.

Se os neurônios da camada de saída tiverem funções com intervalo limitado, os dados de saída devem também ser escalonados para compatibilizar a magnitude entre os dados de saída e os de entrada.

Em treinamentos com poucos dados, em que a amostra não garanta a representação dos limites máximos e mínimos, a utilização de funções sem limitação, como a “Linear”, é a mais recomendada, porém com ressalvas com relação à incapacidade de extrapolação para além dos limites determinados pela amostra de treinamento.

Para respostas nas quais valores negativos não são desejados, pode-se empregar limitadores, mantendo-se o seu mínimo valor de saída igual a zero.

2.3.7 Método da Retropropagação do Erro

Até meados da década de 1980, nenhum dos métodos sugeridos pelos pesquisadores era capaz de treinar uma rede com neurônios em camadas ocultas. O método da retropropagação (*backpropagation*) surgiu com o propósito de fazer este treinamento. Foi inventado e popularizado por Rummelhart, Hinton e Williams na década de 1980 (Rummelhart *et. al.*, 1986).

As redes com apenas uma camada têm uma séria limitação; elas distinguem apenas padrões lineares, não sendo adequadas para o uso em problemas mais complexos, tais como o proposto neste trabalho, que é a previsão de níveis fluviais.

Este método de treinamento é uma generalização da Regra Delta, no qual o erro é propagado a partir da saída da rede até a sua camada inicial.

Os pesos de cada neurônio são atualizados, aplicando-se a Regra Delta isoladamente a cada neurônio, sendo que as suas entradas são as saídas da camada anterior, e o seu erro resulta da soma, ponderada pelos pesos da camada posterior, dos produtos dos seus erros pelas derivadas das suas funções de ativação (Figura 2.8).

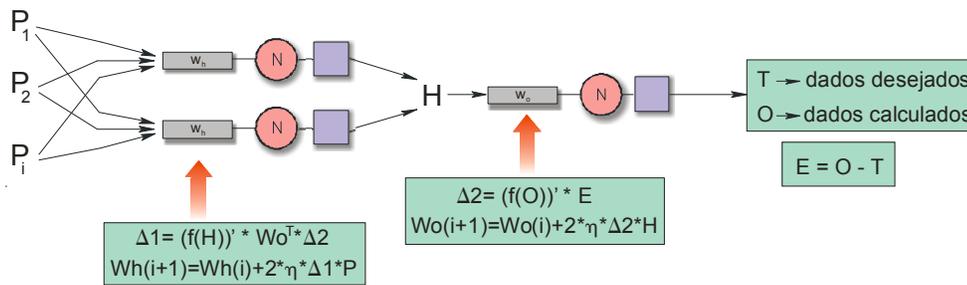


Figura 2.8 - Esquema do treinamento por retropropagação do erro.

O método da retropropagação do erro é muito poderoso, mas possui os mesmos problemas de convergência lenta que a Regra Delta. As mesmas alternativas recomendadas para a aceleração da convergência da Regra Delta podem ser empregadas para a retropropagação: a escolha de pontos de partidas distintos e o uso do termo *momentum*.

2.3.8 Arquitetura das Redes Neurais Artificiais

Uma rede neural é composta por camadas de processamento, podendo ter em cada camada vários neurônios. O dado é apresentado aos neurônios da primeira camada (ou camada de entrada), produzindo sinais em sua saída, que por sua vez, irão estimular os neurônios da camada subsequente e assim por diante, até atingir a última camada (camada de saída). A estrutura da rede fica então formada por uma camada de neurônios de saída, e as demais camadas são chamadas de ocultas ou intermediárias (Figura 2.9).

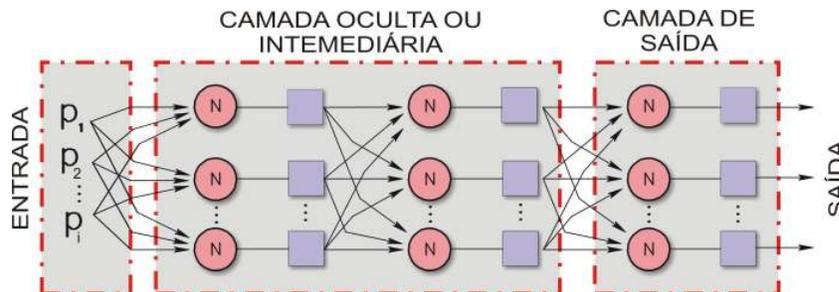


Figura 2.9 - Estrutura de uma Rede Neural Genérica.

Ainda não existe uma solução bem definida para a escolha do número de camadas, de neurônios e de conexões a serem criadas em uma rede neural, a fim de solucionar um determinado problema. Uma rede muito complexa pode causar o superajustamento (*overfitting*), em que, até mesmo pequenos ruídos nos dados podem ser identificados pela rede, prejudicando a qualidade dos resultados gerados a partir de novas amostras. Por outro lado, a simplicidade da rede pode não conseguir reproduzir o comportamento desejado (Figura 2.10).

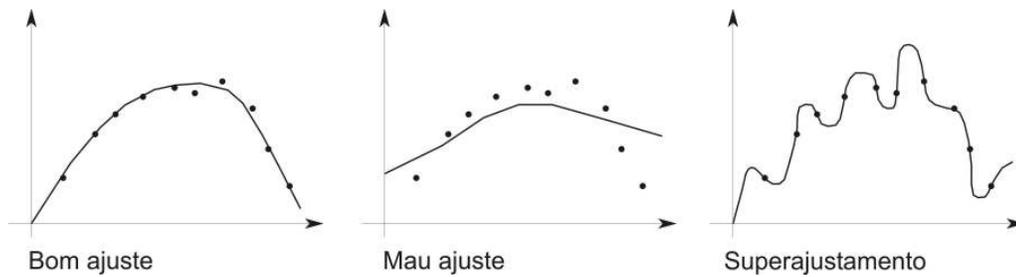


Figura 2.10 - Resultados de ajustamentos.

O teorema de Kolmogorov-Nielsen (1957) apud Kovacs (1996), mostra que sempre há uma implementação exata com uma rede neural de três camadas para representar uma função contínua, sendo a camada de entrada um vetor de dimensão n , a camada intermediária deve ter $(2n+1)$ neurônios e na camada de saída, m neurônios. Esse teorema resume a busca da arquitetura ótima para a rede neural, como sendo a busca do melhor número de neurônios para a camada intermediária, sendo que o acréscimo de camadas em nada melhoraria o resultado, ou seria uma melhora de pequena significância.

2.3.9 Validação Cruzada

O superajustamento pode também ser fruto da execução de um elevado número de iterações, pois os erros das respostas da rede para a amostra de treinamento sempre diminuem, enquanto que, para uma amostra inédita (ou seja, que não é utilizada no treinamento), este erro, a partir de um certo número de ciclos, tende a elevar-se. Esta perda de qualidade dos resultados da amostra de validação é causada pela capacidade da rede neural em reproduzir o ruído da banda aleatória da amostra de treinamento, que é distinta da amostra de validação.

A validação cruzada utiliza uma outra amostra, que não será usada no treinamento da rede, para executar uma avaliação do erro ao longo do treinamento. Para cada ajuste dos pesos dos neurônios é calculado o erro da saída da amostra de validação e, após a conclusão do treinamento, é criado um gráfico com os erros da amostra de treinamento e de validação. Estes erros são obtidos simultaneamente com o treinamento. A partir deste gráfico é possível identificar o número da iteração onde o mínimo para a amostra de validação foi atingido, e então os pesos sinápticos desta iteração são os eleitos para a rede (Figura 2.11).



Figura 2.11 - Função do Erro Quadrático da amostra de Treinamento e de Validação.

2.3.10 Mínimos Locais

Existem algumas estratégias para evitar que a convergência pare em algum ponto de mínimo local da superfície da função do erro quadrático. Uma estratégia é fazer vários treinamentos com pontos de partidas distintos, para que o caminhamento seja feito com trajetórias diferentes, permitindo assim cair em mínimos locais diferentes, e então, escolher qual foi o treinamento que obteve um hipotético mínimo global.

A tentativa que apresentar o menor erro será então adotada como o mínimo global. Outra estratégia seria a de acrescentar um ruído aos pesos sinápticos, fazendo com que eles saltem para além do limite de atração deste mínimo local, encontrando assim uma nova trajetória em direção a outro ponto de mínimo da função (Kovacs,1996).

2.3.11 Aplicações Usando Redes Neurais em Recursos Hídricos

As redes neurais artificiais, como fora dito anteriormente, têm ampliado cada vez mais sua área de utilização. Na área de recursos hídricos, o uso principal é para previsão. Sem a pretensão de apresentar uma revisão exaustiva da aplicação de redes neurais artificiais na área de recursos hídricos, foram selecionados alguns trabalhos que constituem uma pequena amostra dos resultados obtidos com esta técnica no âmbito brasileiro e mundial.

Dawson e Wilby (2001) apontam a modelagem por redes neurais como uma alternativa viável à modelagem hidrológica tradicional, apresentando uma descrição objetiva das principais etapas da modelagem por redes neurais artificiais. Os autores citam, ainda, alguns cuidados com a técnica, que devem ser levados em conta, tais como a subjetividade na definição da arquitetura da rede neural e a escolha dos dados de entrada. Estas ressalvas dizem respeito à aplicação da técnica para a modelagem de processos chuva-vazão e para a previsão de níveis fluviais, as quais, por sua vez, incentivam o refinamento da técnica para a obtenção de melhores resultados.

Na bacia do rio Jaguaribe (Ceará), foi comparado um modelo em redes neurais ao modelo conceitual MODHAC. Como dados de entrada, foram utilizadas as chuvas mensais de até dois meses anteriores, para prever as vazões nos postos Iço, Podimirim e Iguatu. A rede neural que obteve melhor resposta utilizou 8 neurônios na camada intermediária, com função sigmóide para esta camada, e linear para a camada de saída. A série de 24 anos de dados mensais foi dividida de forma que a amostra de treinamento ficasse com 7 anos, e a de validação, 11 anos. Concluiu-se que a utilização de redes neurais é promissora e adequada, uma vez que, neste caso, mostrou resultados melhores do que a modelagem conceitual (Lima, 2003).

No Canadá, na bacia do Red River, uma rede neural foi testada para prever a vazão de pico, o tempo de pico, a vazão de base, os tempos de subida e descida do hidrograma e as larguras do hidrograma para 50% e 75% da vazão de pico. Como entradas, foram utilizados cinco parâmetros: a precipitação acumulada na primavera, a acumulada no inverno, um fator de tempo e um índice de fusão do gelo. Os resultados não foram melhores do que os do modelo conceitual, pois a região é densamente monitorada e a incerteza nas informações é muito pequena. Entretanto, o autor recomenda o uso em bacias com poucas e incertas informações (Sajjad e Slobodan, 2005).

Um modelo de propagação de vazões por redes neurais foi testado na bacia do rio Iguazu. As entradas foram as vazões a montante de Fluviópolis e no afluente Timbó, a saída foi a vazão em União da Vitória, 104 km a jusante. A área de drenagem é de 24.200 km² e a declividade média é de 0,1%. A rede neural foi estruturada em 3 camadas intermediárias com 8 neurônios cada, com funções de ativação sigmóides. A técnica de treinamento utilizada foi a retropropagação do erro (*backpropagation*). O modelo foi treinado para previsão de eventos com uma amostra de 7 eventos. Foram separados para treinamento 4 eventos e os outros 3 foram usados na verificação. O resultado demonstrado ficou com erros médios relativos de vazão na faixa de 3 a 8%, o que, segundo o autor, não desabona totalmente o modelo (Muller e Fill, 2003).

Em um trabalho de modelagem com redes neurais, foram utilizadas as precipitações de meses anteriores e do mês para o qual se deseja obter a previsão de vazão mensal. Para o posto Cajazeiras, no estado do Ceará, o arranjo de dados de entrada que apresentou a melhor estatística utilizou as chuvas do mês em consideração, dos dois meses anteriores, e a vazão do mês anterior. Porém, o melhor arranjo para prever o volume total escoado não usava o parâmetro de vazão anterior. Os autores não observaram uma grande influência da variação do número de neurônios na camada intermediária sobre a exatidão das respostas, sendo que o melhor modelo teve 3 neurônios em sua camada intermediária. Já sobre o particionamento da amostra, foi evidente a importância de uma escolha correta dos tamanhos da amostra de treinamento e de validação, sendo que o melhor particionamento está próximo de 50% para cada uma das etapas (Ferreira e Lima, 2003).

No caso de previsão do nível para o Rio Santa Maria em dois pontos, foi utilizado um modelo em rede neural para fazer a previsão com alcances de 10 e 24 h. Os parâmetros de entrada são a chuva em 5 postos dentro da bacia de 12.077 km². A amostra de treinamento foi composta por 9 anos de dados diários, e a de validação por 3 anos. Foram testadas redes com 2 e 3 neurônios na camada intermediária. O número de iterações ótimo foi buscado com a interrupção do treinamento, em diversos momentos, e armazenamento dos pesos resultantes e

estatísticas para análise posterior, sendo que para este caso o número de iterações ideais foi próximo de 1000. Os resultados foram analisados através de uma estatística não-convencional, onde se obteve os valores de erros que não ultrapassavam patamares de frequência estabelecidos, o que gera uma forma mais intuitiva de analisar a qualidade dos resultados de previsão (Pedrollo, 2005).

Os exemplos citados mostram a utilização dos modelos em redes neurais em diversos problemas de previsão, com resultados satisfatórios. Porém, de forma geral a maioria dos trabalhos citados não apresentam, ou não evidenciam, as dificuldades e dilemas na utilização da técnica de redes neurais artificiais, tais como a escolha da arquitetura, análise dos índices de qualidade do treinamento, particionamento da amostra e convergência do treinamento para mínimos locais. Estas carências foram estímulos para a idealização desta pesquisa, que pretende investigar metodologias que contornem as dificuldades na utilização da técnica.

2.4 Regressão Linear Multivariada

Modelos empíricos são freqüentemente utilizados para a previsão de vazões com entrada de precipitação. Sua formulação não considera características físicas do processo de transformação chuva-vazão, e permite obter bons resultado para bacias pequenas, que têm, conseqüentemente, rápida resposta aos eventos de chuva (Tucci,1998). Dentre os modelos empíricos, um dos mais utilizados é o modelo de regressão, que pode ser classificado em simples ou multivariado, em função do número de variáveis independentes que são envolvidas na modelagem. Outra classificação é a dependência da variação do resultado do modelo em função das variáveis independentes, que pode ser linear ou não-linear.

A utilização de modelos de regressão requer um conhecimento, ou uma verificação, do grau de correlação entre as variáveis de entrada e saída desejadas a constituir o modelo, além de critérios de parcimônia para evitar modelos com complexidade muito maior que a necessária para representar o processo.

Nesta pesquisa foi utilizada apenas a regressão linear multivariada, pois sua utilização não tem o caráter comparativo-competitivo, e sim, como um balizador do grau de qualidade do resultado que é obtido com esta ferramenta matemática.

Forma do modelo de regressão linear multivariada:

$$Y = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2 + \dots + a_n \cdot x_n + \varepsilon$$

Subtraindo o erro “ ε ” do valor observado, “Y”, obteremos o valor de saída do modelo, “ \hat{Y} ”:

$$\hat{Y} = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2 + \dots + a_n \cdot x_n$$

O ajuste de modelo de regressão é a obtenção de valores para os parâmetros “ a_i ” que promovam o menor valor para a soma dos resíduos, $(\sum(Y - \epsilon))$, gerados com a amostra de calibração.

Para estimar os valores dos parâmetros do modelo é utilizado o método de “Mínimos Quadrados”, desenvolvido independentemente, salvo alguma controvérsia, por Carl Friedrich Gauss e Adrien Marie Legendre no início do século XIX (Draper e Smith, 1981).

Utilizando uma notação matricial, o método de “Mínimos Quadrados” é expresso pelo seguinte equacionamento:

$$a = (x^T x)^{-1} x^T Y$$

A partir da década de 1980, com o advento da computação, as rotinas de cálculo passaram a ser um pouco diferentes do demonstrado, pois mesmo utilizando precisão dupla ao manipular os dados computacionalmente, ocorrem erros de precisão significativos. Uma alternativa, utilizada pelo programa MATLAB, é através de uma fatorização ortogonal triangular para matrizes esparsas (Demuth e Beale, 2004).

A modelagem por regressão exige um conhecimento (experiência) prévio da relação entre as variáveis de entrada e saída. Especialmente nas regressões multivariadas, estas relações são de difícil identificação, exigindo uma série de experimentações e testes em busca da forma da equação de regressão que represente com mais exatidão o fenômeno modelado.

Definida a forma da equação de regressão a ser utilizada, e com os coeficientes ajustados, a utilização do modelo resulta resíduos que seguem, geralmente, a distribuição normal e, a partir desta hipótese, a qualidade do modelo é medida através da variância dos resíduos, muitas vezes representadas por intervalos de confiança que indicam a magnitude da dispersão para certos níveis de significância.

3. Área de Estudo e Dados Disponíveis

3.1 Área de Estudo

3.1.1 Bacia do Rio Quaraí

A escolha da bacia para o estudo de caso foi tomada em virtude das suas características físicas, da facilidade de obtenção dos dados hidrológicos e do efetivo problema de inundações ribeirinhas observado nas cidades de Quaraí e Artigas.

O rio Quaraí é um afluente pela margem esquerda do rio Uruguai, integrando a Bacia do Rio da Prata. A bacia do Quaraí possui uma área de drenagem de cerca de 14.800 km², dos quais aproximadamente 6.700 km² (45%) em território brasileiro e cerca de 8.100 km² (55%) no extremo noroeste do Uruguai. Esta é uma bacia transfronteiriça de águas compartilhadas entre o Brasil e o Uruguai, sendo a fronteira entre os países o curso principal do rio Quaraí (Figura 3.1) (PPGICBRQ, 2005).



Figura 3.1 – Vista aérea do rio Quaraí e as cidades de Quaraí e Artigas.

O comprimento total da calha principal de drenagem é de 351 km, a diferença das cotas altimétricas, da nascente até o exutório, é de 326 m, e a altitude média da bacia é de 200 m.

Situada entre os meridianos 55°35'W e 57°40'W e os paralelos 29°40'S e 30°55'S, a bacia apresenta, segundo o Sistema Universal de Classificação Climática de Köppen, um Clima Temperado Úmido, na variedade de Clima Subtropical ou Virginiano do tipo "Cfa". Em virtude da sua continentalidade e, também, da presença de substrato rochoso próximo à superfície, além de escassa cobertura vegetal, a área apresenta grande amplitude térmica

diária (no mês mais frio as temperaturas oscilam entre 3°C e 18°C e, no mês mais quente, superam a 22°C), e anual, com temperatura média de 19,7°C, e máximas acima de 30°C no verão (PPGICBRQ, 2005).

3.1.2 A Bacia a Montante das Cidades de Quaraí e Artigas

A região de interesse é a Sub-bacia do Rio Quaraí, a montante das cidades fronteiriças Artigas (Uy) e Quaraí (Br), na coordenada geográfica 30°23'S e 56°30'W (Figura 3.2).

A área de drenagem superficial desta sub-bacia é de aproximadamente 4.500 km². Nesta área, a declividade dos cursos d'água apresenta valores maiores que os da média para toda bacia (0,93 m/km ou 0,093%), devido à sua localização junto às nascentes mais altas do Rio Quaraí (PPGICBRQ, 2005).

O solo da região possui composição variada, mas em geral tem embasamento basáltico, com vários locais de afloramento de rocha. A espessura da camada de solo é fina (cerca de 0,50 m), propiciando uma baixa capacidade de armazenamento e, juntamente com a declividade mais acentuada desta região, resulta um coeficiente de escoamento médio anual da ordem de 0,46, bem como uma vazão de base quase nula (PPGICBRQ, 2005).

Uma característica importante da bacia, que merece destaque para a elaboração de um modelo de previsão de nível, é sua rápida resposta, apresentando tempo de concentração de 28h e o tempo observado entre o pico de chuva e o pico de vazão entre 12 e 15 h, na seção entre Quaraí e Artigas.

A precipitação média anual varia entre 1.300 mm e 1.500 mm. A evapotranspiração potencial anual é de cerca de 1.600 mm. A região apresenta uma variabilidade mensal de precipitação de 80%, e anual de 30% (PPGICBRQ, 2005).



Figura 3.2 - Localização da Bacia do Rio Quaraí e a sub-bacia em estudo.

3.1.3 Inundações no trecho próximo às cidades de Artigas e Quaraí

As cidades de Artigas e Quaraí se diferenciam em suas populações, tendo, respectivamente, 42 mil habitantes e 25 mil habitantes. Ambas as cidades são atingidas pelas enchentes do rio Quaraí; aproximadamente 10 mil habitantes do lado uruguaio (Artigas) são atingidos, e no lado brasileiro (Quaraí) 1,2 mil.

A ocupação das zonas inundáveis está associada ao nível sócio-econômico da população local que, por falta de opções de locais de moradia e de informação dos riscos envolvidos em ocupar estes locais, assenta-se nestas zonas desde a década de 1980 (PPGICBRQ, 2005).

A análise de freqüências das inundações indica que, em 80% dos picos de vazão, durante os eventos de cheia, a população não é atingida (PPGICBRQ, 2005).

A bacia escoia 90% do volume total anual em 30% do tempo, caracterizando um regime de variação de nível muito amplo (PPGICBRQ, 2005).

A cota para que o rio extravase a sua calha principal, atingindo a planície de inundação, é de 6,80 m e, para que atinja zonas habitadas, é de 8,36 m, referenciados pela régua da DNH (Dirección Nacional de Hidrografia del Uruguay), estação OSE-DNH 84.0 (Figura 3.3). Na Tabela 3.1 estão os valores de cota máxima para vários tempos de retorno na seção do rio Quaraí, entre as cidades de Quaraí e Artigas (PPGICBRQ, 2005).

Tabela 3.1 - Tempo de retorno, vazão máxima e cota, na seção Quaraí/Artigas (PPGICBRQ, 2005).

Tr	Qmax	h
(anos)	(m ³ /s)	(m)
2	1458	9,02
5	2377	10,68
10	3112	11,73
20	3929	12,73
30	4455	13,305
50	5178	14,03
100	6280	15,02

A remoção da população atingida é realizada durante a inundação, causando maiores prejuízos e dificuldades para o auxílio da Defesa Civil aos atingidos do que se houvesse uma previsão de inundação confiável e com antecedência suficiente.

Em função do pequeno tempo entre picos e as demais características observadas na bacia, tais como o alto coeficiente de escoamento, a previsão de nível com base somente em níveis a montante de Artigas e Quaraí não permite uma antecedência adequada.

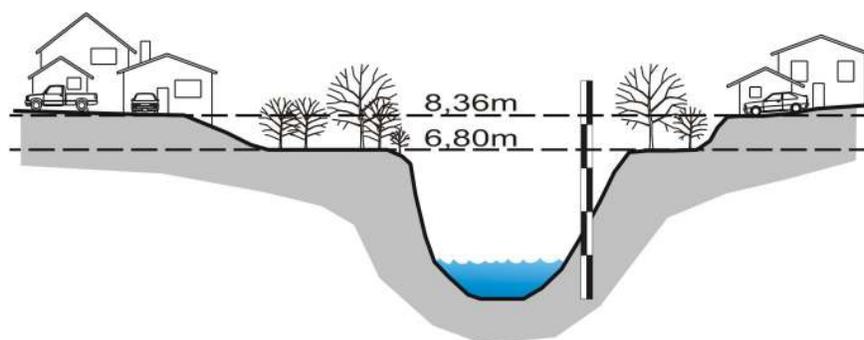


Figura 3.3 - Seção do Rio Quaraí e as cotas para extravasar a calha principal e para atingir a população

Atualmente, as cidades de Artigas e Quaraí não possuem sistema de alerta de cheias, porém, em trabalho realizado pela DNH foi criado um modelo de previsão que é alimentado com dados de precipitação observada na rede telemétrica e a cada hora durante a ocorrência do evento, para prever o nível máximo ao final do evento. A previsão por evento tem o inconveniente de não prever o início do evento, necessitando uma vigilância constante das condições meteorológicas que possam causar um evento com magnitude suficiente para provocar uma inundação prejudicial.

3.2 Dados Disponíveis

3.2.1 Dados Hidrológicos Observados

Os dados observados na bacia são registrados pela rede telemétrica monitorada pela DNH e CTM (Comision Técnico Mixta de Salto Grande – Uruguay), formada por três pluviógrafos e um linígrafo, este situado no local desejado de previsão de nível, ou seja, na ponte entre as cidades de Quaraí e Artigas (Figura 3.4, Tabela 3.2).

Tabela 3.2 - Localização dos postos de monitoramento telemétrico

Código	Nome	Entidade Responsável	Longitude decimal	Latitude decimal	Altitude (m)
1600	Artigas	CTM	56,5°	30,35°	116
2800	Catalán Grande	CTM	56,25°	30,78°	180
2900	Sarandi de Arapey	CTM	56,2°	30,98°	250

Os dados da rede telemétrica foram obtidos por acesso restrito ao endereço eletrônico da CTM, que gerencia a operação da hidrelétrica de Salto Grande (Uruguay), e correspondem ao período entre 01.05.2005 a 01.05.2007.

A precipitação diária observada na bacia foi calculada com a média ponderada por polígonos de Thiesen do acumulado de cada posto pluviométrico. As proporções de composição para cada posto são: Artigas, 18%; Catalán Grande, 57%; e Sarandi de Arapey, 25%.

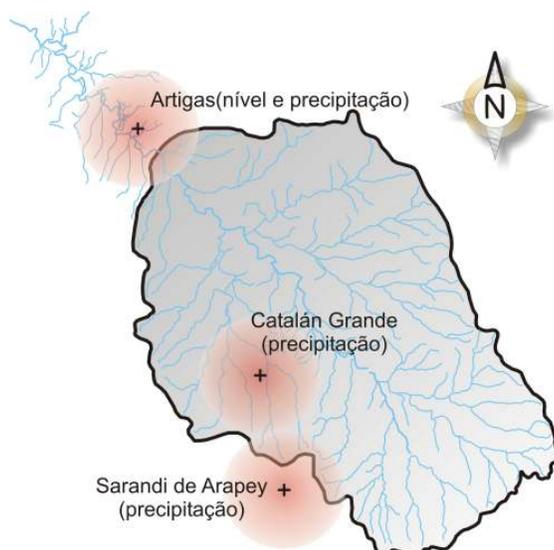


Figura 3.4 - Postos da rede telemétrica do DNH (Uruguai).

Na área brasileira da bacia existem dois postos pluviométricos, o posto Caty e o posto Fazenda Encerra, localizados, respectivamente, nas coordenadas (56,18°W; 30,52°S) e (55,75°W; 30,72°S), monitorados pela CPRM-ANA(Companhia de Pesquisa de Recursos Minerais – Agência Nacional de Águas). Estes postos utilizam pluviômetros e não estão conectados à rede telemétrica, impossibilitando o uso dos seus dados pelo sistema de alerta de cheia.

3.2.2 Dados de Previsão Meteorológica

Os dados de previsão de precipitação foram obtidos junto ao CPTEC/INPE, que fornece diariamente o resultado do modelo ETA para dois horários, 0 h e 12 h. O resultado é uma previsão numérica pontual para as intersecções de uma malha de 40 x 40 km. O domínio dos dados do modelo, utilizado neste trabalho, cobre a região compreendida entre as longitudes de 44°W a 69°W e as latitudes de 19°S a 44,2°S.

A chuva prevista foi obtida por média ponderada a partir das áreas dos polígonos de Thiessen, dos 4 pontos da malha de previsão do modelo ETA, que estão dentro, ou mais próximos, do limite da bacia (Figura 3.5, Tabela 3.3).

Tabela 3.3 - Coordenadas dos pontos de previsão hidrometeorológica.

Longitude decimal	Latitude decimal	%	Área (km ²)
56,2°	30,6°	52	2321,11
55,8°	30,6°	15	680,16
56,2°	31°	14	627,08
55,8°	31°	19	827,275

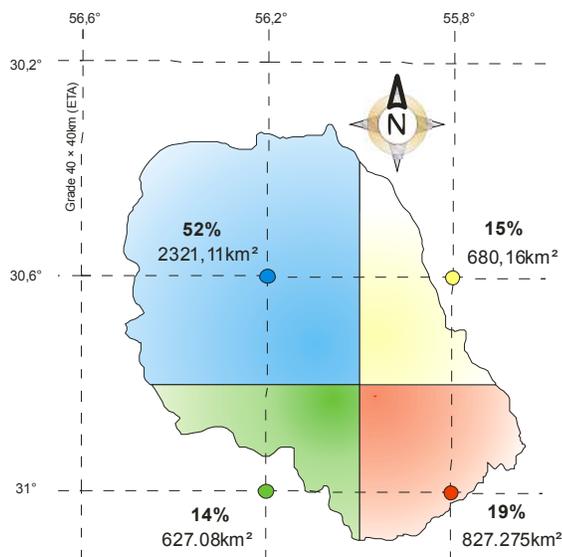


Figura 3.5 - Polígonos de Thiesen para os pontos de previsão hidrometeorológica na bacia do Quaraí.

Os dados de previsão foram transformados em chuva diária somando-se as previsões parciais de 6h do dia correspondente. O início da coleta de dados de previsão de chuva foi em 05.01.2005, e o término em 05.01.2007.

4. Metodologia

A metodologia está dividida em 4 itens, começando pela apresentação das técnicas utilizadas na avaliação do grau de qualidade das previsões de precipitação, que é uma das entradas do modelo de redes neurais para previsão do nível d'água apresentado no segundo item, que explicita o método de eleição da arquitetura de rede neural e os demais recursos utilizados.

No terceiro item é apresentado o modelo de redes neurais sem a entrada de previsão de precipitação e, por fim, o último item refere-se ao modelo de regressão linear multivariada.

Para fins de auxílio durante a leitura da descrição metodológica, são apresentadas na Figura 4.1, em forma de fluxograma, as etapas realizadas nesta pesquisa. A numeração das etiquetas corresponde aos itens numerados do índice geral.

4.1 Análise da Qualidade da Previsão Hidrometeorológica do modelo ETA

Modelos de previsão de nível, que têm como entrada a previsão hidrometeorológica, podem ser prejudicados pela baixa qualidade desta entrada, fazendo assim necessária uma avaliação deste dado, para avaliar o grau de concordância com os dados de precipitação reais (observados).

4.1.1 Sincronização dos Dados

A chuva prevista pelo modelo ETA é disponibilizada no horário internacional (UTC), e a precipitação observada é registrada pelo horário local (horário oficial de Brasília com 3 horas a menos).

A discretização da previsão de precipitação é de 6 h. Como a chuva observada é registrada em intervalos de tempo menores, optou-se por corrigir a hora dos dados observados. Efetivamente, nenhuma modificação nos registros foi realizada, apenas admitiu-se que o dia para os dados observados inicia às 21 h do dia anterior e encerra às 21 h do dia atual.

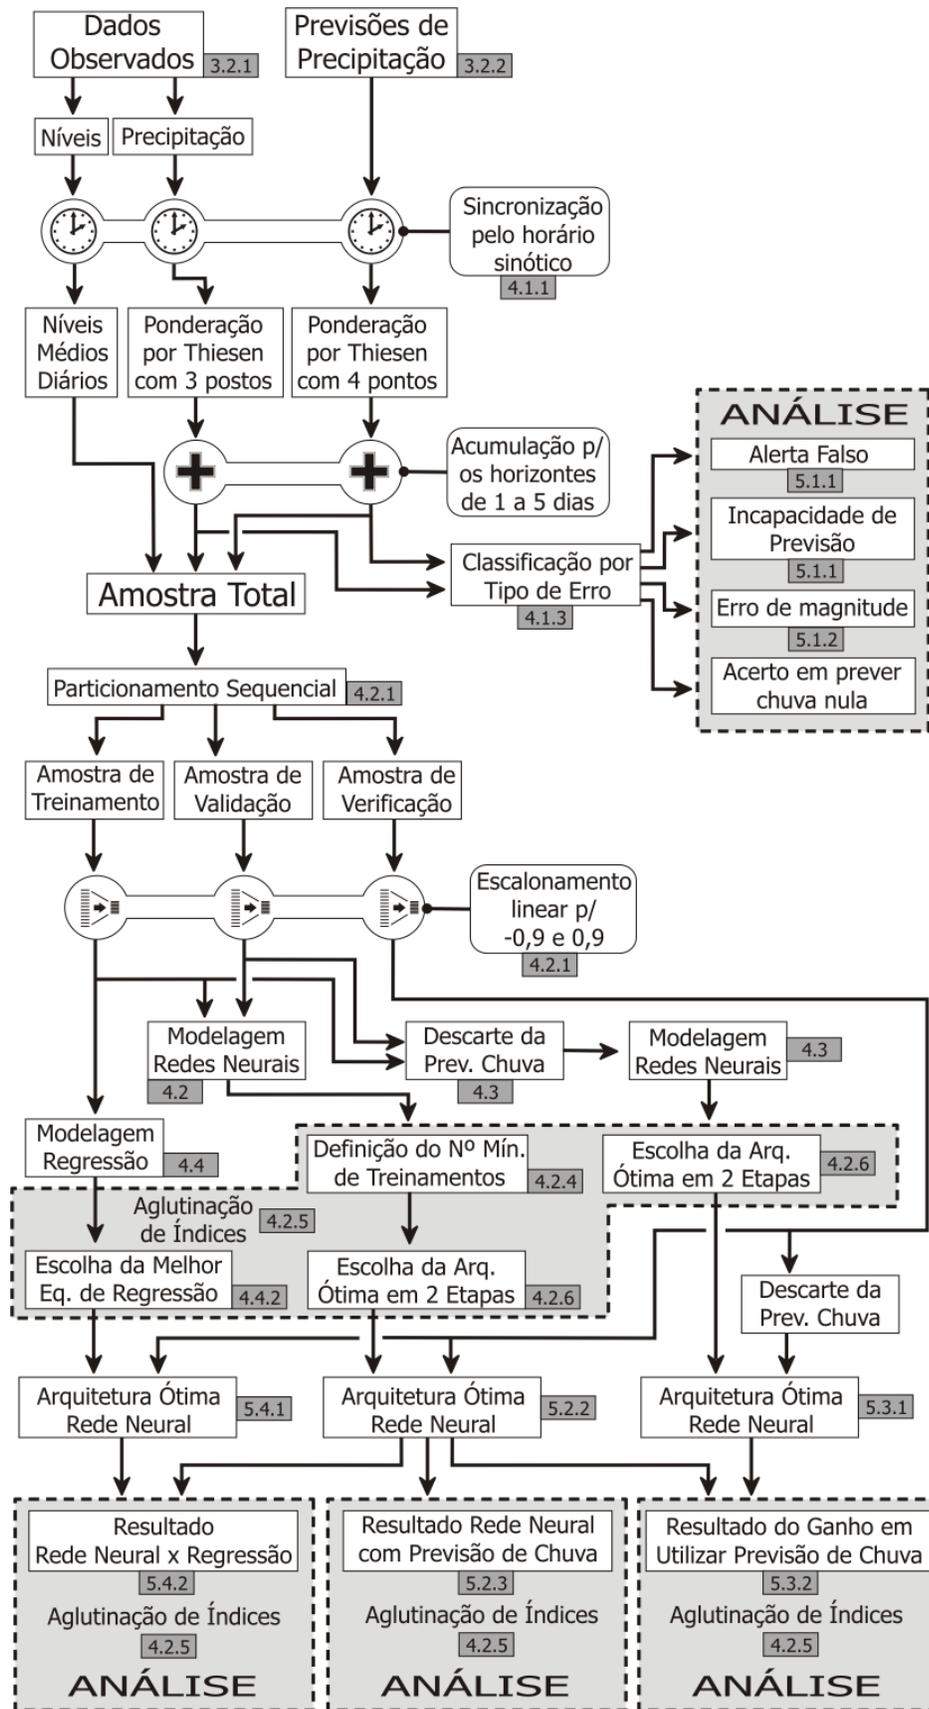


Figura 4.1 – Fluxograma de etapas

4.1.2 Índices para Análise da Qualidade da Previsão Hidrometeorológica

A avaliação da qualidade dos resultados de um modelo, para ser mais explicativa, deve utilizar mais de um índice, pois cada um deles tem sua característica própria e avalia o resultado apenas sob uma ótica. A seguir são apresentados os índices utilizados na avaliação do modelo de previsão de precipitação, e uma breve descrição do seu significado:

Volume total

$$V_o = \sum P_o \text{ (volume total observado), } V_c = \sum P_c \text{ (volume total previsto)}$$

Com o volume total dos valores de chuva previstos e da chuva observada é possível avaliar o grau de superestimação ou subestimação que o modelo de previsão ETA apresentou ao longo do período disponível de dados.

Onde:

P_c = precipitação prevista (modelo ETA) P_o = precipitação observada

Erro Médio Quadrático Absoluto

$$EMQ = \frac{\sum (P_c - P_o)^2}{n}$$

Onde:

n = número de amostras

Este índice penaliza quadraticamente os erros, fazendo com que os erros de maior magnitude influenciem mais significativamente na sua elevação. Assim, com este índice, a variabilidade do erro pode ser identificada e comparada entre os resultados.

Erro Médio Absoluto

$$EMA = \frac{\sum |P_c - P_o|}{n}$$

Este índice mostra de modo mais plausível o erro, porém não representa o grau de variabilidade dos erros.

Erro Padrão Absoluto

$$EPA = \sqrt{\frac{\sum (P_c - P_o)^2}{n}}$$

Supondo-se que a distribuição de frequências dos erros seja normal, este índice mostra o grau de dispersão dos erros em relação ao EMA, tendo a mesma unidade do valor da variável avaliada.

Coefficiente de Correlação Linear ou de Pearson

$$R = \frac{\sum (P_o - \bar{P}_o) \cdot (P_c - \bar{P}_c)}{\sqrt{\sum (P_o - \bar{P}_o)^2 \cdot \sum (P_c - \bar{P}_c)^2}}$$

Este coeficiente indica o grau de associação linear entre duas variáveis aleatórias, sendo o valor 1 o indicador de máxima associação direta, 0 o mínimo e -1 a máxima associação inversa. O coeficiente de correlação é utilizado tanto para relações lineares, quanto não-lineares, e mede a qualidade do ajustamento dos dados das equações realmente consideradas. O quadrado deste índice é o coeficiente de determinação (R²), que indica a proporção da variação total da variável independente que é explicada pelo modelo. Casos com coeficiente alto (próximo a 1), onde não existe uma relação evidente de causa e efeito, é chamada de correlação disparatada ou espúria (SPIEGEL, 1970).

4.1.3 Resíduos da Previsão Hidrometeorológica

Na Figura 4.2 são apresentados, em forma de fluxograma, as possibilidades de erro e acerto da previsão hidrometeorológica, e as situações que geram resíduos. O resíduo é definido como o módulo da diferença entre a chuva prevista e a chuva observada, sendo que o caso que nunca gera resíduo é quando a previsão e a observação são nulas, ou ainda, em casos muito raros quando ambas não são nulas, mas têm o mesmo valor.

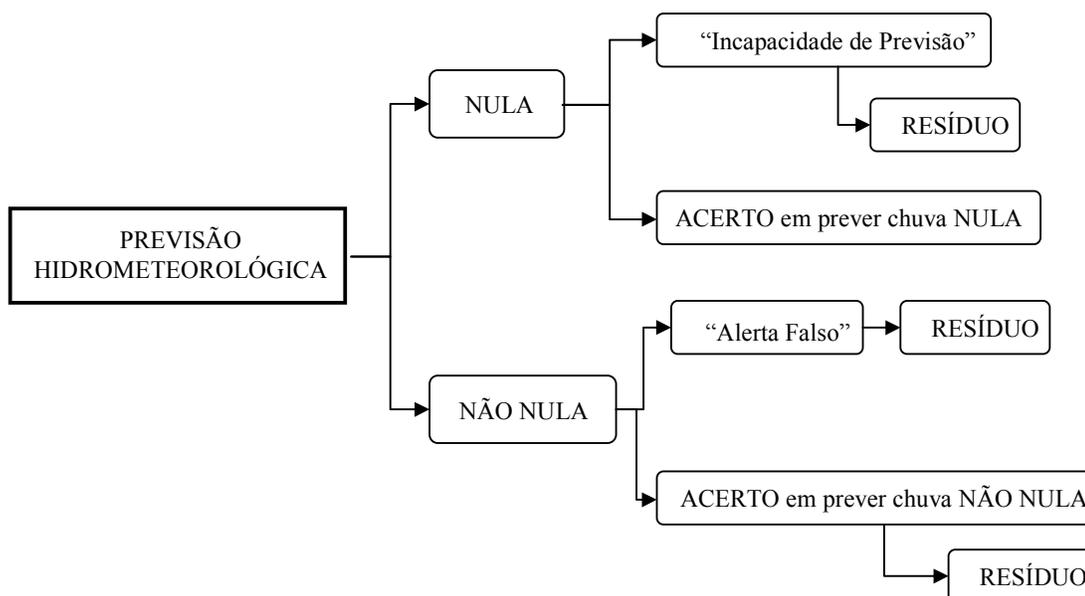


Figura 4.2 – Fluxograma de possibilidades de erros na previsão hidrometeorológica.

A divisão dos tipos de erros possíveis é fundamental para a correta avaliação da qualidade do modelo, pois, assim, é eliminada a influência dos demais tipos de erros nos índices de qualidade do tipo de erro em análise.

4.2 Modelo de Redes Neurais com uso de Previsão de Precipitação

Neste item estão expostas as técnicas utilizadas na modelagem por redes neurais, destacando-se o particionamento das amostras, o escalonamento, a aglutinação dos índices de qualidade, a definição do número mínimo de repetições do treinamento, a eleição da arquitetura ótima, as funções de ativação e os algoritmos de treinamento.

4.2.1 Amostras de Dados para a Rede Neural

As amostras para a aplicação da rede neural são constituídas de 3 atributos de entrada e 1 de saída.

As amostras estão arranjadas em 4 colunas, sendo cada linha uma amostra da situação, com previsão de chuva acumulada até o dia do horizonte de previsão, níveis observados nos 2 dias anteriores ao dia de previsão e os níveis observados nos dias do horizonte de previsão (Tabela 4.1). Assim, foram organizados 5 conjuntos de amostras, uma para cada horizonte de previsão, pois as previsões de precipitação não são fixas, e vão sendo atualizadas conforme o dia do horizonte de previsão se aproxima.

Tabela 4.1 – Amostra para treinamento da rede neural

Entradas			Saídas
Nível anteontem	Nível ontem	Previsão de chuva acumulada do 1º dia até um dia antes do horizonte de previsão	Nível no dia do horizonte de previsão
N_{i-2}	N_{i-1}	$\sum_i^{i+H-1} P_i$	N_{i+H-1}

O particionamento normalmente utilizado, que divide a amostra em percentis contínuos, ocasiona alguns problemas, conforme Lachtermacher e Fuller (1994) apud Dawson e Wilby (2001). Quando a amostra é excessivamente pequena, é impossível que as 3 amostras sejam independentes, então o método de divisão causa efeito significativo nos resultados, e mesmo a utilização da validação cruzada não garante que a rede neural tenha adquirido somente o aprendizado desejado, podendo o treinamento ter sido influenciado, também, pelo ruído intrínseco da amostra.

Nesta pesquisa, os 5 conjuntos de amostras (um para cada horizonte de previsão e com 1043 registros) foram divididos em grupos amostrais de treinamento, de validação e de verificação. A divisão foi realizada, extraíndo-se sucessivamente, de cada grupo de 4 amostras, em ordem cronológica, duas para treinamento, uma para validação e uma para verificação, ficando o grupo de amostras para treinamento com 50%, o de validação com 25% e o de verificação, também com 25% do total (Figura 4.3).

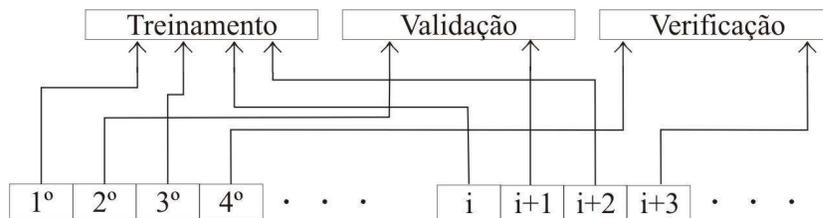


Figura 4.3 – Particionamento seqüencial das amostras

A divisão intercalada tem por objetivo criar amostras mais significativas (com índices estatísticos mais semelhantes aos dos demais grupos amostrais) que as por divisão tradicional, na qual a divisão é feita separando-se os grupos das amostras em ordem cronológica contínua. A divisão intercalada pode ser importante, devido à pequena quantidade de dados. A amostra de validação, embora corresponda praticamente às mesmas situações da amostra de treinamento, tem modificadas as componentes aleatórias específicas, o que permite a filtragem destas componentes pelo processo.

Nas Tabelas 4.2 e 4.3 são apresentadas as médias extraídas dos grupos resultantes do particionamento seqüencial, verificando-se a homogeneidade entre os grupos, e conseqüentes representatividades.

Tabela 4.2 – Médias das variáveis de entrada para os 3 grupos.

	Nível anteontem (m)	Nível ontem (m)	Prev. chuva 1º dia (mm)	Prev. chuva 2º dia (mm)	Prev. chuva 3º dia (mm)	Prev. chuva 4º dia (mm)	Prev. chuva 5º dia (mm)
	$N_{(i-2)}$	$N_{(i-1)}$	$P_{(i)}$	$P_{(i+1)}$	$P_{(i+2)}$	$P_{(i+3)}$	$P_{(i+4)}$
Treinamento	2,253	2,241	2,478	2,807	3,399	4,240	3,417
Validação	2,259	2,212	2,954	2.335	3,799	3,961	4,040
Verificação	2,234	2,259	2,195	3.003	3,431	4,543	2,797

Tabela 4.3 – Médias das variáveis de saída para os 3 grupos.

	Nível 1º dia (m)	Nível 2º dia (m)	Nível 3º dia (m)	Nível 4º dia (m)	Nível 5º dia (m)
	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	$N_{(i+5)}$
Treinamento	2,229	2,216	2,206	2,205	2,206
Validação	2,236	2,194	2,203	2,189	2,218
Verificação	2,214	2,232	2,198	2,218	2,189

As falhas contidas nos registros dos dados fazem com que cada horizonte de previsão tenha um conjunto de dados diferente dos demais, pois, ao ocorrer uma falha nos dados de previsão de chuva, cada horizonte de previsão perderá um registro de nível distinto.

Após o particionamento das amostras realizou-se o escalonamento, que teve como limites -0,90 (inferior) e 0,90 (superior).

A seguinte equação foi utilizada para o escalonamento dos dados de entrada:

$$D_E = \left[\frac{1,8}{\max(D) - \min(D)} \cdot (D_i - \min(D)) \right] - 0,9$$

Onde:

D_E = dado escalonado

D_i = dado a ser escalonado

D = série total de dados não escalonada

4.2.2 Índices para Análise da Qualidade do Modelo de Previsão de Nível

Os índices para a análise dos resultados do modelo de previsão de nível foram os mesmos utilizados na análise da qualidade da previsão hidrometeorológica, com o acréscimo do coeficiente de persistência (CP) e do erro não ultrapassado para as frequências determinadas.

Coeficiente de Eficiência (CE - Nash Sutcliffe) e Coeficiente de Persistência (CP)

$$CE = 1 - \frac{\sum (Po_i - Pc_i)^2}{\sum (Po_i - \overline{Po})^2} \quad CP = 1 - \frac{\sum (Po_i - Pc_i)^2}{\sum (Po_i - Po_{i-1})^2}$$

O coeficiente de eficiência, originalmente, compara a vantagem da utilização do modelo proposto em relação a um modelo de previsão que prevê sempre o valor médio observado. Porém, na pior das hipóteses, prever o último nível observado seria um modelo mais eficiente para realizar uma comparação com o modelo proposto, então o índice foi modificado para ser utilizado o último registro de nível como modelo alternativo de previsão, ao invés do nível médio observado (Kitanidis e Bras, 1980).

O coeficiente de persistência varia de $-\infty$ a 1, onde para valores negativos o modelo proposto é pior que o modelo de prever a repetição do último nível observado, para $CP = 0$ os dois modelos são equivalentes e para valores positivos do CP, o modelo proposto é tanto melhor quanto mais próximo de 1 for este valor (Tabela 4.4).

Tabela 4.4 – Interpretações para o índice CP.

Valor de CP	Interpretação do Índice
$CP < 0$	O modelo proposto é pior que o modelo que prevê o último valor observado
$CP = 0$	Os dois modelos são equivalentes
$0 < CP \leq 1$	O modelo proposto é melhor que o modelo que prevê o último valor observado

Erro Não ultrapassado para determinada Frequência

A utilização de um valor de erro que não é superado em um percentual das vezes que o modelo faz a previsão pode ser mais significativo que os índices das estatísticas tradicionais, baseadas na média e na variação em torno da média (Pedrollo, 2005). Além disso, constitui-se, ao contrário dos demais, em uma estatística absoluta de qualidade do modelo, cuja interpretação independe de comparações, por representar diretamente uma grandeza mensurável.

Foram adotados 3 valores de frequência para analisar o erro, 50% 75% e 90%. A escolha destes valores permite saber como é o incremento (formato da curva) no erro para as frequências acima de 50%.

Este índice dá uma noção mais plausível da qualidade da previsão, pois indica a magnitude do erro associado à frequência, que tem um significado imediato, direto, para o tomador de decisão.

4.2.3 Recursos Utilizados

As aplicações com redes neurais, nesta pesquisa, foram efetuadas com uso do programa computacional MatLAB v5.3, disponibilizado pelo PPGIPH/UFRGS, portanto a nomenclatura adotada para os recursos (funções de ativação e algoritmos de treinamento) foi a mesma utilizada pelo programa, e podem ser consultados no manual da *toolbox*.

As funções de ativação utilizadas na camada intermediária foram a TANSIG (Figura 4.4) e a SATLINS (Figura 4.5). A escolha destas funções de ativação teve o objetivo de permitir uma maior maleabilidade para a rede, pois são funções que admitem valores negativos e positivos em sua saída. Na primeira etapa de escolha da melhor arquitetura para a rede neural, foram comparadas e verificadas as vantagens do uso de funções sigmóides em relação às lineares.

TANSIG:

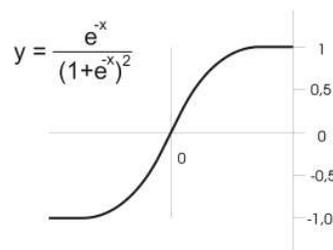


Figura 4.4 – Função de ativação Sigmóide TANSIG.

SATLINS:

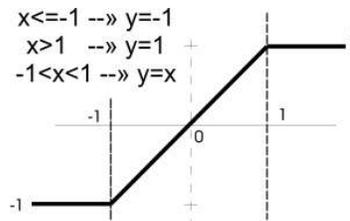


Figura 4.5 – Função de ativação Linear SATLINS.

Na camada de saída da rede neural foi utilizada, invariavelmente, a função linear ilimitada superiormente e limitada em zero inferiormente, a POSLIN (Figura 4.6). Esta escolha impede que a saída apresente valores negativos para o nível do rio e, também, permite respostas superiores às apresentadas à rede pela amostra de treinamento.

POSLIN:

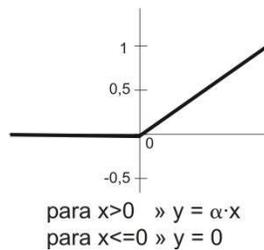


Figura 4.6 – Função de ativação Linear POSLIN.

Em geral, os algoritmos de treinamento são sofisticções do método de treinamento da retropropagação do erro, que melhoram a velocidade de processamento, a capacidade de generalização, ou evitam o superajustamento.

Os algoritmos utilizados neste trabalho são encontrados na *toolbox* do software matemático MATLAB.

TrainGD (Gradiente Descendente)

Este é o algoritmo original da retropropagação do erro, que utiliza o passo de aprendizado para atualizar os pesos e tendências dos neurônios da rede no sentido inverso do gradiente da função de erro. Para tamanhos de passo de aprendizado altos, o processo de treinamento pode ficar indefinidamente instável, e para passos de aprendizado pequenos a instabilidade é sanada, porém ocorre um acréscimo no tempo de processamento (Demuth e Beale, 2004).

TrainGDM (Gradiente Descendente com *Momentum*)

Este algoritmo tem o mesmo princípio que o utilizado no TrainGD, porém com o acréscimo do *momentum* ele usa, além da informação local do gradiente, a última tendência do caminho percorrido sobre a superfície de erro, permitindo que sejam ignorados os

pequenos mínimos locais, e o prosseguimento em busca de um mínimo mais significativo (Demuth e Beale, 2004).

TrainLM (Levenberg-Marquardt)

O algoritmo *Levenberg-Marquardt* foi criado para aproximar um treinamento de segunda ordem, sem ter que operar com a matriz *Hessiana*. Quando a função de desempenho for do tipo soma de quadrados (como utilizadas nas típicas redes retropropagativas, a aproximação da matriz de *Hessiana* pode ser realizada por “ $H = JT \cdot J$ ”, e o gradiente por “ $g = JT \cdot E$ ”, onde “ J ” é a matriz Jacobiana, que contém as primeiras derivadas dos erros da rede neural, com os respectivos pesos e tendências, sendo “ E ” o vetor de erros da rede.

A matriz *Jacobiana* pode ser operada através de técnicas padrões de retropropagação, ficando a operação muito menos complexa do que com uma matriz *Hessiana*.

$$O_{k+1} = O_k - [J^T \cdot J + \mu \cdot I]^{-1} \cdot J^T \cdot E$$

A aproximação da matriz *Hessiana* é empregada na atualização dos pesos e tendências. Quando o escalar μ for zero, o processo é igual ao método de Newton, usando a aproximação da matriz *Hessiana*. Quando o valor de μ é elevado, o gradiente descende com um pequeno tamanho de passo. O método de Newton é rápido e muito preciso, ficando próximo do erro mínimo. Desta forma, o valor de μ decai após cada passo bem sucedido (redução na função de desempenho), e o aumento do valor de μ somente ocorre quando o passo dado também aumenta a função de desempenho. Assim, a função de desempenho será reduzida a cada iteração sendo um algoritmo desenvolvido com o intuito de promover um método de treinamento rápido para redes neurais com tamanho moderado (Demuth e Beale, 2004).

TrainBR (regularização automática)

Este algoritmo é uma combinação do *Levenberg-Marquardt* com a regularização *Bayesiana*, que faz uma modificação na função objetivo, acrescentando uma taxa de variação, que reduz a magnitude dos valores dos pesos sinápticos (w) e das tendências (b), fazendo com que a rede neural responda mais suavemente, o que previne o superajustamento, e também resulta um treinamento com maior poder de generalização (Demuth e Beale, 2004). Abaixo é apresentada a modificação na função objetivo, realizada na regularização *Bayesiana*.

Função objetivo com erro médio quadrático tradicional: $SEM_Q = \frac{1}{n} \sum_{i=1}^n (E_i)^2$

Função objetivo modificada: $SEM_{Q_{REG}} = \gamma \cdot SEM_Q + (1 - \gamma) \frac{1}{n} \sum_{j=1}^n (W_j)^2$

Onde:

γ = taxa de desempenho da regularização *Bayesiana*.

W = pesos dos neurônios da rede neural.

E = erros das respostas da rede em relação aos valores observados

4.2.4 Definição do número mínimo de treinamentos

A definição do número mínimo de treinamentos é necessária, para que se tenha certeza de que neste conjunto mínimo exista um treinamento considerado o melhor possível para aquela arquitetura. Esta distinção de qualidade entre treinamentos, com a mesma arquitetura, se deve à condição inicial do treinamento, que utiliza pesos aleatórios nos neurônios da rede, para iniciar o processo, gerando, assim, diferentes ajustes finais dos pesos.

Os processos de treinamento implementados neste trabalho sempre foram do tipo supervisionado por batelada, e os índices utilizados para realizar a escolha são obtidos da amostra de validação, pois, assim, é preservada a amostra de verificação, a qual não influencia na definição da melhor arquitetura da rede neural.

Assim, uma rede neural foi treinada 100 vezes, sempre com a mesma arquitetura, para verificar o comportamento dos seus índices de qualidade. Ao ordenar os índices, observou-se que cerca de 10% dos treinamentos são de baixa qualidade, enquanto os demais treinamentos seguem uma tendência linear de melhora do índice. O mesmo procedimento foi realizado para um conjunto de 30 treinamentos, para, assim, comparar com o melhor resultado do conjunto de 100 treinamentos (Figura 4.7).

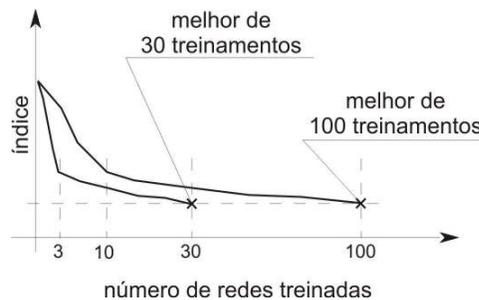


Figura 4.7 – Comportamento do índice em função do número de treinamentos.

A verificação do número mínimo de treinamentos foi realizada para mais algumas arquiteturas de rede neural, e com diferentes algoritmos de treinamento, bem como para outros horizontes de previsão, pois para cada horizonte de previsão temos diferentes formatos da superfície de erro, o que poderia influenciar no comportamento da qualidade dos índices em função do número de treinamentos.

4.2.5 Aglutinação dos índices de avaliação do modelo

A escolha do melhor resultado dentro de um conjunto, em uma primeira análise, seria simplesmente optar pelo treinamento que apresentou os melhores índices, porém, raramente ocorre de um treinamento ser melhor para todos os índices. Por vezes, um treinamento que se mostra vencedor segundo alguns índices apresenta desempenho medíocre segundo os demais.

Foi necessário adotar critérios mais condizentes com o problema, que indicassem o treinamento que melhor conciliasse as contradições dos resultados de todos os índices. Em virtude da finalidade do modelo de previsão de nível para um sistema de alerta de cheias, foram adotados ponderadores para cada índice, que privilegiassem mais os índices indicativos de maior exatidão da previsão de nível para os picos.

Na Tabela 4.5 são apresentados os ponderadores utilizados para cada índice.

Tabela 4.5 – Ponderadores para nota da qualidade dos resultados da rede neural.

EMQ	EMA	EPA	R	CP	Erro não ultrapassado 90%	Erro não ultrapassado 75%	Erro não ultrapassado 50%
3	2	1	2	3	3	2	1

A eleição ponderada do melhor desempenho em um conjunto (j) de resultados é realizada associando-se, a cada treinamento, uma nota relativa ao próprio conjunto, sendo que para cada índice (i) o treinamento que obteve o pior desempenho recebe o valor “0” e o que obteve o melhor recebe o valor do ponderador para o índice, e então, a nota do treinamento é obtida pela média ponderada dos valores dos índices.

O valor escalonado ($V_{i,j}$) para cada índice de um treinamento é:

$$V_{i,j} = w_i \cdot \left(\frac{|melhor(I_i) - I_{i,j}|}{melhor(I_i) - pior(I_i)} \right)$$

Onde: w_i é o peso ponderador para o índice “ i ”;

I é vetor que contém o conjunto de resultados dos índices (i) a serem ponderados.

A nota (NP_j) para cada treinamento é:

$$NP_j = \frac{\sum_i V_{i,j}}{\sum_i w_i}$$

4.2.6 Eleição da arquitetura ótima do modelo de rede neural

Uma rede neural tem diversos parâmetros de ajuste, que modificam suas características, de forma que a busca pela melhor configuração deve ser sistematizada.

A definição da melhor arquitetura da rede neural foi efetuada em duas etapas. Evitou-se empregar um número maior de etapas, para que, assim, não fiquem combinações de

arquitetura de rede neural sem avaliação de seus índices, pois a cada etapa alguns parâmetros são fixados, para então reduzir o número de combinações e prosseguir com a eleição da arquitetura ótima.

Na primeira etapa foram utilizadas 2 redes neurais padrão, uma com pouca complexidade (3 neurônios na camada intermediária) e outra com mais complexidade (12 neurônios na camada intermediária), e variou-se as funções de ativação e os algoritmos de treinamento. Uma exploração de uma maior variação do número de neurônios na camada intermediária será realizada na segunda etapa.

O objetivo, nesta primeira etapa, foi de eleger o melhor arranjo das funções de ativação e algoritmos de treinamento, e analisar a validade para graus de complexidade distintos. Os parâmetros, taxas de aprendizado e *momentum*, foram mantidos constantes. Para cada configuração foram executados 30 treinamentos, resultando índices estatísticos para os grupos de amostras de treinamento e de verificação. Nesta etapa foi fixado um limite de, no máximo, 50 acréscimos (falhas) no erro da amostra de validação cruzada, durante o treinamento. Este limite foi adotado para evitar a interrupção por motivo de oscilações do erro, observado logo a princípio do processo de treinamento.

Aplicado o método de seleção ponderada para cada conjunto de 30 treinamentos, foi selecionado o melhor resultado, para cada uma das 16 configurações propostas na primeira etapa. A seleção ponderada foi então novamente aplicada para a escolha de qual das configurações foi, dentre as 16, a melhor para cada horizonte de previsão.

A segunda etapa é um ajuste mais refinado da configuração eleita na primeira etapa. Os parâmetros que foram experimentados, nesta segunda etapa, foram o número de neurônios na camada intermediária, o número de falhas aceita na validação cruzada e as taxas de incremento e decremento do parâmetro *mu* do algoritmo *Levenberg-Marquardt*.

A gama de variações para cada um destes parâmetros está apresentada na Tabela 4.6.

Tabela 4.6 – Parâmetros que foram experimentados na segunda etapa da eleição.

<i>mu</i>		Nº Neurônios na Camada Intermediária	Nº de Falhas Toleradas para a Validação Cruzada
decremento	incremento		
		2	10
		3	
0,05	5	5	50
0,1	10	8	
0,2	20	12	200
0,6	60	24	
1,0	100	32	500

Assim, serão treinadas 140 distintas arquiteturas de rede neural para cada um dos 5 horizontes de previsão, e comparadas simultaneamente entre si, de forma que não são

descartadas combinações possíveis para os parâmetros cuja variação foi testada. O acréscimo de tempo ocorrido na realização da busca da melhor arquitetura é evidente, porém, espera-se que, desta forma, esta etapa tenha a eficácia desejada.

4.3 Modelo de Redes Neurais sem uso de Previsões de Precipitação

A vantagem notável da utilização de dados de previsão de chuva em modelos de previsão de nível é de ampliar o horizonte destas previsões.

Os modelos comparados foram o de redes neurais com a arquitetura que promoveu os melhores resultados para entradas de níveis observados e chuva prevista, e um outro modelo, também por redes neurais, porém, contendo somente entradas de níveis observados (Figura 4.8).

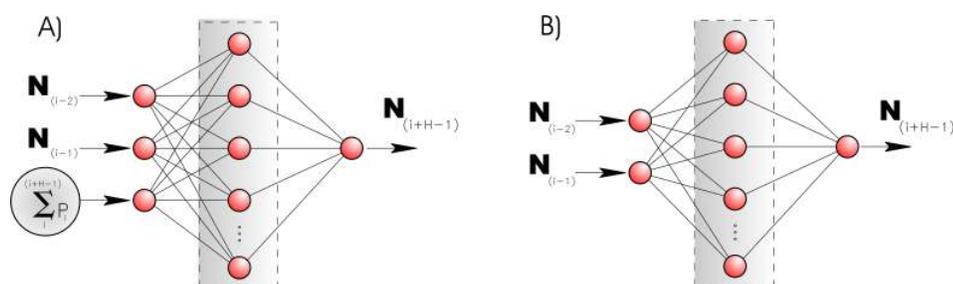


Figura 4.8 – Redes Neurais para verificar o ganho usando previsão hidrometeorológica.

Esta investigação pretende comparar o desempenho, e verificar o ganho que foi obtido, pela utilização das previsões de chuvas. Ou, melhor ainda, a redução do desempenho pela sua não utilização, que poderia ocorrer se o acesso às informações fosse interrompido.

A eleição da melhor arquitetura de rede neural seguiu a mesma metodologia empregada no modelo com previsão de precipitação agregada, com duas etapas.

4.4 Modelagem por Regressão Linear Multivariada

Modelos de regressão são consagrados e largamente utilizados na previsão de níveis. Existem diversas variações do método de regressão, e com diferentes sofisticções implementadas, porém, a comparação neste trabalho não pretende eleger o melhor método para previsão de níveis, mas sim, balizar, em termos de ordem de grandeza aproximada, o modelo por redes neurais artificiais, usando-se como referência um modelo sem grandes sofisticções, tradicionalmente usado. Com esta pretensão estabelecida, a pesquisa não foi mais intensiva em explorar recursos para a modelagem por regressão.

O modelo por regressão foi obtido através do ajuste por mínimos quadrados de uma equação com 3 variáveis, que são as mesmas entradas do modelo por redes neurais (2 níveis observados anteriormente e a previsão de chuva na bacia), além de uma variável adicional, que pondera a previsão de precipitação por um índice representativo da condição de umidade

do solo (“U” - capacidade de infiltração), esta, em função do nível do rio no momento em que a previsão de nível é realizada. Este ponderador teve por objetivo permitir um escalonamento (ampliação ou redução) do efeito da precipitação sobre o nível a ser previsto, fornecendo ao modelo um grau de liberdade a mais.

Assim, o modelo de regressão utilizado tem uma vocação conceitual, levando em conta variáveis que sabidamente determinam o comportamento do nível do rio nos instantes futuros.

4.4.1 Amostras de Dados para o Modelo de Regressão Multivariada

A divisão das amostras para o modelo de regressão foi a mesma utilizada no modelo por redes neurais, para que, assim, a comparação dos resultados entre os modelos tenha validade e coerência. A amostra de validação cruzada utilizada no treinamento do modelo por redes neurais não teve utilidade na modelagem por regressão, sendo desconsiderada nesta etapa.

4.4.2 Eleição do modelo de regressão

A modelagem por regressão multivariada utilizou 4 diferentes configurações das variáveis independentes:

1- Utiliza 2 níveis anteriores e chuva prevista

$$N_{prev} = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3$$

2 - Utiliza 2 níveis anteriores e chuva prevista, multiplicada pelo índice de umidade do solo

$$N_{prev} = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3 \cdot U$$

3 - Utiliza 2 níveis anteriores e chuva prevista, elevada ao índice de umidade do solo

$$N_{prev} = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3^U$$

4 - Utiliza 2 níveis anteriores

$$N_{prev} = a_0 + a_1 \cdot x_1 + a_2 \cdot x_2$$

Onde:

N_{prev} = nível previsto pelo modelo de regressão

x_1 = nível do rio em (i-2) “antes de ontem”

x_2 = nível do rio em (i-1) “ontem”

x_3 = previsão de chuva do modelo ETA acumulada até o horizonte de previsão

a_0, a_1, a_2 e a_3 são os parâmetros da solução do sistema linear $A(x)=y$

U = ponderador da precipitação em função da magnitude do nível médio observado nos dois dias anteriores ao dia quando a previsão de nível é efetuada.

Onde:
$$U = \frac{x_1 + x_2}{2}$$

O ponderador U foi escalonado para o intervalo entre 0 e 2. Este processo evita que o parâmetro a_3 fique muito pequeno, conforme foi observado em tentativa de utilização sem o escalonamento, onde ele variou de ordens de 10^{-6} a 10^{-10} .

Os parâmetros do modelo foram ajustados por mínimos quadrados, para a amostra de treinamento (520 dados), e os resultados, para efetuar a escolha do melhor modelo para cada horizonte de previsão, foram obtidos da mesma amostra utilizada na validação cruzada (260 dados), do modelo por redes neurais.

5. Resultados e Análises

A apresentação dos resultados é iniciada pela análise do modelo de previsão de precipitação, objetivando avaliar a qualidade das previsões de precipitação e a capacidade deste de fornecer informações relevantes para o modelo de previsão de nível.

Em seguida, prosseguiu-se com a apresentação dos resultados e análises para o modelo proposto de redes neurais, com a utilização de previsão de precipitação. Com estes resultados, foi realizada a avaliação da influência da utilização da previsão hidrometeorológica no modelo, e também a comparação com os resultados obtidos pelo modelo de regressão linear multivariada.

A avaliação da influência do uso de previsão hidrometeorológica é realizada comparando-se diretamente os resultados, do modelo por redes neurais que utiliza esta previsão com o que não a utiliza.

A comparação do modelo por redes neurais com o modelo por regressão tem por objetivo oferecer uma referência adicional, situando, em termos de ordem de grandeza dos índices de magnitude, o desempenho relativo dos modelos. Este resultado é atingido pela exposição e análise comparativa destes índices de desempenho, obtidos dos modelos com as configurações que apresentaram os melhores resultados.

Por fim, é apresentada uma análise baseada nos resultados da proposta de utilização de um modelo por redes neurais para incorporar o módulo de previsão de nível a um sistema de alerta de cheias.

5.1 Qualidade da Previsão Hidrometeorológica

5.1.1 “Alerta Falso” e “Incapacidade de Previsão”

Uma análise inicial, que leva em conta dados nulos de previsão ou de observação, permite obter-se uma idéia da confiabilidade do modelo ETA para chuvas de pequena intensidade e verificar-se, assim, a importância dos erros associados a “Alertas Falsos” (prever precipitação, porém, a observação não confirmar a ocorrência do evento) e “Incapacidades de Previsão” (incapacidade de prever a ocorrência de precipitação) (Tabela 5.1). Estes dois tipos de falha são fontes de preocupação para os operadores de sistema de alerta, que utilizam previsão de chuva como dado de entrada.

A Figura 5.1 mostra os dados da Tabela 5.1 em forma de conjuntos sobrepostos, permitindo uma análise visual intuitiva do comportamento das falhas em função do horizonte de previsão.

Tabela 5.1 – Contagem de observações e/ou previsões de precipitação nula.

	1º dia		2º dia		3º dia		4º dia		5º dia	
PREV NULO e OBS NULO	557		542		495		463		469	
PREV NULO	679		650		599		564		590	
OBS NULO	633		633		633		633		633	
PREV NULO e OBS NÃO-NULO "Incapacidade de Prever Evento"	122	18,0%	108	16,6%	104	17,4%	101	17,9%	121	20,5%
PREV NÃO-NULO e OBS NULO "Alerta Falso"	76	12,0%	91	14,4%	138	21,8%	170	26,9%	164	25,9%



Figura 5.1 – Acerto de previsão de chuva nula e as falhas de “Incapacidade de Previsão” e “Alerta Falso”.

A Tabela 5.2 mostra os índices estatísticos dos resíduos para falha “Alerta Falso”, onde é prevista alguma lâmina de precipitação, mas a precipitação observada é nula. São apresentados, também nesta tabela, os valores do resíduo que não foi superado em 90, 75 e 50% das ocorrências de “Alerta Falso”. Na Figura 5.2 são apresentadas as curvas de permanência para o resíduo da falha por “Alerta Falso”.

Tabela 5.2 – Índices estatísticos para o resíduo de “Alerta Falso”.

	1º dia	2º dia	3º dia	4º dia	5º dia
EMQ(mm ²)	37,02	32,52	45,86	65,08	97,49
EMA(mm)	2,53	3,08	3,79	5,11	5,80
EPA(mm)	1,72	1,77	2,59	3,42	4,11
Resíduo não ultrapassado em 90%(mm)	6,85	7,93	10,23	14,71	14,91
Resíduo não ultrapassado em 75%(mm)	2,53	3,77	4,99	7,19	7,89
Resíduo não ultrapassado em 50%(mm)	0,63	0,98	1,65	2,75	2,41

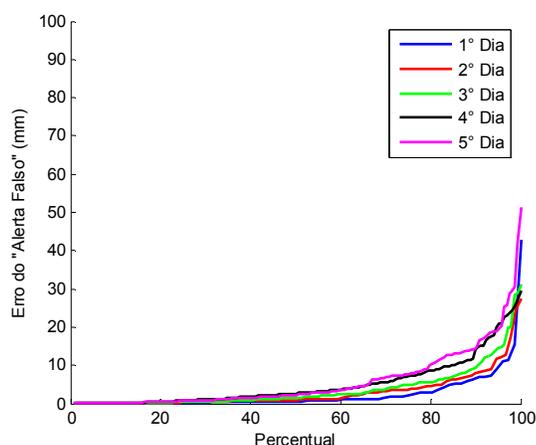


Figura 5.2 – Curvas de permanência do resíduo do “Alerta Falso”.

A Tabela 5.3 mostra os índices estatísticos para o resíduo da falha “Incapacidade de Previsão”, onde a previsão de chuva é nula, mas é observada precipitação não nula. São apresentados, também nesta tabela, os valores do resíduo que não foi superado em 90, 75 e 50% das ocorrências de “Incapacidade de Previsão”. Na Figura 5.3 são apresentadas curvas de permanência para o resíduo da falha por “Incapacidade de Previsão”.

Tabela 5.3 – Índices estatísticos para o resíduo de “Incapacidade de Previsão”.

	1° dia	2° dia	3° dia	4° dia	5° dia
EMQ(mm)	79,81	84,46	102,50	118,95	187,27
EMA(mm)	4,09	4,40	5,15	5,71	7,08
EPA(mm)	3,21	3,10	3,36	3,56	4,89
Resíduo não ultrapassado em 90%(mm)	10,17	14,97	15,12	16,50	19,08
Resíduo não ultrapassado em 75%(mm)	3,50	3,53	5,14	5,57	8,00
Resíduo não ultrapassado em 50%(mm)	1,26	1,26	1,29	1,68	1,80

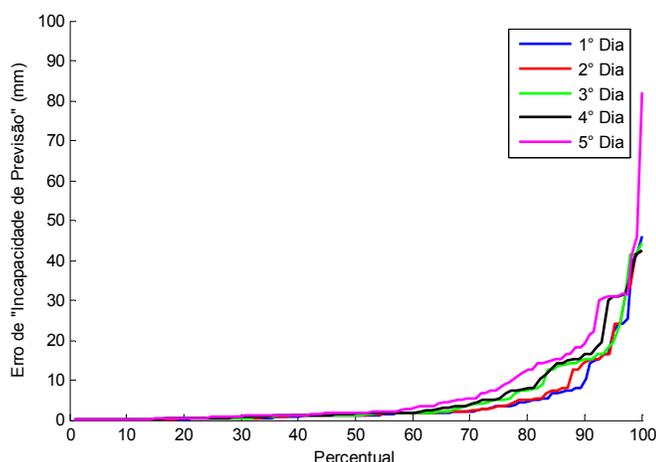


Figura 5.3 – Curvas de permanência do resíduo da “Incapacidade de Previsão”.

Verifica-se que o ordenamento esperado (maiores horizontes de previsão com maiores resíduos) foi confirmado nestes resultados.

Os resíduos para as falhas por “Incapacidade de Previsão” são sempre pouco superiores aos de “Alerta Falso”, mostrando um comportamento muito semelhante entre estes dois tipos de falha.

O número de ocorrências para a falha do tipo “Incapacidade de Previsão” manteve-se praticamente constante em função do horizonte de previsão. Já para falha do tipo “Alerta Falso”, o aumento foi significativo; para os horizontes de previsão de 4 e 5 dias o aumento observado foi mais que o dobro das ocorrências para o de 1 dia (Tabela 5.1 e Figura 5.1).

As curvas de permanência para “Alerta Falso” (Figura 5.2) indicam um pequeno incremento (declividade) até o percentual de 60% da amostra, e na Figura 5.3, até 70% para a falha por “Incapacidade de Previsão”. Assim, na maior parte das vezes, o resíduo é constante e de baixa magnitude, principalmente para falha de “Incapacidade de Previsão”.

A observação do resíduo de falha por “Incapacidade de Previsão” para o 5º dia, onde 20,5% das previsões nulas não são confirmadas (foi observada alguma precipitação), permite obter-se uma estimativa do máximo erro que ocorre com a utilização das previsões de chuva do modelo ETA. Para este horizonte, 90% dos resíduos não superam 19,08 mm de chuva, sendo que para 75% dos resíduos este índice cai para 8mm, ficando o EMA em 7,08 mm. Estes volumes não são suficientes para produzir grandes elevações de nível de água no Rio Quaraí, conforme verificado nos dados observados.

Realizando a mesma observação para o resíduo de falha por “Alerta Falso”, os resultados para o 5º dia de horizonte de previsão têm 25,9% de chance de ocorrer com previsões não nulas de chuva, para este horizonte, 90% dos resíduos não superaram 14,91 mm de chuva, já para 75% dos resíduos este índice cai para 7,89 mm e o EMA em 5,80 mm.

Fazendo-se estas mesmas observações para horizontes cada vez mais curtos, é notável a melhora dos índices estatísticos, concluindo-se que o modelo é confiável em relação aos erros de “Incapacidade de Previsão” e “Alerta Falso”.

5.1.2 Previsões e Observações Não Nulas

Os índices apresentados na Tabela 5.4 foram obtidos excluindo-se os casos em que a chuva prevista e/ou observada foram nulas, desprezando-se, assim, a influência dos erros por “Alerta Falso”, “Incapacidade de Previsão” e acerto para chuva nula, nos índices.

Tabela 5.4 – Índices estatísticos para dados com chuva prevista e observada não nulas.

	1º dia	2º dia	3º dia	4º dia	5º dia
Σ Volume Previsto (mm)	2050,86	2092,85	2291,99	2706,96	2092,25
Σ Volume Observado (mm)	2537,51	2562,05	2501,72	2459,72	2180,07
Σ Vol,(Previsto - Observado) (mm)	-486,65	-469,20	-209,73	247,24	-87,82
EMQ (mm ²)	187,59	212,64	312,02	301,47	279,89
EMA (mm)	8,83	9,61	11,38	11,74	11,18
EPA (mm)	13,70	14,58	17,66	17,36	16,73
R	0,45	0,38	0,25	0,27	0,24
Resíduo não ultrapassado em 90%	20,27	24,56	29,57	30,16	27,22
Resíduo não ultrapassado em 75%	12,73	12,91	14,92	15,82	16,27
Resíduo não ultrapassado em 50%	5,07	5,67	7,15	7,13	6,42

Na Figura 5.4, estão desenhadas as curvas de permanência do resíduo para previsão e observação não nula, nos horizontes de 1 a 5 dias de antecedência.

Nas Figuras 5.5 a 5.9, são apresentadas as séries de previsões e observações de chuva não nula.

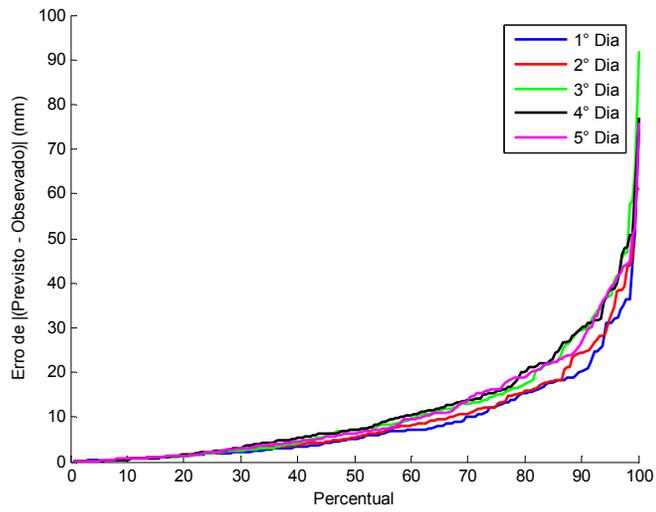


Figura 5.4 – Curva de permanência dos resíduos de previsão e observação não nulas.

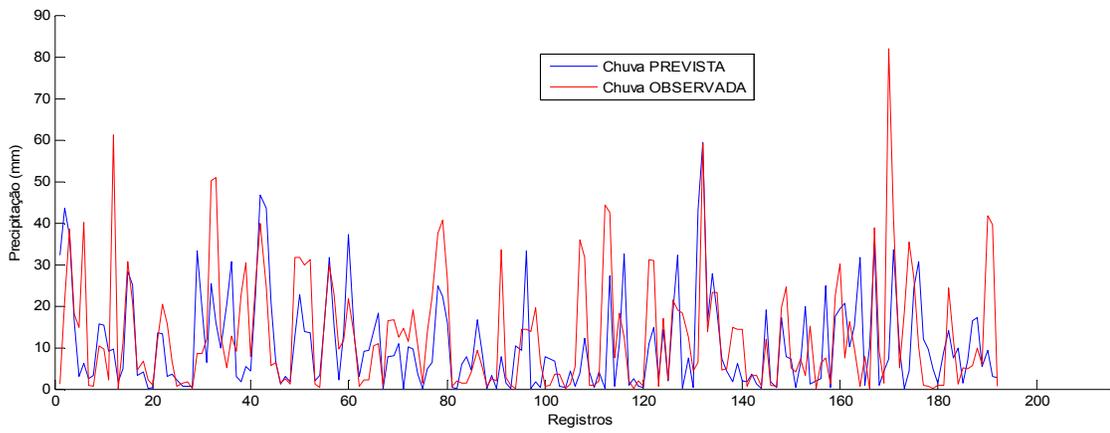


Figura 5.5 – Previsões e observações para horizonte de 1 dia.

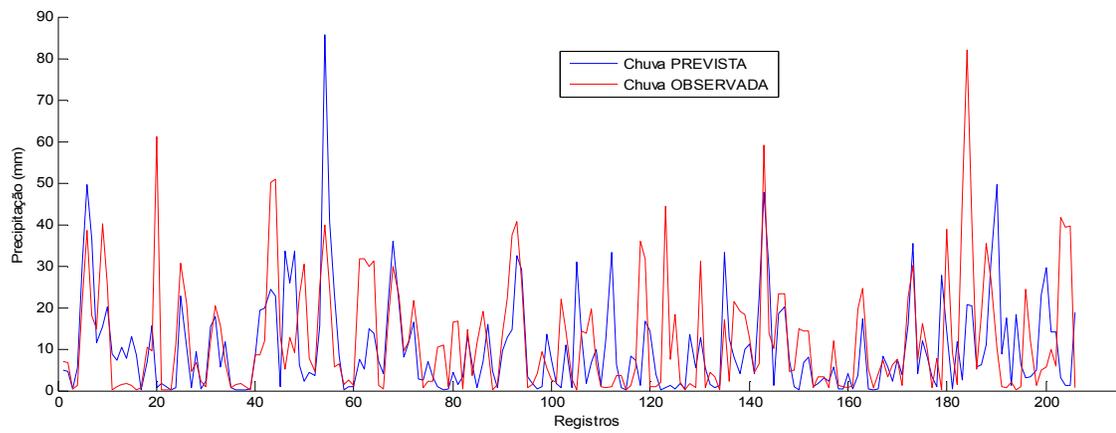


Figura 5.6 – Previsões e observações para horizonte de 2 dias.

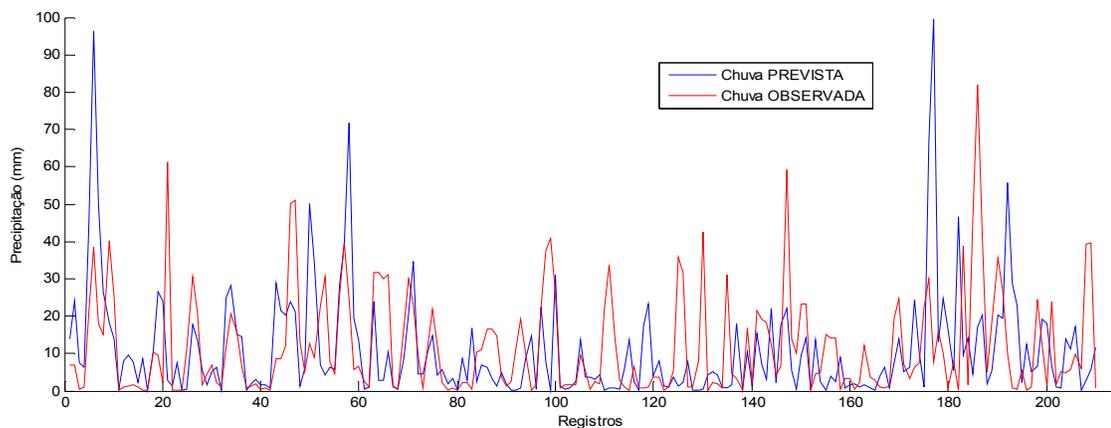


Figura 5.7 – Previsões e observações para horizonte de 3 dias.

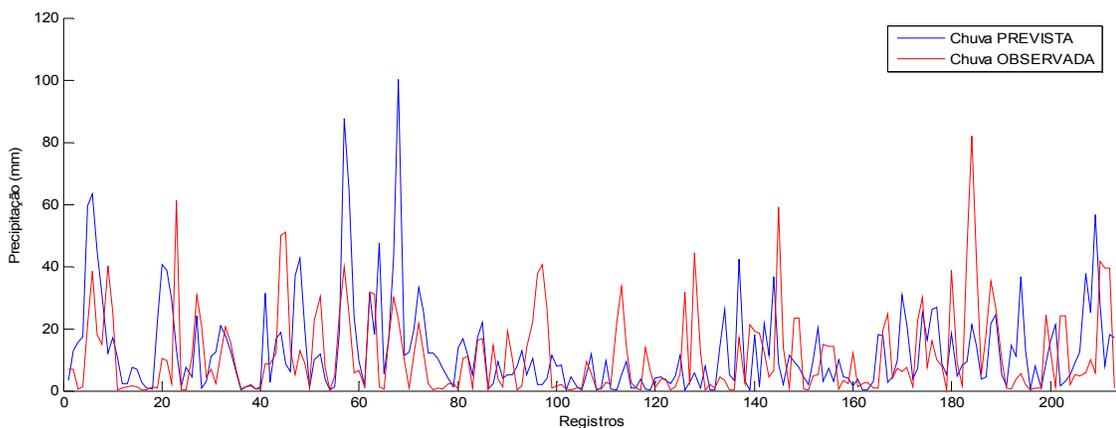


Figura 5.8– Previsões e observações para horizonte de 4 dias.

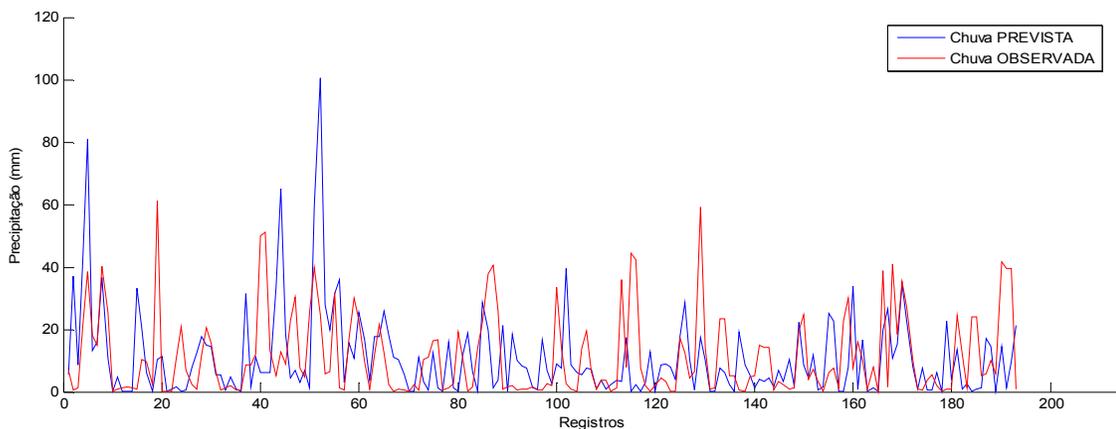


Figura 5.9– Previsões e observações para horizonte de 5 dias.

O comportamento das previsões em função do horizonte de previsão não apresentou grande diferença, e a curva de permanência da Figura 5.4 possibilita verificar a homogeneidade deste comportamento. Esta curva de permanência para os resíduos apresentou um incremento importante já a partir dos 40%, e acentua-se mais ainda, após os 75%, para todos os horizontes de previsão.

Analisando-se os índices estatísticos em conjunto, pode-se fazer um ordenamento, em função do horizonte de previsão, do melhor ao pior desempenho, o qual resulta em 1 dia, 2 dias, 5 dias, 4 dias e 3 dias.

Em relação aos volumes acumulados, é observada uma tendência de subestimação para os menores horizontes de previsão (1, 2 e 3 dias). O horizonte de 4 dias apresentou superestimação, e para o horizonte de 5 dias o modelo volta a apresentar subestimação.

O erro de volume de precipitação acumulada não é fator de impedimento para a utilização da previsão hidrometeorológica em modelos de previsão de cheias, onde é mais importante o acerto de eventos extremos do que o volume total acumulado, de forma que, se o erro na previsão de precipitação é sistemático, modelos empíricos como os representados por redes neurais, podem compensar esta deficiência e obter resultados satisfatórios.

O modelo de previsão hidrometeorológica apresenta baixos índices para o Coeficiente de Correlação (R), indicando baixa associação entre a chuva prevista e a observada. Para os menores horizontes (1 e 2 dias), porém, é mais provável um sucesso no aproveitamento da previsão de precipitação para aplicação em modelos de previsão de nível em cursos d'água, uma vez que, para estes horizontes, a incerteza da previsão de precipitação é menor.

Analisando os gráficos das Figuras 5.5 a 5.9, verifica-se uma baixa capacidade de prever as precipitações de maiores magnitudes (pico), principalmente para os maiores horizontes de previsão, o que pode gerar dificuldades na previsão de nível, dependendo do grau de influência que este dado terá no resultado do modelo.

5.2 Análise dos Resultados do Modelo de Redes Neurais com uso de Previsão de Precipitação

5.2.1 Resultados da definição do número mínimo de treinamentos das redes neurais

Na Tabela 5.5 são apresentados os resultados dos melhores índices, para 30 e 100 repetições de treinamento e para os 5 horizontes de previsão. Foi utilizada uma rede neural com 3 neurônios na camada intermediária e o algoritmo de treinamento TrainLM.

Os resultados observados, nos diversos testes realizados, mostraram sempre o mesmo comportamento, em que a melhora da qualidade do índice para um número cada vez maior de repetições não é significativa, principalmente para a etapa de escolha da arquitetura da rede neural, onde este critério, número de treinamentos, será utilizado igualmente para todas as configurações a explorar.

Tabela 5.5 – Melhor índice para os conjuntos com 30 e 100 repetições do treinamentos e para os 5 horizontes de previsão.

Horizonte de Previsão	Nº Treinamentos	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)
1º dia	30	0,090	0,165	0,300	0,965	0,513	0,389	0,183	0,071
	100	0,074	0,155	0,272	0,971	0,599	0,395	0,170	0,064
2º dia	30	0,324	0,313	0,569	0,862	0,512	0,818	0,337	0,135
	100	0,324	0,314	0,570	0,861	0,511	0,784	0,328	0,127
3º dia	30	0,548	0,405	0,740	0,762	0,431	1,020	0,410	0,202
	100	0,517	0,403	0,719	0,771	0,462	0,993	0,430	0,158
4º dia	30	0,699	0,508	0,836	0,691	0,393	1,096	0,551	0,245
	100	0,677	0,492	0,823	0,703	0,412	1,039	0,503	0,244
5º dia	30	0,671	0,501	0,819	0,697	0,420	1,164	0,690	0,292
	100	0,650	0,489	0,806	0,708	0,438	1,059	0,574	0,283

Com base nos resultados dos testes realizados, foi adotado o mínimo de 30 repetições de treinamentos para cada arquitetura de rede neural para então eleger o melhor dos treinamentos deste conjunto.

5.2.2 Resultados da eleição da arquitetura da rede neural COM uso de previsão de precipitação

Os resultados da 1ª etapa da eleição estão apresentados nas Tabelas 5.6 a 5.10. A configuração das redes neurais é identificada na primeira coluna das tabelas, através da seguinte definição das siglas:

(i)N: rede neural com “i” neurônios na camada intermediária;

Sat: função SATLINS na camada intermediária;

Tan: função TANSIG na camada intermediária;

BR, GD, GDM e LM: algoritmos de treinamento TrainBR, TrainGD, TrainGDM e TrainLM, respectivamente;

Tabela 5.6 – Resultados para cada configuração de rede neural (horiz. 1 dia) COM previsão de chuva

Arquitetura da RN	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,091	0,165	0,301	0,964	0,509	0,448	0,182	0,069	0,203
3N_Sat_GD	0,093	0,164	0,305	0,963	0,495	0,444	0,186	0,062	0,168
3N_Sat_GDM	0,088	0,169	0,297	0,965	0,522	0,424	0,199	0,078	0,200
3N_Sat_LM	0,086	0,161	0,293	0,966	0,535	0,410	0,172	0,078	0,412
3N_Tan_BR	0,083	0,155	0,289	0,967	0,548	0,417	0,164	0,066	0,560
3N_Tan_GD	0,083	0,161	0,288	0,967	0,549	0,452	0,192	0,068	0,393
3N_Tan_GDM	0,090	0,162	0,301	0,964	0,509	0,444	0,192	0,072	0,202
3N_Tan_LM	0,074	0,155	0,272	0,971	0,599	0,403	0,186	0,069	0,751
12N_Sat_BR	0,085	0,165	0,292	0,967	0,539	0,420	0,190	0,080	0,324
12N_Sat_GD	0,086	0,161	0,293	0,966	0,534	0,397	0,192	0,065	0,415
12N_Sat_GDM	0,090	0,165	0,299	0,965	0,514	0,443	0,185	0,068	0,228
12N_Sat_LM	0,081	0,161	0,285	0,968	0,558	0,331	0,185	0,081	0,590
12N_Tan_BR	0,074	0,154	0,272	0,971	0,600	0,391	0,182	0,067	0,797
12N_Tan_GD	0,077	0,158	0,277	0,970	0,585	0,404	0,209	0,068	0,608
12N_Tan_GDM	0,075	0,159	0,274	0,970	0,593	0,422	0,188	0,074	0,641
12N_Tan_LM	0,072	0,154	0,268	0,972	0,610	0,369	0,195	0,074	0,826

Tabela 5.7 – Resultados para cada configuração de rede neural (horiz. 2 dias) COM previsão de chuva

Arquitetura da RN	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,374	0,332	0,611	0,840	0,436	0,808	0,345	0,146	0,700
3N_Sat_GD	0,494	0,369	0,703	0,784	0,255	0,912	0,322	0,196	0,216
3N_Sat_GDM	0,481	0,400	0,694	0,802	0,274	0,909	0,439	0,208	0,100
3N_Sat_LM	0,331	0,321	0,576	0,859	0,500	0,841	0,369	0,152	0,769
3N_Tan_BR	0,332	0,321	0,576	0,858	0,499	0,785	0,370	0,154	0,818
3N_Tan_GD	0,465	0,385	0,682	0,805	0,298	0,869	0,416	0,188	0,234
3N_Tan_GDM	0,471	0,390	0,686	0,804	0,290	0,886	0,434	0,209	0,165
3N_Tan_LM	0,356	0,327	0,597	0,847	0,463	0,834	0,369	0,129	0,715
12N_Sat_BR	0,340	0,325	0,583	0,857	0,487	0,940	0,338	0,154	0,672
12N_Sat_GD	0,394	0,365	0,628	0,856	0,405	0,839	0,378	0,216	0,521
12N_Sat_GDM	0,418	0,353	0,647	0,818	0,369	0,902	0,402	0,147	0,399
12N_Sat_LM	0,301	0,313	0,549	0,872	0,545	0,811	0,369	0,155	0,888
12N_Tan_BR	0,382	0,341	0,618	0,846	0,424	0,831	0,347	0,162	0,644
12N_Tan_GD	0,322	0,322	0,568	0,863	0,514	0,763	0,401	0,140	0,843
12N_Tan_GDM	0,497	0,385	0,705	0,778	0,250	0,903	0,395	0,188	0,120
12N_Tan_LM	0,314	0,325	0,561	0,866	0,526	0,802	0,391	0,156	0,822

Tabela 5.8 – Resultados para cada configuração de rede neural (horiz. 3 dias) COM previsão de chuva

Arquitetura da RN	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,559	0,408	0,748	0,751	0,419	1,087	0,431	0,174	0,694
3N_Sat_GD	0,686	0,473	0,828	0,701	0,287	0,993	0,519	0,280	0,246
3N_Sat_GDM	0,691	0,478	0,831	0,689	0,282	0,954	0,508	0,281	0,253
3N_Sat_LM	0,562	0,419	0,750	0,753	0,415	0,934	0,452	0,208	0,768
3N_Tan_BR	0,618	0,422	0,786	0,746	0,357	0,986	0,449	0,206	0,601
3N_Tan_GD	0,660	0,434	0,812	0,696	0,314	1,012	0,440	0,197	0,428
3N_Tan_GDM	0,715	0,449	0,846	0,687	0,256	1,151	0,398	0,220	0,188
3N_Tan_LM	0,540	0,407	0,735	0,760	0,438	1,003	0,482	0,205	0,763
12N_Sat_BR	0,580	0,439	0,761	0,740	0,397	1,058	0,493	0,246	0,539
12N_Sat_GD	0,667	0,452	0,817	0,699	0,306	1,108	0,467	0,242	0,272
12N_Sat_GDM	0,639	0,430	0,799	0,707	0,335	0,964	0,446	0,207	0,518
12N_Sat_LM	0,557	0,386	0,746	0,755	0,421	1,026	0,384	0,171	0,817
12N_Tan_BR	0,515	0,401	0,718	0,772	0,464	0,984	0,444	0,213	0,876
12N_Tan_GD	0,609	0,440	0,780	0,725	0,367	1,005	0,508	0,206	0,514
12N_Tan_GDM	0,690	0,451	0,831	0,678	0,282	1,097	0,551	0,195	0,176
12N_Tan_LM	0,534	0,397	0,731	0,769	0,445	0,994	0,409	0,191	0,868

Tabela 5.9 – Resultados para cada configuração de rede neural (horiz. 4 dias) COM previsão de chuva

Arquitetura da RN	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,775	0,553	0,880	0,652	0,326	1,138	0,602	0,351	0,306
3N_Sat_GD	0,752	0,503	0,867	0,663	0,347	1,046	0,578	0,274	0,576
3N_Sat_GDM	0,767	0,502	0,876	0,653	0,333	1,218	0,560	0,279	0,392
3N_Sat_LM	0,730	0,514	0,854	0,675	0,365	1,166	0,633	0,287	0,453
3N_Tan_BR	0,835	0,564	0,914	0,630	0,274	1,210	0,662	0,384	0,009
3N_Tan_GD	0,791	0,511	0,889	0,656	0,313	1,035	0,593	0,278	0,471
3N_Tan_GDM	0,740	0,500	0,860	0,669	0,357	1,102	0,588	0,264	0,554
3N_Tan_LM	0,630	0,480	0,793	0,727	0,453	1,066	0,613	0,268	0,883
12N_Sat_BR	0,690	0,492	0,831	0,697	0,400	1,091	0,645	0,256	0,658
12N_Sat_GD	0,692	0,485	0,832	0,697	0,398	1,080	0,622	0,255	0,696
12N_Sat_GDM	0,759	0,495	0,871	0,658	0,340	1,037	0,540	0,263	0,617
12N_Sat_LM	0,648	0,500	0,805	0,720	0,437	1,025	0,629	0,320	0,808
12N_Tan_BR	0,644	0,481	0,802	0,720	0,440	1,047	0,581	0,268	0,891
12N_Tan_GD	0,742	0,494	0,861	0,667	0,355	1,220	0,555	0,256	0,484
12N_Tan_GDM	0,715	0,486	0,845	0,685	0,379	1,138	0,573	0,246	0,633
12N_Tan_LM	0,638	0,483	0,798	0,724	0,446	1,040	0,612	0,272	0,882

Tabela 5.10 – Resultados para cada configuração de rede neural (horiz. 5 dias) COM previsão de chuva

Arquitetura da RN	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,722	0,529	0,850	0,668	0,375	1,167	0,741	0,301	0,273
3N_Sat_GD	0,736	0,513	0,858	0,661	0,364	1,218	0,623	0,292	0,286
3N_Sat_GDM	0,732	0,517	0,856	0,662	0,367	1,221	0,637	0,289	0,283
3N_Sat_LM	0,728	0,557	0,853	0,674	0,370	1,168	0,745	0,353	0,200
3N_Tan_BR	0,664	0,491	0,815	0,701	0,426	1,136	0,640	0,278	0,606
3N_Tan_GD	0,761	0,523	0,873	0,646	0,342	1,281	0,593	0,301	0,157
3N_Tan_GDM	0,740	0,523	0,860	0,658	0,360	1,199	0,617	0,304	0,271
3N_Tan_LM	0,672	0,502	0,820	0,697	0,419	1,123	0,618	0,318	0,565
12N_Sat_BR	0,735	0,502	0,857	0,660	0,364	1,185	0,598	0,258	0,356
12N_Sat_GD	0,722	0,516	0,849	0,669	0,376	1,226	0,623	0,268	0,338
12N_Sat_GDM	0,669	0,500	0,818	0,699	0,422	1,115	0,686	0,291	0,559
12N_Sat_LM	0,602	0,474	0,776	0,734	0,480	1,029	0,594	0,287	0,925
12N_Tan_BR	0,609	0,465	0,780	0,730	0,473	1,076	0,600	0,257	0,893
12N_Tan_GD	0,713	0,515	0,844	0,674	0,383	1,269	0,657	0,280	0,312
12N_Tan_GDM	0,729	0,535	0,854	0,664	0,369	1,255	0,727	0,327	0,176
12N_Tan_LM	0,640	0,458	0,800	0,714	0,446	1,022	0,541	0,248	0,873

Observou-se, nos resultados da 1ª etapa de eleição, uma variação da melhor arquitetura em função do horizonte, porém, em linhas gerais, podemos identificar uma arquitetura que apresentou bom desempenho para todos os horizontes. Uma rede treinada com o algoritmo TrainLM e função de ativação TANSIG, mostrou-se a mais regular para os 5 horizontes de previsão. O grau de complexidade da rede neural (3 ou 12 neurônios na camada intermediária) influenciou no desempenho dos índices. As redes mais complexas (com 12 neurônios na camada intermediária) apresentaram, sistematicamente, melhor desempenho que as de menor complexidade.

Como resultado da primeira etapa, optou-se por fixar o algoritmo de treinamento em TrainLM e a função de ativação em TANSIG.

A escolha final (2ª etapa), por nota ponderada para o modelo por redes neurais com uso da previsão de precipitação, é apresentada na Tabela 5.11. Nesta tabela estão as arquiteturas consideradas ótimas para cada um dos 5 horizontes de previsão.

Tabela 5.11 – Arquiteturas ótimas de rede neural para o modelo COM uso de previsão de chuva

Horizonte Previsão	Algoritmo	Nº Neurônios	μ (Incremento)	μ (Decremento)	Nº Falhas na Validação Cruzada	Função de Ativação
Dia 1	TRAINLM	5	10	0,10	50	TANSIG
Dia 2	TRAINLM	12	20	0,20	500	TANSIG
Dia 3	TRAINLM	12	5	0,05	10	TANSIG
Dia 4	TRAINLM	32	10	0,10	200	TANSIG
Dia 5	TRAINLM	24	20	0,20	500	TANSIG

5.2.3 Resultados do modelo de previsão de nível COM previsão de chuva para as arquiteturas ótimas

Após a etapa de escolha da arquitetura ótima para o modelo de previsão, as redes eleitas foram utilizadas para os testes com a amostra de verificação, que não teve influência em nenhuma das etapas, nem de treinamento nem de validação cruzada/eleição, mantendo assim uma total independência destes processos.

Os resultados para a amostra de verificação, utilizando o modelo ótimo eleito para cada horizonte de previsão, estão apresentados na Tabela 5.12.

Tabela 5.12 – Resultado para a amostra de verificação – Modelo RN COM previsão de chuva.

Horizonte	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	Nota
Dia 1	0,255	0,227	0,505	0,899	0,361	0,480	0,204	0,079	0,824
Dia 2	0,436	0,345	0,660	0,812	0,414	0,795	0,333	0,157	0,494
Dia 3	0,546	0,422	0,739	0,757	0,442	0,946	0,486	0,207	0,275
Dia 4	0,545	0,425	0,738	0,759	0,503	0,991	0,515	0,219	0,324
Dia 5	0,637	0,477	0,798	0,735	0,475	1,073	0,541	0,276	0,142

A piora dos índices em função do aumento do horizonte de previsão apresenta uma inversão entre o 3º e 4º dias. Observando-se o ordenamento da qualidade da previsão de chuva em função do horizonte, que é 1, 2, 5, 4 e 3, pode-se levantar algumas hipóteses explicativas para este resultado. A previsão de nível utiliza valores de previsão de precipitação acumulada, assim, para o 3º dia temos a influência mais significativa da má qualidade de previsão de precipitação para este horizonte do que para o horizonte de 4 dias. Na prática, analisando os índices isoladamente, nota-se que os resultados entre o 3º e o 4º dia de previsão de nível são

muito próximos e alternam-se, indicando por vezes vantagem para um horizonte e por vezes para outro, porém, utilizando-se o método de nota ponderada é possível obter-se uma avaliação global dos índices, filtrando-se a subjetividade do julgamento.

Nota-se, ainda, que os índices de erro associado às freqüências seguiu a tendência de piora em função do aumento do horizonte de previsão para os 3 valores de freqüência selecionados (50, 75 e 90%), além de apresentar valores aceitáveis para uma previsão de nível, onde o erro variou de cerca de 50 cm para o horizonte de 1 dia e 110 cm para o horizonte de 5 dias, para 90% do tempo. Estes índices, erros associados à freqüência, possibilitam um entendimento mais intuitivo e realista da incerteza do modelo de previsão, constituindo uma margem de garantia para uso do tomador de decisão em um sistema de alerta de cheias. A observação simples do erro médio absoluto atenua o grau de incerteza, pois não informa a magnitude que o modelo erra. Em geral, o erro médio absoluto correspondeu ao erro associado a 75%, sendo que para os menores horizontes ele manteve-se acima deste valor, e para os maiores horizontes, um pouco abaixo.

Os resultados dos valores de nível calculado e observado, para os 5 horizontes, estão apresentados nas Figuras 5.10 a 5.14, onde são apresentados, para cada horizonte, os dados em seu ordenamento original. Nestes gráficos, é possível comprovar visualmente o decaimento da qualidade dos resultados em função do aumento do horizonte de previsão.

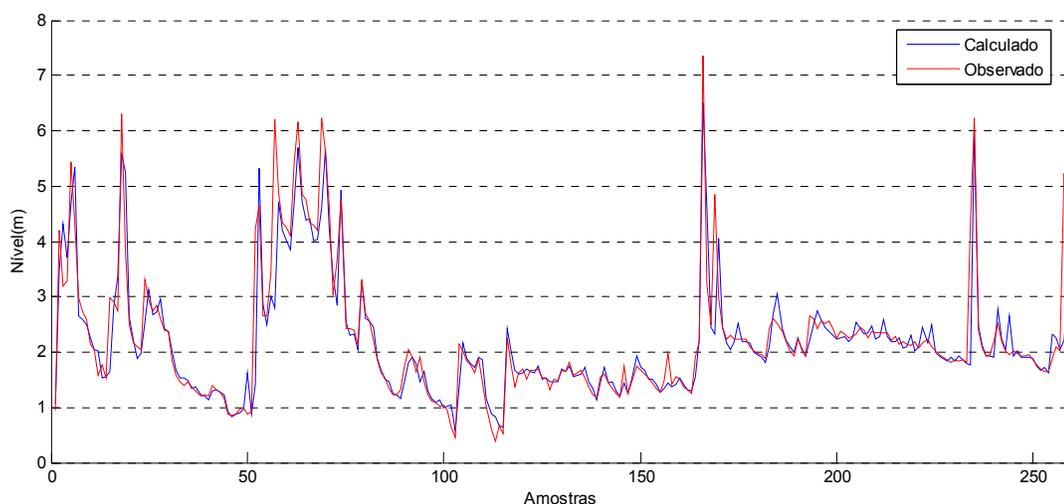


Figura 5.10 – Previsões e observações para horiz. de 1 dia – ordem original – COM previsão de chuva.

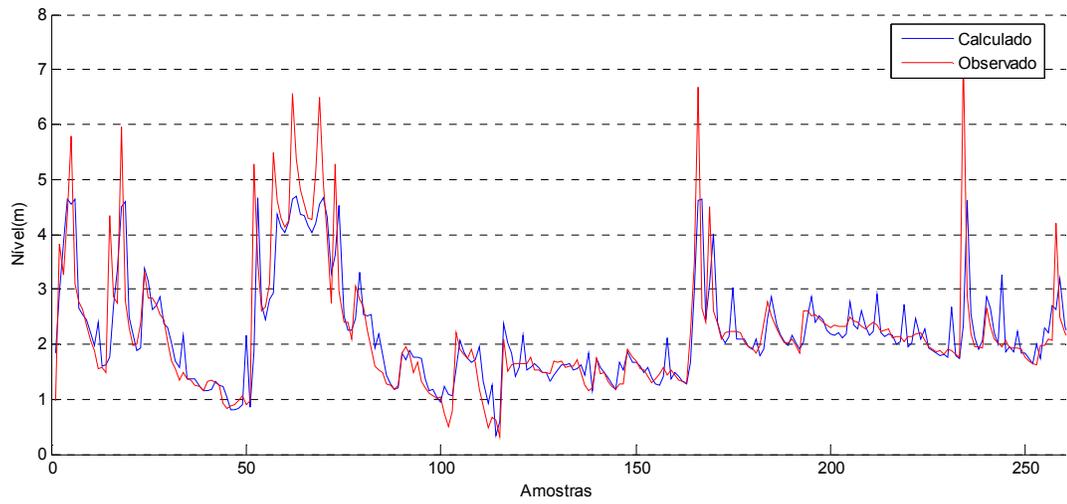


Figura 5.11 – Previsões e observações para horiz. de 2 dias – ordem original – COM previsão de chuva.

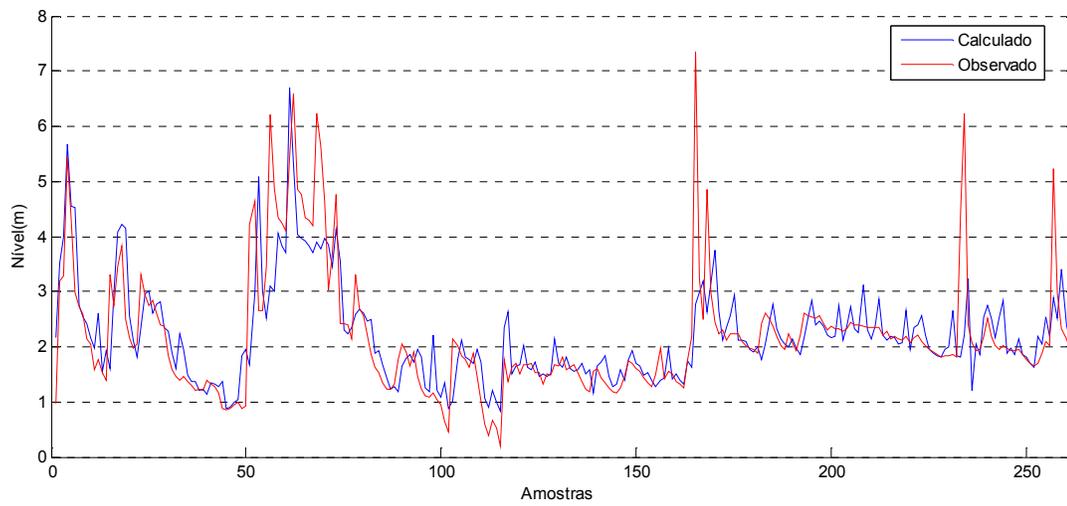


Figura 5.12 – Previsões e observações para horiz. de 3 dias – ordem original – COM previsão de chuva.

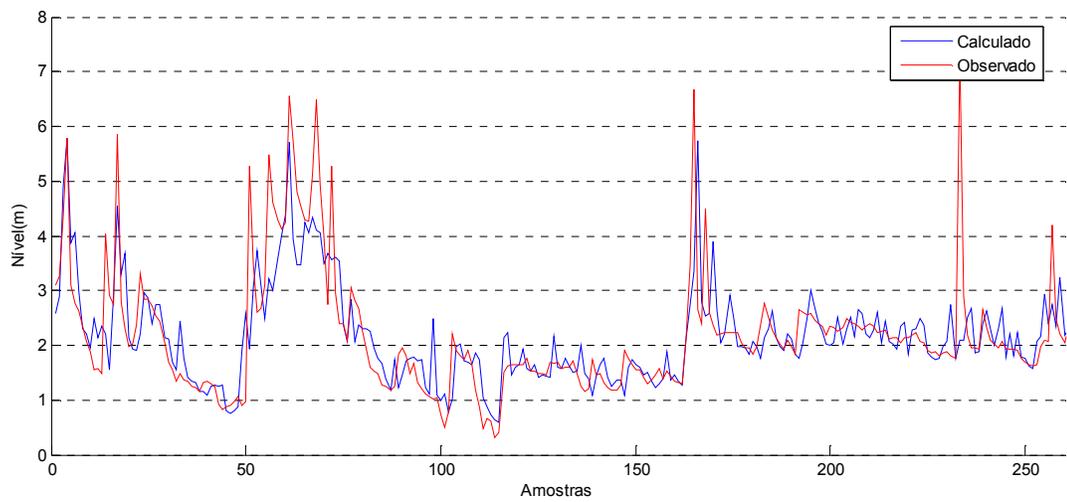


Figura 5.13 – Previsões e observações para horiz. de 4 dias – ordem original – COM previsão de chuva.

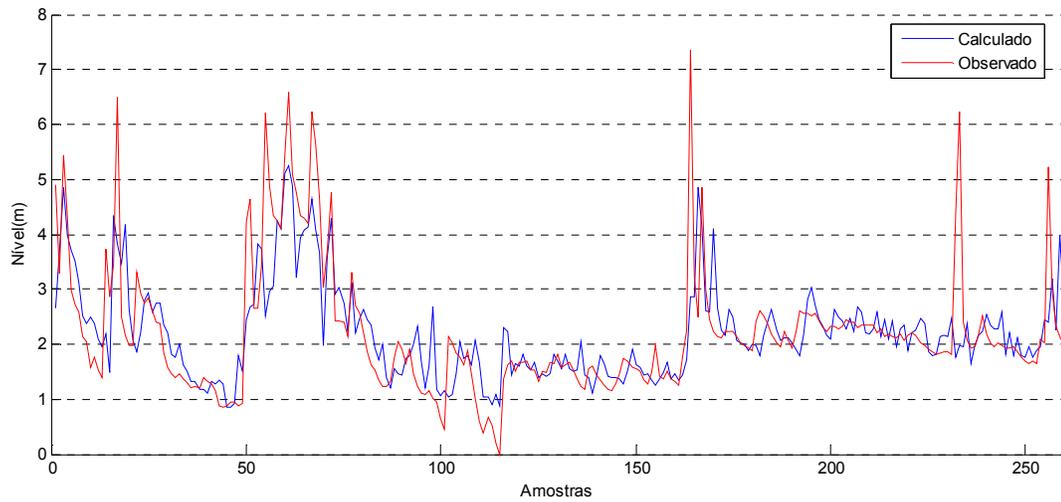


Figura 5.14 – Previsões e observações para horiz. de 5 dias – ordem original – COM previsão de chuva.

A análise dos gráficos na ordem original dos dados, em uma primeira instância, pode indicar uma falsa qualidade dos resultados obtidos pelo modelo.

Uma maneira de se avaliar os erros de previsão de nível para os eventos com maior magnitude, é graficar o nível previsto em função da magnitude do nível que o modelo deveria informar (nível observado).

Nas Figuras 5.15 a 5.19, são apresentados os gráficos ordenados em função do nível observado. Neles é possível verificar que, justamente para os níveis mais altos, os de especial interesse em um sistema de previsão de cheias, o modelo não responde com a precisão desejada, permitindo definir a região de confiança de resposta do modelo.

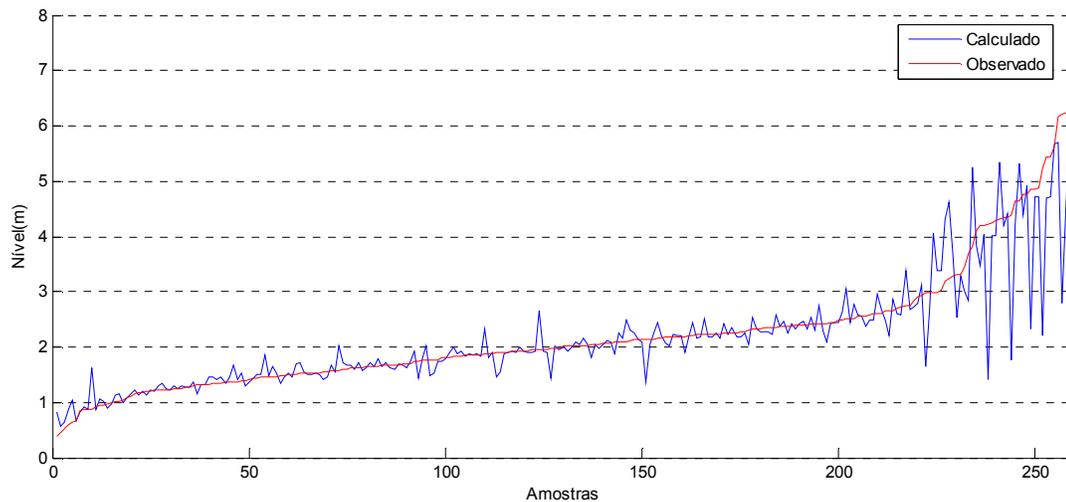


Figura 5.15 – Previsões e observações para horiz. de 1 dia – ordem crescente – COM previsão de chuva.

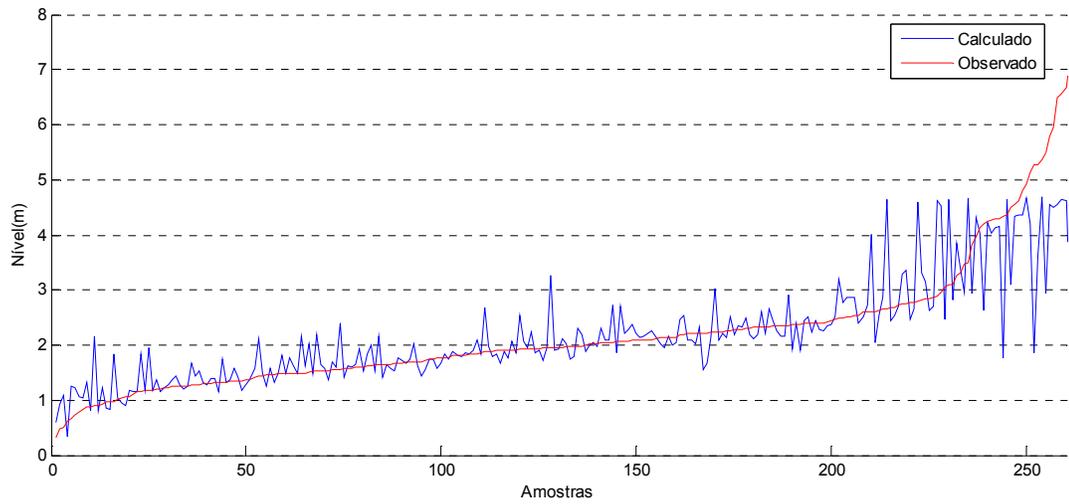


Figura 5.16 – Previsões e observações para horiz. de 2 dias – ordem crescente – COM previsão de chuva.

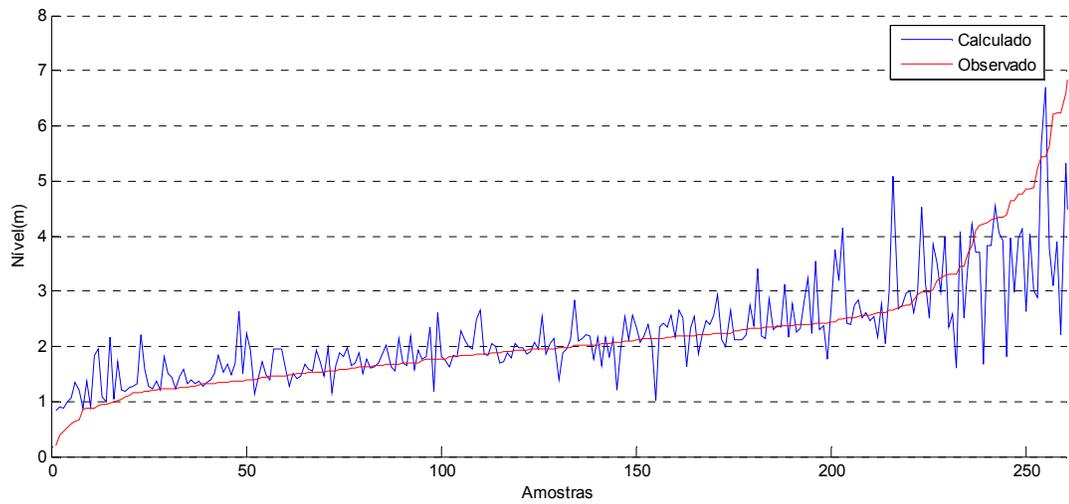


Figura 5.17 – Previsões e observações para horiz. de 3 dias – ordem crescente – COM previsão de chuva.

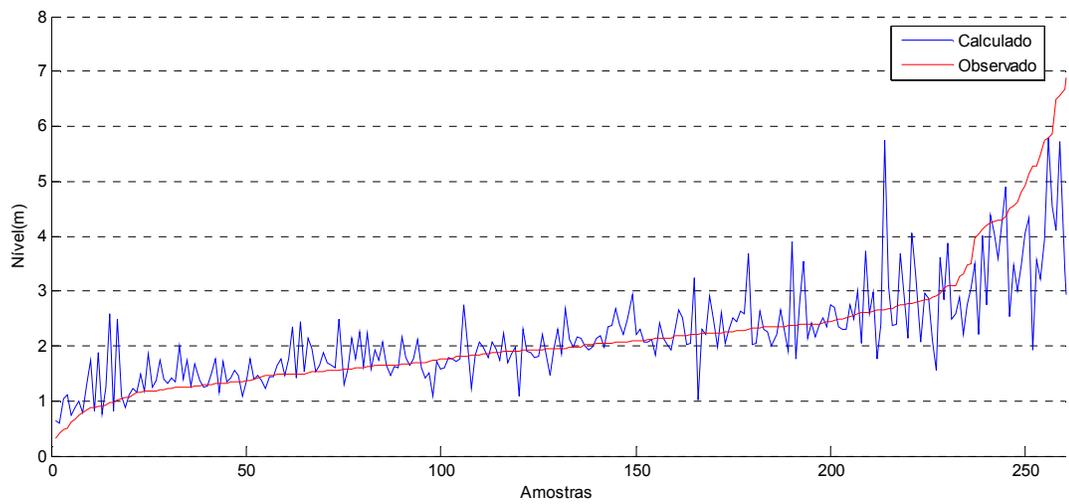


Figura 5.18 – Previsões e observações para horiz. de 4 dias – ordem crescente – COM previsão de chuva.

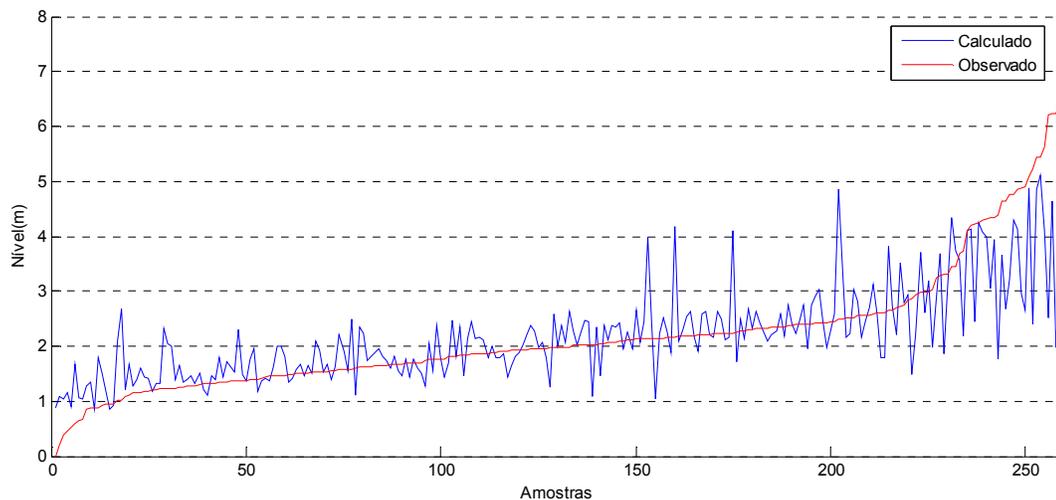


Figura 5.19 – Previsões e observações para horiz. de 5 dias – ordem crescente – COM previsão de chuva.

Os gráficos com níveis observados em ordem crescente mostram, claramente, o aumento da imprecisão das previsões para níveis superiores a 3 metros. Para os níveis mais próximos ao nível médio observado (aproximadamente 2,20 m), os resíduos de previsão de nível foram menores, dando credibilidade ao modelo de previsão para estas magnitudes. Porém, é evidente que a previsão de nível, com fins de incorporar um sistema de alerta de inundações, deva ter um bom desempenho, especialmente em níveis elevados. O treinamento do modelo de redes neurais, realizado com os dados disponíveis, não proporcionou uma qualidade suficiente para previsão, não apresentando a exatidão desejada para os picos.

A Figura 5.20 mostra dois histogramas, um para a amostra de treinamento e outra para a amostra de verificação, onde é possível visualizar o número de registros de níveis observados para os blocos de classe que cobrem todo o espectro. Nota-se, também, o que reforça a informação contida na Tabela 4.3, que os histogramas comprovam a homogeneidade entre as amostras. Assim, o treinamento foi fortemente influenciado pelo maior número de registros nas faixas de nível próximas à média. O resultado para as demais faixas ficou prejudicado, pois a experiência com as situações extremas não foi suficiente para criar um treinamento eficiente.

A causa mais evidente que colaborou para que o treinamento não obtivesse o desempenho desejado foi a escassez amostral dos dados nos limites extremos, identificada pela distribuição de frequências, que mostra os poucos cenários com níveis extremos (acima de ~3,5 m), constituindo assim, uma região de pseudo-extrapolação, onde a qualidade dos resultados da rede neural é bastante prejudicada.

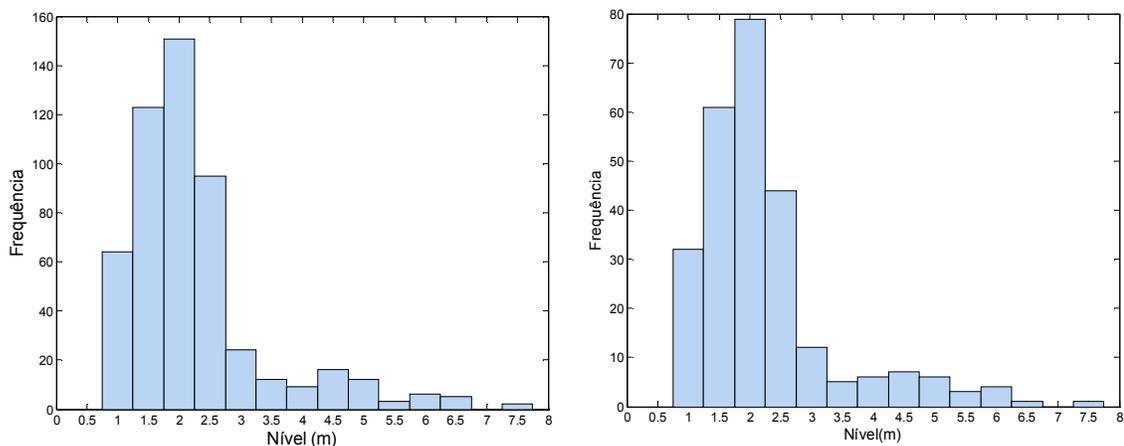


Figura 5.20 – Histogramas para as amostras de treinamento e verificação

Análise dos erros por “Alerta Falso” e “Incapacidade de Previsão”

Nas Tabelas 5.13 a 5.22 estão selecionados os 4 maiores erros por “Alerta Falso” e “Incapacidade de Previsão”. Nas duas últimas colunas estão os valores observados e os calculados, marcados em negrito. São apresentados, também, os dados de entrada do modelo correspondentes aos níveis calculados e observados. Os níveis (N) estão expressos em metros, e as previsões de precipitação (P) estão apresentadas em milímetros.

Tabela 5.13 - Maiores erros por “Alerta Falso” – Horiz. 1 dia – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	$P_{(i)}$	$N_{(i+1)}$	Prev. 1º dia	Erro (m)
6,301	5,962	0,1	3,836	5,262	1,426
7,360	6,690	0,0	3,250	4,618	1,368
4,192	3,828	10,7	3,203	4,311	1,109
4,843	4,512	0,0	2,986	4,068	1,082

Tabela 5.14 - Maiores erros por “Incapacidade de Previsão” – Horiz. 1 dia – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	$P_{(i)}$	$N_{(i+1)}$	Prev. 1º dia	Erro (m)
3,462	3,102	0,0	6,200	2,807	-3,393
2,030	2,066	17,2	5,229	2,213	-3,015
0,919	0,964	25,3	4,233	1,425	-2,808
1,824	1,775	0,0	4,378	1,754	-2,623

Tabela 5.15 - Maiores erros por “Alerta Falso” – Horiz. 2 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	Prev. 2º dia	Erro (m)
7,360	6,690	0,0	3,250	2,665	4,644	1,979
6,301	5,962	0,1	3,836	2,790	4,593	1,803
4,378	7,295	0,0	6,239	2,880	4,621	1,741
3,684	5,275	2,3	4,769	2,960	4,529	1,569

Tabela 5.16 - Maiores erros por “Incapacidade de Previsão” – Horiz. 2 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	Prev. 2º dia	Erro (m)
1,824	1,775	20,3	4,378	7,295	2,355	-4,940
0,919	0,964	26,2	4,233	5,272	1,857	-3,415
1,490	1,454	9,8	2,976	4,332	1,762	-2,571
3,462	3,102	6,2	6,200	5,485	2,931	-2,554

Tabela 5.17 - Maiores erros por “Alerta Falso” – Horiz. 3 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	$P_{(i)}$	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	Prev. 3° dia	Erro (m)
4,233	5,272	30,6	4,648	3,490	2,658	5,092	2,434
6,301	5,962	1,4	3,836	2,790	2,501	4,158	1,657
5,441	5,778	12,6	4,311	3,100	2,985	4,524	1,539
4,843	4,512	0,0	2,986	2,610	2,445	3,764	1,319

Tabela 5.18 - Maiores erros por “Incapacidade de Previsão” – Horiz. 3 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	Prev. 3° dia	Erro (m)
1,902	2,217	44,5	2,186	3,473	7,360	3,173	-4,588
1,824	1,775	20,3	4,378	7,295	6,239	2,214	-4,031
2,644	2,673	18,1	3,462	3,102	6,200	3,037	-3,093
0,888	0,894	24,5	0,919	0,964	4,233	1,678	-2,555

Tabela 5.19 - Maiores erros por “Alerta Falso” – Horiz. 4 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	Prev. 4° dia	Erro (m)
2,186	3,473	72,1	7,360	6,690	3,250	2,665	5,742	3,077
0,999	1,069	40,4	0,888	0,894	0,919	0,964	2,576	1,611
4,843	4,512	0,0	2,986	2,610	2,445	2,377	3,903	1,526
1,116	1,111	54,8	1,078	1,074	1,161	1,008	2,500	1,491

Tabela 5.20 - Maiores erros por “Incapacidade de Previsão” – Horiz. 4 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	$P_{(i)}$	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	Prev. 4° dia	Erro (m)
1,859	1,820	18,6	1,824	1,775	4,378	7,295	2,099	-5,196
0,888	0,894	30,5	0,919	0,964	4,233	5,272	1,919	-3,353
1,902	2,217	44,5	2,186	3,473	7,360	6,690	3,352	-3,338
4,30	4,27	8,2	4,208	5,137	6,230	6,480	4,099	-2,380

Tabela 5.21 - Maiores erros por “Alerta Falso” – Horiz. 5 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	$N_{(i+5)}$	Prev. 5° dia	Erro (m)
2,186	3,473	72,1	7,360	6,690	3,250	2,665	2,491	4,851	2,361
6,301	5,962	1,4	3,836	2,790	2,501	2,293	2,163	4,186	2,022
4,843	4,512	0,3	2,986	2,610	2,445	2,377	2,245	4,115	1,870
5,229	4,192	0,0	2,993	2,481	2,329	2,208	2,134	3,980	1,846

Tabela 5.22 - Maiores erros por “Incapacidade de Previsão” – Horiz. 5 dias – COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	$N_{(i+5)}$	Prev. 5° dia	Erro (m)
1,250	1,338	65,7	1,902	2,217	2,186	3,473	7,360	2,499	-4,503
1,859	1,820	18,6	1,824	1,775	4,378	7,295	6,239	1,910	-4,268
2,658	2,605	7,3	2,644	2,673	3,462	3,102	6,200	2,436	-3,675
1,876	1,980	38,2	2,090	2,086	2,030	2,066	5,229	2,479	-2,836

Ao analisar os maiores erros por “Alerta Falso” e “Incapacidade de Previsão” é possível verificar a ineficiência do modelo em identificar variações abruptas no nível do rio.

Os erros por “Incapacidade de Previsão” apresentaram maiores valores que os por “Alerta Falso”, mostrando novamente que o treinamento adquirido pelo modelo para prever níveis extremos não foi suficiente por falta de informações na amostra de dados disponível. Os maiores erros de “Alerta Falso” tiveram magnitudes moderadas de nível a ser previsto, ao

contrário do erro por “Incapacidade de Previsão”, onde as magnitudes foram sempre mais altas.

A influência dos níveis observados na previsão do nível, para todos os horizontes de previsão, é o que rege na prática a magnitude do nível a ser previsto. Contudo, em uma análise preliminar, observa-se que a previsão de precipitação também contribui, com uma importância menor, no resultado do modelo.

Nas Figuras A1 a A5 (Anexo 1), são apresentadas as superfícies de resultado das redes neurais treinadas com o uso de previsão de precipitação. Nelas, é possível conhecer o comportamento do modelo em função das suas variáveis de entrada. Os dois níveis anteriores observados estão representados nos eixos horizontais, e para cada horizonte de previsão foram obtidos os resultados para previsões de chuva nula, 1/3 da máxima, 2/3 da máxima e a máxima chuva do conjunto de dados coletados do modelo ETA, totalizando 4 superfícies de resultado para cada horizonte de previsão de nível. Os intervalos de variação dos gráficos são compatíveis com os observados, e estão discretizados em 25cm, variando do nível 0 até o máximo observado, porém as combinações entre as variáveis extrapolam a diversidade de condições contidas na amostra de dados disponível.

Na Figura 5.21 estão apresentadas as contagens das combinações entre os dois níveis anteriores de entrada do modelo para uma malha discretizada em 25 cm. Nota-se um forte alinhamento das contagens seguindo a bissetriz do primeiro quadrante cartesiano e uma densidade acentuada próximo ao valor médio dos níveis observados (2,20 m).

O baixo desempenho do modelo em prever mudanças bruscas nos níveis se dá pela falta de combinações fora do eixo da bissetriz para efetivar um treinamento nestas situações.

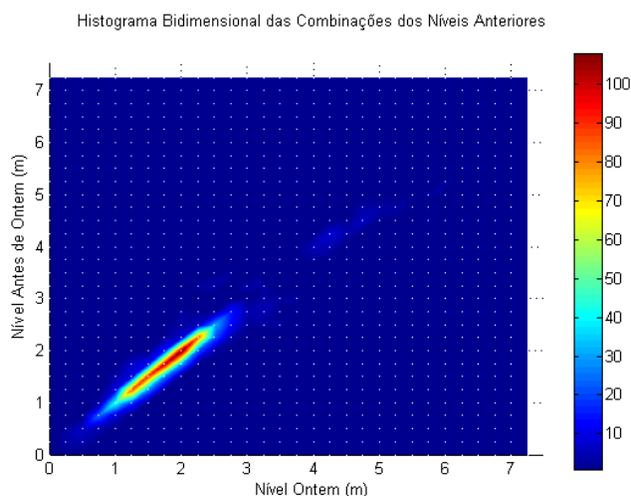


Figura 5.21 – Histograma bidimensional da contagem de combinações entre os níveis anteriores observados (entrada do modelo).

O formato das superfícies para os diferentes volumes de precipitação prevista mostra a influência que esta variável tem na resposta do modelo, amplificando o nível previsto para observações anteriores baixas.

Não é possível extrair mais nenhuma informação do comportamento em relação ao formato da superfície, por sua maior parcela estar em região de extrapolação, onde os resultados do modelo não podem ser verificados.

5.3 Análise da Influência do Uso de Previsão de Precipitação no Modelo de Redes Neurais

5.3.1 Resultados da eleição da arquitetura da rede neural SEM uso de previsão de chuva

Na primeira etapa, ao contrário do modelo que utilizou em sua entrada a previsão de precipitação, não foi possível fixar apenas um algoritmo de treinamento e uma única função de ativação da camada intermediária para todos os horizontes de previsão. Assim, foram fixados algoritmos e funções de ativação independentes para cada horizonte de previsão de nível (Tabelas 5.23 a 5.27).

Tabela 5.23 - Resultados para cada configuração de rede neural (horiz. 1 dia) – SEM previsão de chuva.

Arquitetura da RN	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,125	0,180	0,354	0,951	0,322	0,402	0,166	0,071	0,598
3N_Sat_GD	0,115	0,186	0,340	0,955	0,375	0,395	0,201	0,092	0,572
3N_Sat_GDM	0,128	0,190	0,358	0,950	0,305	0,423	0,197	0,091	0,283
3N_Sat_LM	0,130	0,178	0,360	0,948	0,298	0,401	0,166	0,072	0,554
3N_Tan_BR	0,121	0,179	0,349	0,951	0,341	0,448	0,181	0,067	0,622
3N_Tan_GD	0,132	0,198	0,364	0,948	0,283	0,393	0,195	0,094	0,157
3N_Tan_GDM	0,125	0,188	0,353	0,951	0,323	0,463	0,190	0,092	0,425
3N_Tan_LM	0,120	0,179	0,346	0,952	0,352	0,381	0,192	0,072	0,573
12N_Sat_BR	0,126	0,186	0,355	0,950	0,318	0,411	0,183	0,079	0,466
12N_Sat_GD	0,117	0,183	0,342	0,954	0,366	0,387	0,189	0,085	0,644
12N_Sat_GDM	0,120	0,185	0,347	0,953	0,348	0,372	0,187	0,083	0,574
12N_Sat_LM	0,137	0,187	0,370	0,946	0,258	0,403	0,173	0,076	0,291
12N_Tan_BR	0,120	0,174	0,347	0,952	0,347	0,411	0,166	0,067	0,795
12N_Tan_GD	0,115	0,181	0,338	0,955	0,379	0,407	0,192	0,083	0,688
12N_Tan_GDM	0,115	0,181	0,339	0,955	0,379	0,405	0,192	0,083	0,687
12N_Tan_LM	0,127	0,176	0,356	0,952	0,313	0,369	0,191	0,064	0,455

Tabela 5.24 - Resultados para cada configuração de rede neural (horiz. 2 dias) – SEM previsão de chuva.

Arquitetura da RN	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,475	0,362	0,690	0,790	0,283	0,800	0,331	0,174	0,629
3N_Sat_GD	0,469	0,366	0,685	0,792	0,292	0,760	0,347	0,170	0,527
3N_Sat_GDM	0,465	0,366	0,682	0,794	0,298	0,778	0,344	0,175	0,568
3N_Sat_LM	0,463	0,352	0,680	0,796	0,302	0,875	0,322	0,169	0,753
3N_Tan_BR	0,483	0,361	0,695	0,785	0,272	0,767	0,334	0,169	0,537
3N_Tan_GD	0,472	0,368	0,687	0,790	0,288	0,838	0,346	0,173	0,508
3N_Tan_GDM	0,480	0,369	0,693	0,786	0,275	0,820	0,336	0,175	0,507
3N_Tan_LM	0,516	0,366	0,718	0,769	0,222	0,845	0,329	0,180	0,342
12N_Sat_BR	0,476	0,339	0,690	0,791	0,282	0,865	0,309	0,132	0,794
12N_Sat_GD	0,463	0,368	0,680	0,795	0,301	0,759	0,363	0,180	0,470
12N_Sat_GDM	0,542	0,365	0,736	0,764	0,182	0,971	0,328	0,144	0,216
12N_Sat_LM	0,484	0,357	0,695	0,786	0,271	0,878	0,327	0,158	0,584
12N_Tan_BR	0,487	0,358	0,698	0,783	0,266	0,831	0,344	0,161	0,467
12N_Tan_GD	0,478	0,372	0,691	0,788	0,279	0,837	0,362	0,166	0,369
12N_Tan_GDM	0,455	0,364	0,674	0,799	0,314	0,810	0,356	0,179	0,575
12N_Tan_LM	0,451	0,350	0,672	0,802	0,319	0,855	0,329	0,157	0,796

Tabela 5.25 - Resultados para cada configuração de rede neural (horiz. 3 dias) – SEM previsão de chuva.

Arquitetura da RN	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,659	0,420	0,812	0,697	0,315	0,983	0,424	0,185	0,379
3N_Sat_GD	0,665	0,448	0,815	0,692	0,309	1,051	0,476	0,216	0,228
3N_Sat_GDM	0,646	0,440	0,804	0,703	0,328	0,954	0,462	0,228	0,436
3N_Sat_LM	0,655	0,403	0,810	0,706	0,318	0,955	0,391	0,165	0,622
3N_Tan_BR	0,676	0,409	0,822	0,693	0,297	1,020	0,481	0,147	0,227
3N_Tan_GD	0,659	0,445	0,812	0,695	0,314	0,993	0,484	0,228	0,262
3N_Tan_GDM	0,645	0,441	0,803	0,703	0,329	0,840	0,487	0,230	0,384
3N_Tan_LM	0,627	0,421	0,792	0,716	0,348	0,905	0,472	0,196	0,627
12N_Sat_BR	0,679	0,432	0,824	0,685	0,294	0,951	0,473	0,188	0,151
12N_Sat_GD	0,635	0,444	0,797	0,709	0,340	0,877	0,526	0,224	0,381
12N_Sat_GDM	0,640	0,440	0,800	0,706	0,334	0,967	0,468	0,223	0,471
12N_Sat_LM	0,652	0,399	0,807	0,718	0,322	0,946	0,420	0,150	0,635
12N_Tan_BR	0,668	0,420	0,817	0,696	0,306	0,950	0,424	0,206	0,395
12N_Tan_GD	0,631	0,437	0,794	0,711	0,344	0,873	0,449	0,233	0,597
12N_Tan_GDM	0,616	0,431	0,785	0,719	0,359	0,916	0,457	0,219	0,719
12N_Tan_LM	0,645	0,395	0,803	0,710	0,329	0,963	0,401	0,142	0,696

Tabela 5.26 - Resultados para cada configuração de rede neural (horiz. 4 dias) – SEM previsão de chuva.

Arquitetura da RN	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,797	0,487	0,893	0,643	0,307	1,018	0,555	0,227	0,333
3N_Sat_GD	0,775	0,513	0,881	0,648	0,326	1,068	0,586	0,288	0,269
3N_Sat_GDM	0,772	0,512	0,879	0,650	0,329	1,072	0,586	0,297	0,298
3N_Sat_LM	0,796	0,480	0,892	0,644	0,308	1,071	0,560	0,200	0,272
3N_Tan_BR	0,780	0,492	0,883	0,647	0,322	1,056	0,558	0,246	0,351
3N_Tan_GD	0,782	0,516	0,885	0,644	0,320	1,035	0,596	0,293	0,184
3N_Tan_GDM	0,795	0,517	0,892	0,636	0,309	1,098	0,557	0,290	0,175
3N_Tan_LM	0,748	0,490	0,865	0,664	0,350	1,074	0,520	0,272	0,689
12N_Sat_BR	0,730	0,490	0,854	0,674	0,366	1,030	0,539	0,257	0,788
12N_Sat_GD	0,765	0,508	0,875	0,654	0,335	1,044	0,626	0,291	0,267
12N_Sat_GDM	0,729	0,498	0,854	0,676	0,366	1,098	0,525	0,280	0,809
12N_Sat_LM	0,792	0,485	0,890	0,645	0,311	1,036	0,540	0,230	0,333
12N_Tan_BR	0,775	0,467	0,880	0,658	0,327	1,136	0,501	0,206	0,609
12N_Tan_GD	0,733	0,494	0,856	0,674	0,362	1,063	0,567	0,278	0,685
12N_Tan_GDM	0,732	0,497	0,856	0,674	0,363	1,072	0,559	0,290	0,705
12N_Tan_LM	0,734	0,469	0,857	0,677	0,362	1,089	0,566	0,204	0,750

Tabela 5.27 - Resultados para cada configuração de rede neural (horiz. 5 dias) – SEM previsão de chuva.

Arquitetura da RN	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	NP
3N_Sat_BR	0,804	0,498	0,897	0,638	0,305	1,065	0,586	0,242	0,326
3N_Sat_GD	0,755	0,523	0,869	0,650	0,347	1,155	0,632	0,307	0,277
3N_Sat_GDM	0,754	0,527	0,868	0,650	0,348	1,147	0,659	0,309	0,204
3N_Sat_LM	0,765	0,502	0,874	0,650	0,339	1,112	0,589	0,269	0,386
3N_Tan_BR	0,765	0,514	0,875	0,643	0,338	1,088	0,606	0,291	0,306
3N_Tan_GD	0,756	0,526	0,870	0,649	0,346	1,133	0,611	0,302	0,312
3N_Tan_GDM	0,783	0,532	0,885	0,632	0,323	1,194	0,600	0,313	0,208
3N_Tan_LM	0,767	0,493	0,876	0,645	0,337	1,129	0,535	0,260	0,520
12N_Sat_BR	0,771	0,503	0,878	0,642	0,333	1,210	0,596	0,246	0,331
12N_Sat_GD	0,719	0,514	0,848	0,670	0,378	1,156	0,631	0,295	0,449
12N_Sat_GDM	0,702	0,508	0,838	0,682	0,393	1,106	0,573	0,315	0,676
12N_Sat_LM	0,678	0,486	0,823	0,694	0,414	1,083	0,580	0,269	0,811
12N_Tan_BR	0,737	0,475	0,858	0,666	0,363	1,085	0,558	0,238	0,640
12N_Tan_GD	0,707	0,511	0,841	0,678	0,389	1,068	0,606	0,307	0,572
12N_Tan_GDM	0,727	0,516	0,853	0,666	0,371	1,124	0,604	0,318	0,475
12N_Tan_LM	0,781	0,489	0,884	0,654	0,324	1,182	0,552	0,216	0,456

Os resultados da 1ª etapa da seleção da arquitetura ótima para o modelo por redes neurais sem a agregação da previsão de precipitação mostraram que, para os horizontes de previsão de 3 e 4 dias, o algoritmo com melhor desempenho foi o TrainGDM, porém, sua vantagem em relação à segunda melhor arquitetura de rede neural não foi significativa. Por não apresentar vantagem significativa, e ser um algoritmo com convergência muito lenta, foi utilizado o algoritmo TrainLM, que foi a segunda melhor arquitetura nos dois casos.

Seguindo a mesma metodologia do modelo por redes neurais com previsão de precipitação agregada, realizou-se a eleição da 2ª etapa, na qual foram obtidas as arquiteturas

finais ótimas (Tabela 5.28), dentre as 140 combinações possíveis dos parâmetros selecionados para serem experimentados.

Tabela 5.28 – Arquiteturas ótimas de rede neural para o modelo SEM uso de previsão de chuva.

Horizonte Previsão	Algoritmo	Nº Neurônios	μ (Incremento)	μ (Decremento)	Nº Falhas na Validação Cruzada	Função de Ativação
Dia 1	TRAINBR	8	60	0,60	10	TANSIG
Dia 2	TRAINLM	8	5	0,05	500	TANSIG
Dia 3	TRAINLM	32	60	0,60	200	TANSIG
Dia 4	TRAINLM	32	5	0,5	200	TANSIG
Dia 5	TRAINLM	32	100	1,00	50	SATLIN

5.3.2 Resultados do modelo de previsão de nível SEM previsão de chuva para as arquiteturas ótimas

Após a escolha da rede neural, considerada ótima para o modelo de previsão de níveis, apenas com entradas de níveis observados anteriormente (sem previsão de chuva), foram extraídos os resultados de previsão para os dados da amostra de verificação.

Foi observado, nos resultados apresentados na Tabela 5.29, que a qualidade da previsão de nível piora com o aumento do horizonte de previsão, exceto para os horizontes de 4 e 5 dias, onde o método de nota ponderada beneficiou o 5º dia por ele apresentar um alto valor para o coeficiente de persistência (CP), considerando-se a previsão para o 5º dia ligeiramente melhor que para o 4º dia. Considerando a pequena diferença entre os resultados dos dois maiores horizontes de previsão, é possível que isso deva-se apenas à própria parcela aleatória presente na saída do modelo, não sendo garantido que este comportamento ocorra para outros conjuntos de dados.

Tabela 5.29 - Resultados para a amostra de verificação – modelo RN SEM previsão de chuva.

Horizonte	EMQ (m²)	EMA (m)	EPA (m)	R	CP	Erro não ultrapassado 90% (m)	Erro não ultrapassado 75% (m)	Erro não ultrapassado 50% (m)	Nota
Dia 1	0,313	0,238	0,560	0,874	0,216	0,419	0,174	0,094	0,824
Dia 2	0,513	0,338	0,716	0,774	0,310	0,704	0,318	0,135	0,619
Dia 3	0,629	0,416	0,793	0,716	0,357	0,993	0,410	0,170	0,446
Dia 4	0,814	0,473	0,902	0,637	0,257	0,975	0,545	0,213	0,124
Dia 5	0,833	0,507	0,913	0,643	0,314	1,080	0,574	0,246	0,126

Os resultados mostrados na Tabela 5.30 foram obtidos das respostas dos modelos por rede neural para a amostra de verificação, e estão dispostos de forma a permitir a comparação dos resultados deste modelo, que utiliza em sua entrada a previsão de precipitação, e o que não a utiliza. As notas contidas na ultima coluna à direita são referentes à avaliação relativa entre os resultados, para o mesmo horizonte de previsão de nível, do modelo que utiliza a previsão de precipitação e do que não a utiliza.

A utilização de previsão de chuva na entrada melhorou a qualidade da previsão de nível para todos os 5 horizontes, porém, com uma pequena vantagem. A diferença entre as notas ponderadas para cada horizonte indica o grau de melhora relativa incrementado à previsão de nível com a utilização da previsão de chuva na entrada do modelo, conforme observa-se nos índices apresentados, da Tabela 5.30.

Tabela 5.30 – Resultados para a amostra de verificação – modelos RN COM e SEM previsão de chuva.

Horizonte	EMQ (m ²)	EMA (m)	EPA (m)	R	CP	Erro 90% (m)	Erro 75% (m)	Erro 50% (m)	EMQ (m ²)	Nota
Dia 1	Com ETA	0,255	0,227	0,505	0,899	0,361	0,480	0,204	0,079	0,706
	Sem ETA	0,313	0,238	0,560	0,874	0,216	0,419	0,174	0,094	0,294
Dia 2	Com ETA	0,436	0,345	0,660	0,812	0,414	0,795	0,333	0,157	0,529
	Sem ETA	0,513	0,338	0,716	0,774	0,310	0,704	0,318	0,135	0,471
Dia 3	Com ETA	0,546	0,422	0,739	0,757	0,442	0,946	0,486	0,207	0,706
	Sem ETA	0,629	0,416	0,793	0,716	0,357	0,993	0,410	0,170	0,294
Dia 4	Com ETA	0,545	0,425	0,738	0,759	0,503	0,991	0,515	0,219	0,765
	Sem ETA	0,814	0,473	0,902	0,637	0,257	0,975	0,545	0,213	0,235
Dia 5	Com ETA	0,637	0,477	0,798	0,735	0,475	1,073	0,541	0,276	0,941
	Sem ETA	0,833	0,507	0,913	0,643	0,314	1,080	0,574	0,246	0,059

Os resultados dos valores de nível calculado e observado, para os 5 horizontes, estão apresentados nas Figuras 5.22 a 5.26, onde são apresentados, para cada horizonte, os dados em seu ordenamento original. Os resultados do modelo de previsão com entrada de previsão de precipitação também estão inseridos nos gráficos, de maneira a permitir uma comparação com os resultados do modelo que não utiliza a previsão de chuva na entrada.

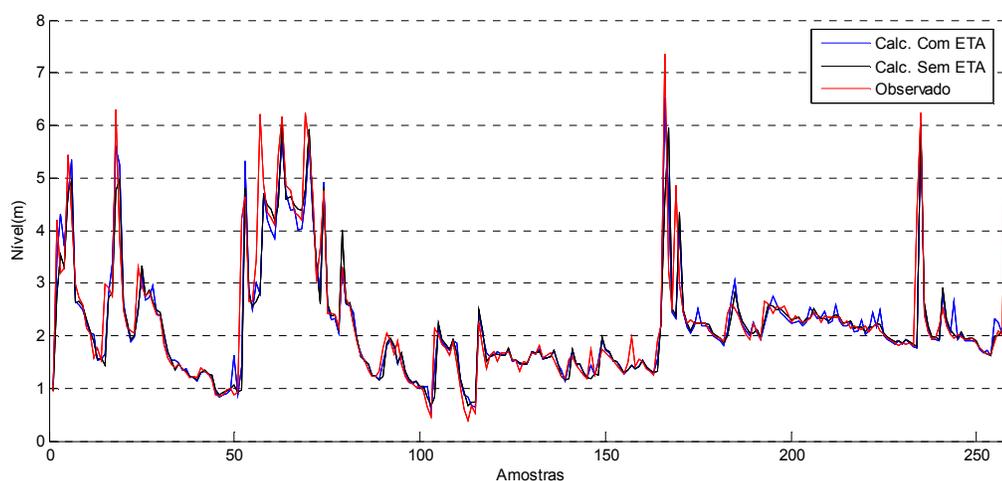


Figura 5.22 - Previsões e observações para horiz. 1 dia – ordem original – COM e SEM previsão de chuva.

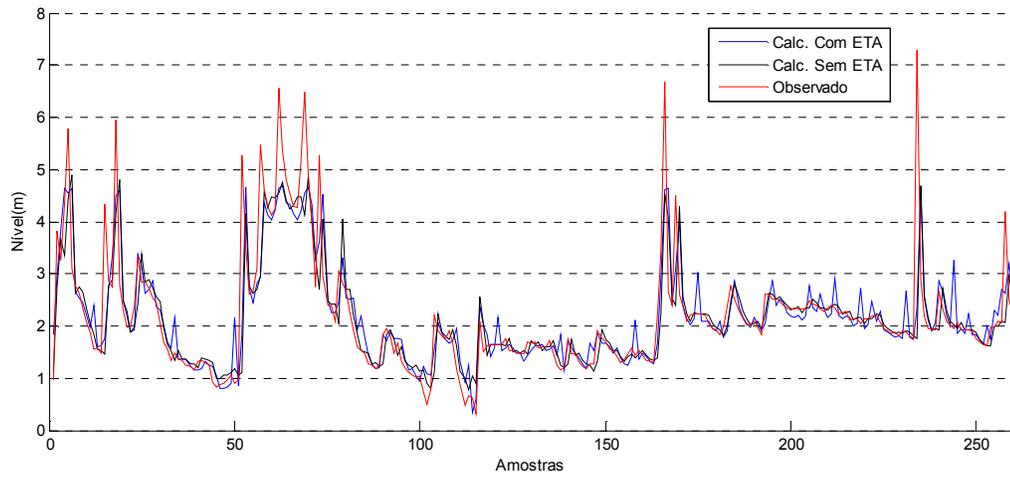


Figura 5.23 - Previsões e observações para horiz. 2 dias – ordem original – COM e SEM previsão de chuva.

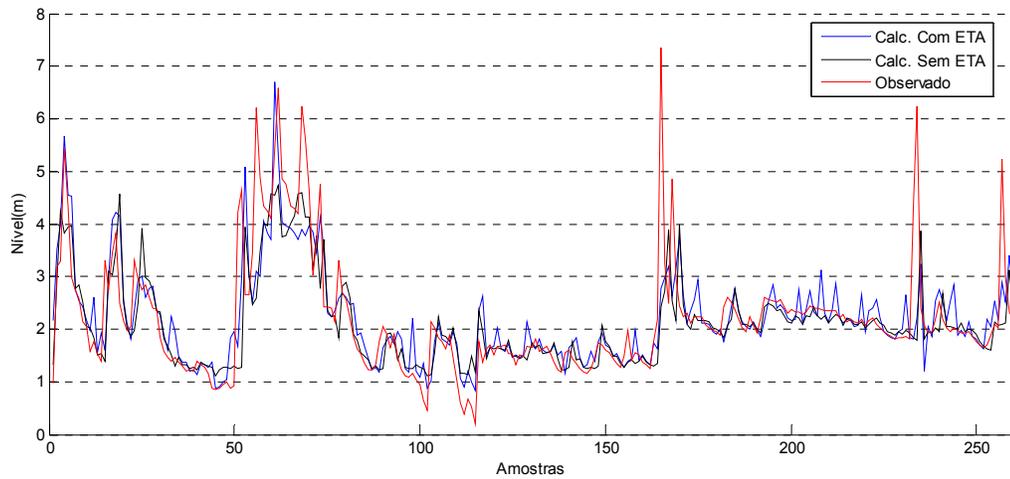


Figura 5.24 - Previsões e observações para horiz. 3 dias – ordem original – COM e SEM previsão de chuva.

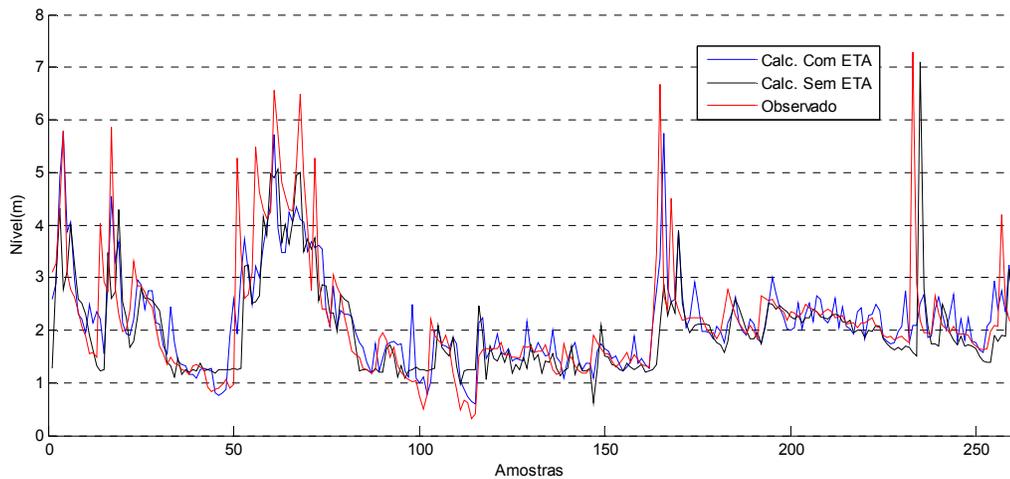


Figura 5.25 - Previsões e observações para horiz. 4 dias – ordem original – COM e SEM previsão de chuva.

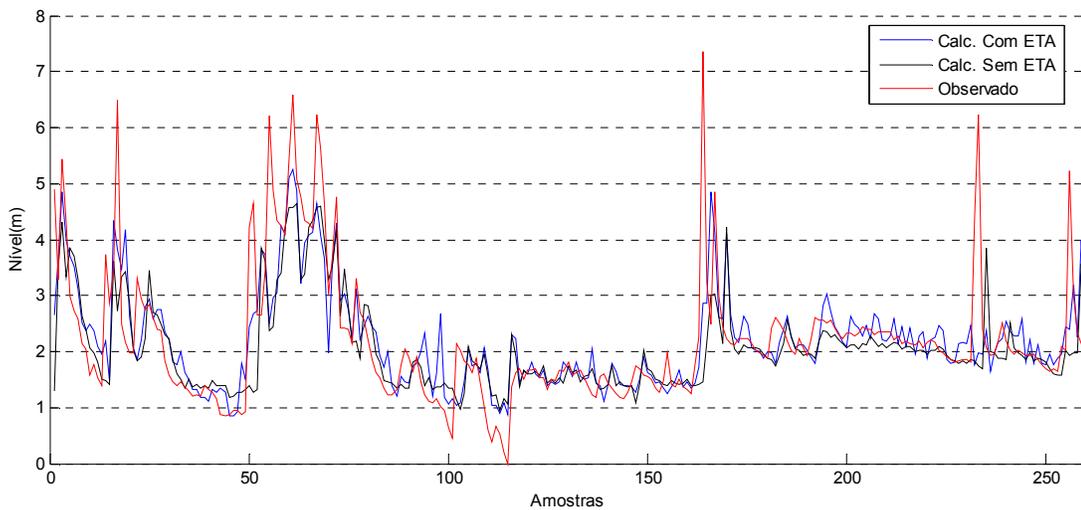


Figura 5.26 - Previsões e observações para horiz. 5 dias – ordem original – COM e SEM previsão de chuva.

Nas Figuras 5.27 a 5.31 são apresentados os resultados do modelo de redes neurais com utilização de previsão de precipitação e sem a sua utilização, em ordenamento crescente do nível a ser previsto, para, assim, possibilitar uma análise do erro em função da magnitude do nível de previsão que o modelo deva atingir.

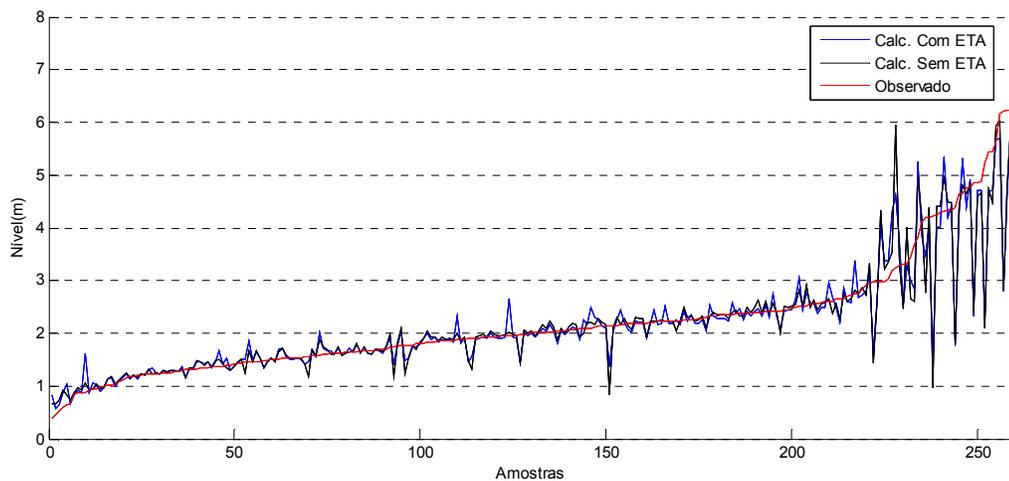


Figura 5.27 - Previsões e observações para horiz. 1 dia – ordem crescente – COM e SEM previsão de chuva.

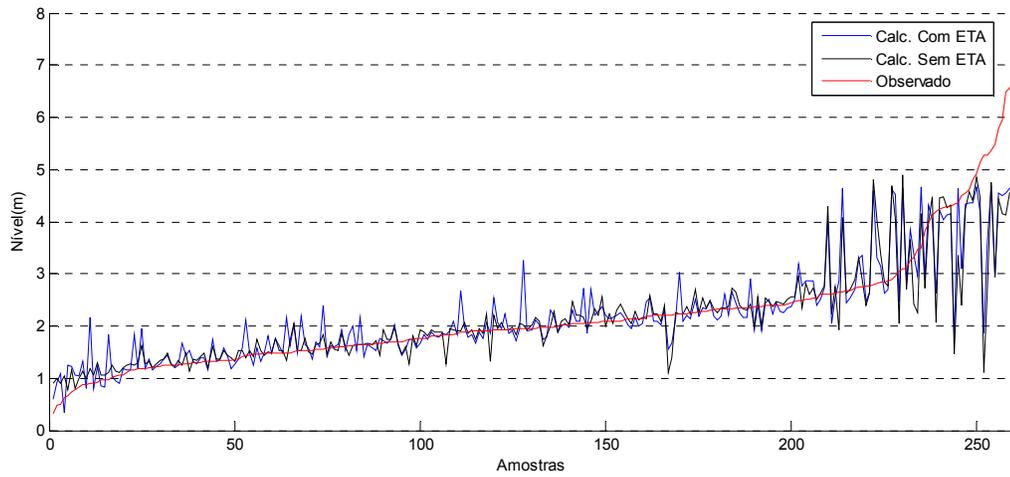


Figura 5.28 - Previsões e observações para horiz. 2 dias – ordem crescente – COM e SEM previsão de chuva.

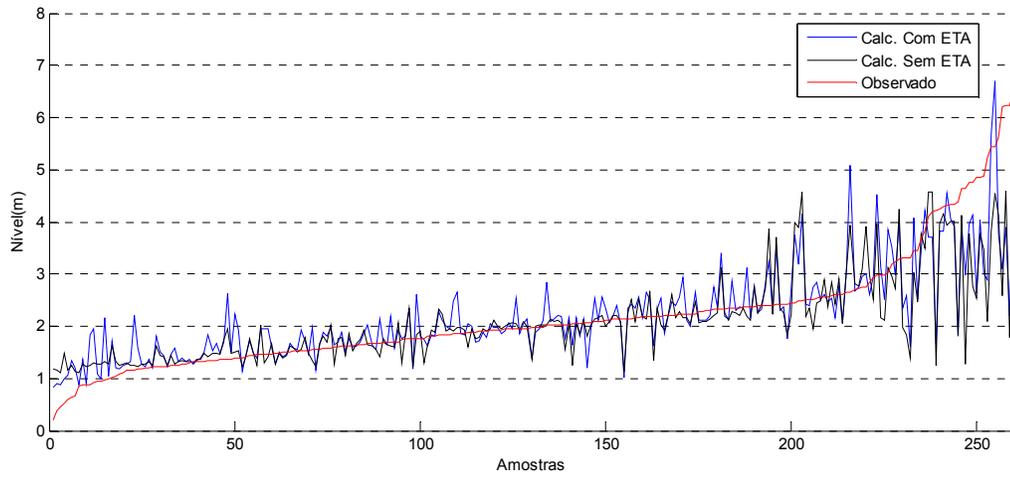


Figura 5.29 - Previsões e observações para horiz. 3 dias – ordem crescente – COM e SEM previsão de chuva.

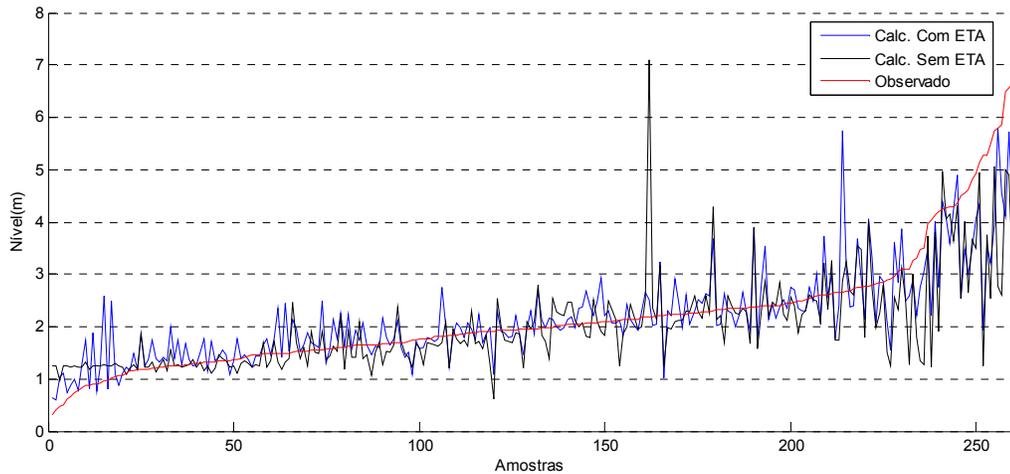


Figura 5.30 - Previsões e observações para horiz. 4 dias – ordem crescente – COM e SEM previsão de chuva.

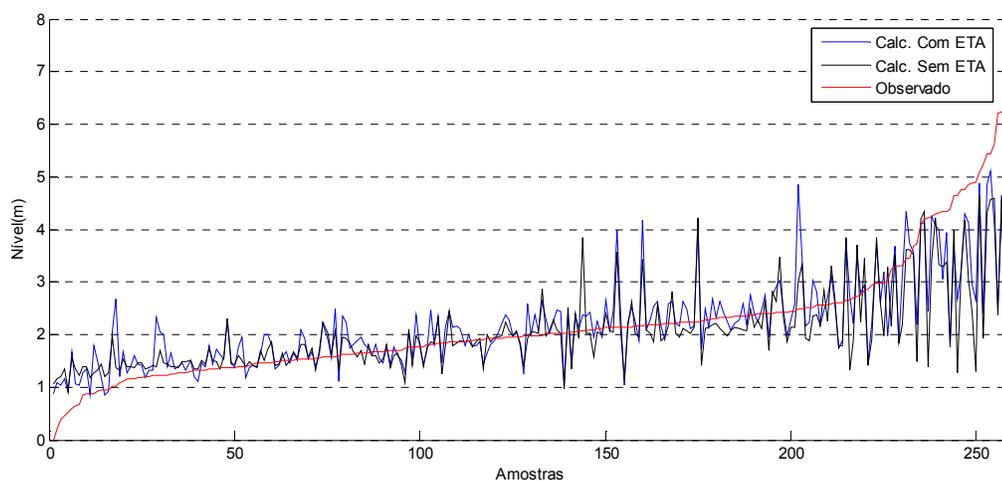


Figura 5.31 - Previsões e observações para horiz. 5 dias – ordem crescente – COM e SEM previsão de chuva.

Os resultados apresentados graficamente não permitem uma indicação clara de qual dos dois modelos é o mais confiável, ambos superestimam os níveis mínimos e subestimam os níveis máximos. Entretanto, nota-se uma maior distinção entre as respostas dos dois modelos com o aumento do horizonte de previsão. Como estas diferenças são pequenas, depende-se dos índices estatísticos para a indicação do modelo mais eficiente, que resultou sendo o que utiliza a previsão de precipitação. Esta pequena diferença dos resultados das alternativas de modelos, com e sem previsão de precipitação, possivelmente é causada pela incerteza das previsões de precipitação, que faz com que o modelo reduza a sua importância.

Em relação aos erros por “Alerta Falso” e “Incapacidade de Previsão”, o comportamento dos resíduos foi muito semelhante ao do modelo por redes neurais com o uso de previsão de precipitação, mostrando magnitudes de erro equivalentes para os mesmos horizontes de previsão. Esta análise não foi apresentada no presente trabalho por não acrescentar informação inédita.

Nas Figuras A6 a A10 (Anexo 2), são apresentadas as superfícies de resultado das redes neurais treinadas sem o uso da previsão de precipitação. Nelas, é possível conhecer o comportamento do modelo em função das suas variáveis de entrada. Da mesma forma que no item 5.2.3 os dois níveis anteriores observados estão representados nos eixos horizontais, e para cada horizonte de previsão foram obtidos os resultados para combinações entre as variáveis de entrada. Os intervalos de variação dos gráficos são compatíveis com os observados, e estão discretizados em 25 cm, variando do nível 0 até o máximo observado, porém as combinações entre as variáveis extrapolam a diversidade de condições contidas na amostra de dados disponível.

Não é possível observar mais nenhum comportamento notável a partir da análise do formato da superfície, por sua maior parcela estar em região de extrapolação, onde os resultados não podem ser verificados.

5.4 Análise Comparativa dos Resultados do Modelo de Regressão Multivariada com o de Redes Neurais

5.4.1 Resultados da eleição da configuração ótima do modelo de regressão

Na Tabela 5.31 são apresentados os resultados dos índices obtidos para o modelo por regressão linear multivariada para os 5 horizontes de previsão.

Tabela 5.31 – Resultados para cada modelo de previsão por regressão linear multivariada.

Horizonte	Modelo	EMQ (m)	EMA (m)	EPA (m)	R	CP	Erro 90% (m)	Erro 75% (m)	Erro 50% (m)	a0	a1	a2	a3	Nota (pond.)
1° dia	1	0,107	0,187	0,328	0,957	0,418	0,457	0,204	0,093	0,2722	-0,2529	1,0926	0,0316	0,721
	2	0,103	0,190	0,320	0,960	0,443	0,457	0,200	0,108	0,3547	-0,2450	1,0522	0,0468	0,780
	3	0,123	0,202	0,350	0,952	0,334	0,458	0,210	0,122	0,3761	-0,2668	1,0763	0,0318	0,319
	4	0,145	0,208	0,381	0,942	0,212	0,409	0,209	0,124	0,3312	-0,3199	1,1687		0,183
2° dia	1	0,390	0,368	0,624	0,831	0,412	0,880	0,413	0,192	0,5122	-0,0053	0,6847	0,0344	0,882
	2	0,417	0,375	0,646	0,819	0,371	0,921	0,378	0,223	0,7010	-0,0331	0,6513	0,0411	0,757
	3	0,521	0,395	0,722	0,766	0,214	0,991	0,390	0,194	0,7314	-0,0900	0,7306	0,0165	0,253
	4	0,557	0,398	0,746	0,747	0,160	0,884	0,375	0,212	0,6398	-0,1013	0,8054		0,309
3° dia	1	0,604	0,459	0,777	0,726	0,372	1,078	0,529	0,229	0,6201	0,1851	0,4181	0,0267	0,731
	2	0,613	0,465	0,783	0,721	0,362	1,092	0,505	0,270	0,8761	0,1480	0,3613	0,0366	0,667
	3	0,700	0,481	0,837	0,674	0,272	1,018	0,522	0,283	0,9364	0,1048	0,4298	0,0144	0,351
	4	0,754	0,483	0,868	0,640	0,216	0,989	0,488	0,275	0,7990	0,1139	0,5134		0,303
4° dia	1	0,738	0,526	0,859	0,669	0,358	1,096	0,706	0,272	0,6703	0,2312	0,3195	0,0231	0,841
	2	0,737	0,517	0,859	0,671	0,359	1,109	0,653	0,307	0,9897	0,1667	0,2827	0,0264	0,874
	3	0,866	0,545	0,931	0,594	0,247	1,183	0,596	0,335	0,8914	0,2105	0,3715	0,0007	0,132
	4	0,872	0,546	0,934	0,590	0,242	1,181	0,584	0,335	0,8698	0,2182	0,3766		0,121
5° dia	1	0,719	0,527	0,848	0,670	0,378	1,154	0,729	0,303	0,6825	0,2412	0,2899	0,0202	0,791
	2	0,708	0,526	0,841	0,679	0,388	1,165	0,664	0,340	1,0479	0,1697	0,2442	0,0230	0,827
	3	0,855	0,564	0,925	0,587	0,260	1,141	0,635	0,352	0,9174	0,2449	0,3263	0,0005	0,317
	4	0,861	0,565	0,928	0,583	0,255	1,187	0,638	0,349	0,8980	0,2510	0,3314		0,118

Verificou-se que a utilização do ponderador não resultou melhora significativa à previsão de nível. Pode-se concluir que os dois modelos de regressão, o que utiliza o ponderador, multiplicando (“U”) à previsão de precipitação, e o que utiliza a previsão de precipitação diretamente, são equivalentes.

Foi adotado, como o melhor modelo de regressão, o modelo 1, para os 5 horizontes de previsão de nível. A previsão de precipitação é utilizada diretamente, para todos os horizontes, sem o ponderador em função da magnitude do nível, para assim, comparar os resultados, para a amostra de verificação, com os do modelo por rede neural.

5.4.2 Resultados do modelo de regressão

Na etapa de eleição verificou-se que a utilização do ponderador não resultou em melhora significativa à previsão de nível. Pode-se concluir que os dois modelos de regressão, o que utiliza o ponderador, multiplicando (“U”) à previsão de precipitação, e o que utiliza a previsão de precipitação diretamente, são equivalentes.

A previsão de precipitação agregada ao modelo de regressão melhorou significativamente os seus resultados para todos os horizontes, obtendo-se índices de qualidade superiores ao do modelo que utiliza somente níveis observados 2 dias anteriores.

O modelo de regressão escolhido foi o modelo 1, onde a previsão de precipitação é utilizada diretamente, para todos os horizontes, sem o ponderador, em função da magnitude do nível. O modelo de regressão eleito foi aplicado à amostra de verificação que não foi utilizada em nenhuma das etapas, de treinamento (calibração) nem de validação/eleição, para que, assim, os resultados fossem comparados. Na Tabela 5.32 estão apresentados os resultados para os 5 horizontes de previsão.

Tabela 5.32 - Resultado para a amostra de verificação – modelo Regressão COM previsão de chuva.

Horizonte	EMQ	EMA	EPA	R	CP	Erro 90%	Erro 75%	Erro 50%	Nota
Dia 1	0,279	0,263	0,528	0,8878	0,3008	0,5290	0,2417	0,1133	0,665
Dia 2	0,483	0,382	0,695	0,7887	0,3499	0,8353	0,3943	0,1958	0,555
Dia 3	0,679	0,463	0,824	0,6899	0,3052	0,9856	0,4874	0,2338	0,421
Dia 4	0,803	0,508	0,896	0,6296	0,2668	1,1900	0,5445	0,2600	0,362
Dia 5	0,962	0,556	0,981	0,5905	0,2076	1,1748	0,5888	0,2757	0,231

O modelo de regressão apresentou comportamento previsto, com notas piores para horizontes maiores. As magnitudes dos índices de qualidade mostraram semelhança no comportamento com os modelos por redes neurais. Na Tabela 5.33 estão dispostos os resultados do modelo por regressão, juntamente com os resultados do modelo por redes neurais. Ambos utilizaram previsão de precipitação como uma das variáveis de entrada.

Tabela 5.33 – Resultados para a amostra de verificação – modelos Regressão e RN COM previsão de chuva.

Horizonte	Modelo	EMQ	EMA	EPA	R	CP	Erro 90%	Erro 75%	Erro 50%	Nota
Dia 1	RN	0,255	0,227	0,505	0,899	0,361	0,480	0,204	0,079	1,0
	Regressão	0,279	0,263	0,528	0,888	0,301	0,529	0,242	0,113	0,0
Dia 2	RN	0,436	0,345	0,660	0,812	0,414	0,795	0,333	0,157	1,0
	Regressão	0,483	0,382	0,695	0,789	0,350	0,835	0,394	0,196	0,0
Dia 3	RN	0,546	0,422	0,739	0,757	0,442	0,946	0,486	0,207	1,0
	Regressão	0,679	0,463	0,824	0,690	0,305	0,986	0,487	0,234	0,0
Dia 4	RN	0,545	0,425	0,738	0,759	0,503	0,991	0,515	0,219	1,0
	Regressão	0,803	0,508	0,896	0,630	0,267	1,190	0,545	0,260	0,0
Dia 5	RN	0,637	0,477	0,798	0,735	0,475	1,073	0,541	0,276	0,941
	Regressão	0,962	0,556	0,981	0,590	0,208	1,175	0,589	0,276	0,059

Em função da comparação entre dois conjuntos de índices resultantes apenas, é possível que a nota ponderada atinja os limites impostos (0 ou 1), quando um dos modelos apresentar vantagem sobre o outro, para todos os índices.

A notas ponderadas mostram que todos índices do modelo por regressão foram piores que os modelos por redes neurais, exceto para o “Erro 50%” com 5 dias de horizonte de previsão, sendo ligeiramente melhor e praticamente igual para ambos modelos.

Os resultados dos valores de nível calculado e observado, para os 5 horizontes, estão apresentados nas Figuras 5.32 a 5.36. São apresentados para cada horizonte os dados em seu ordenamento original Os resultados do modelo de previsão baseado em redes neurais com entrada de previsão de precipitação também estão inseridos nos gráficos, de maneira a permitir uma comparação com os resultados do modelo por regressão.

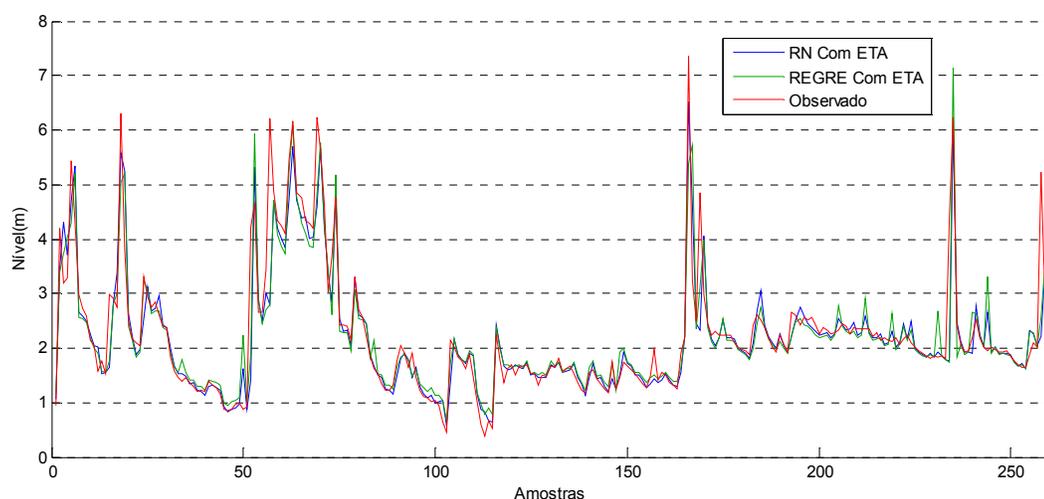


Figura 5.32 - Previsões e observações para horiz. 1 dia – ordem original – RN e REGRE COM previsão de chuva.

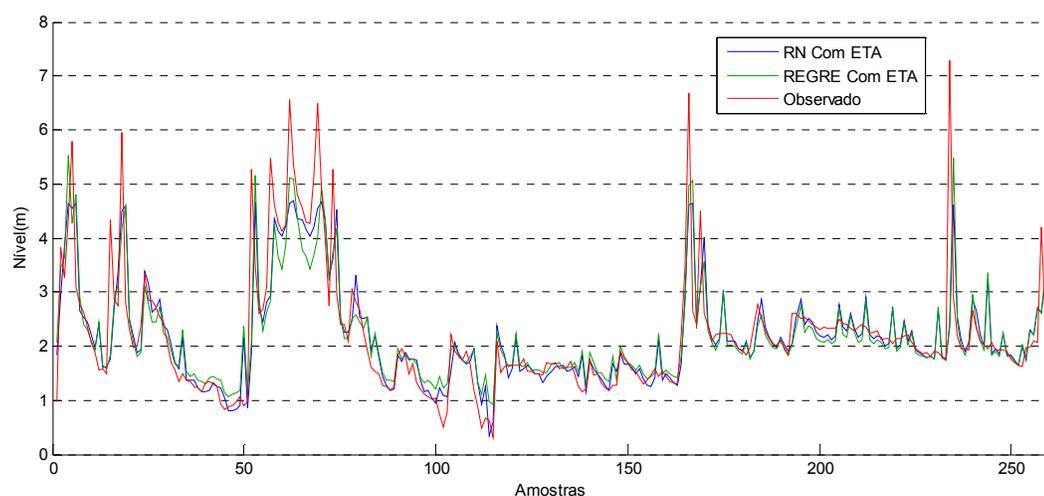
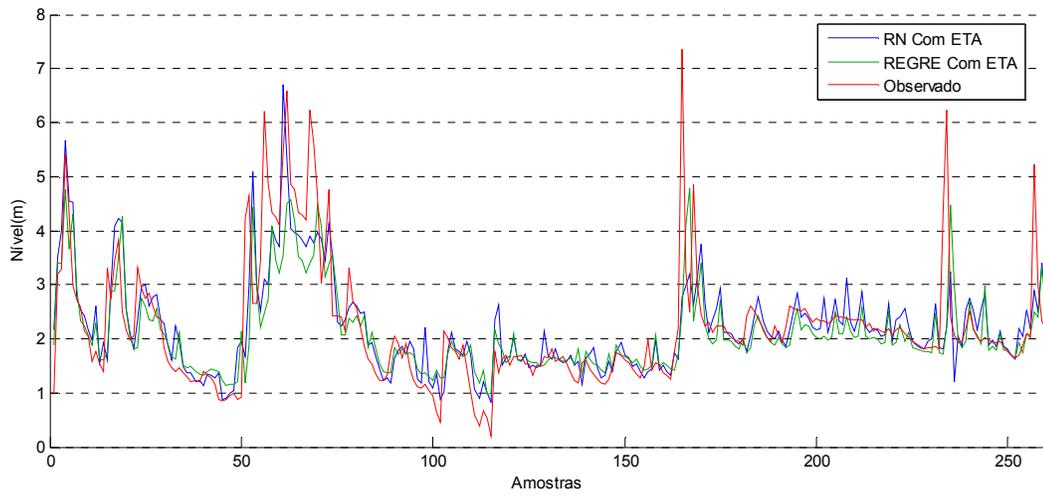
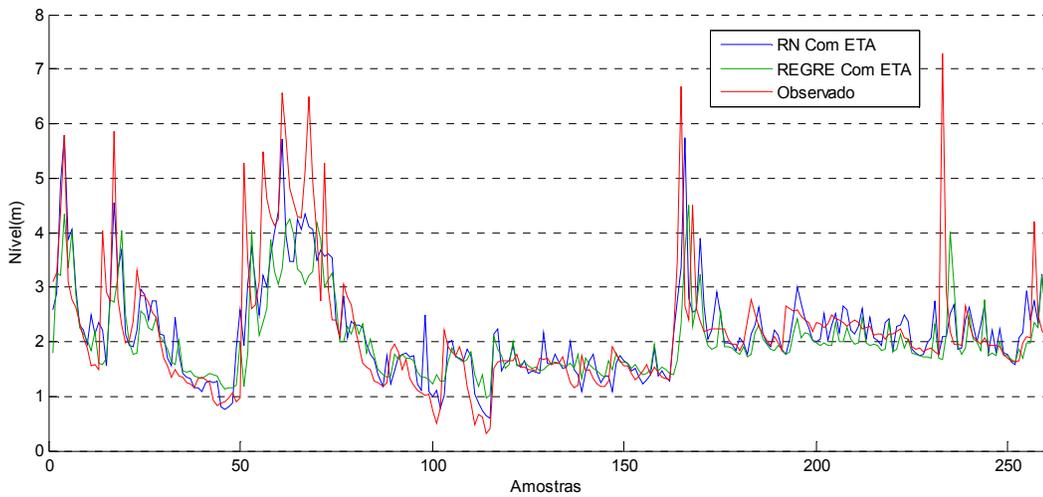


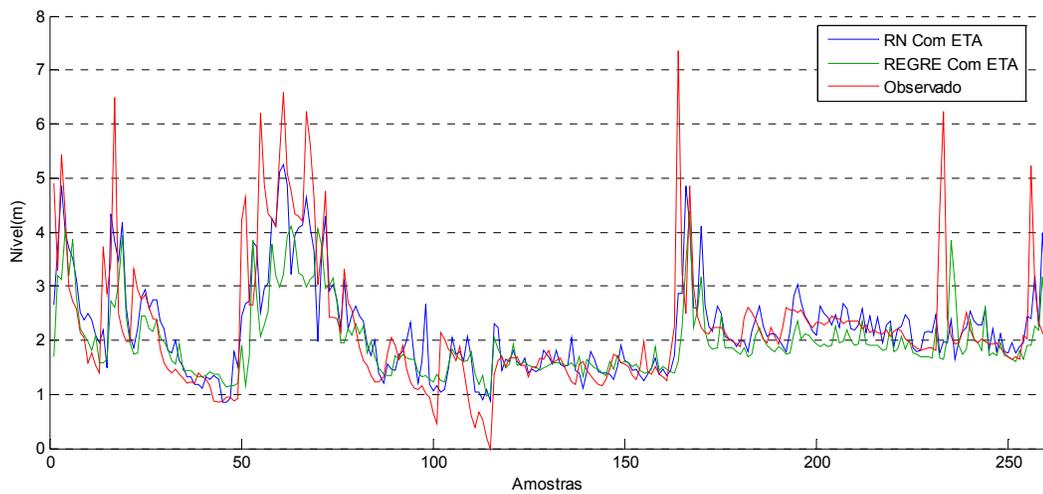
Figura 5.33 - Previsões e observações para horizonte de 2 dias – ordem original – RN e REGRE COM previsão de chuva.



**Figura 5.34 - Previsões e observações para horizonte de 3 dias – ordem original – RN e REGRE
COM previsão de chuva.**



**Figura 5.35 - Previsões e observações para horizonte de 4 dias – ordem original – RN e REGRE
COM previsão de chuva.**



**Figura 5.36 - Previsões e observações para horizonte de 5 dias – ordem original – RN e REGRE
COM previsão de chuva.**

Nas Figuras 5.37 a 5.41, estão apresentados os gráficos em ordenamento crescente do nível a ser previsto, para assim, possibilitar uma análise do erro em função da magnitude do nível de previsão que o modelo deva atingir.

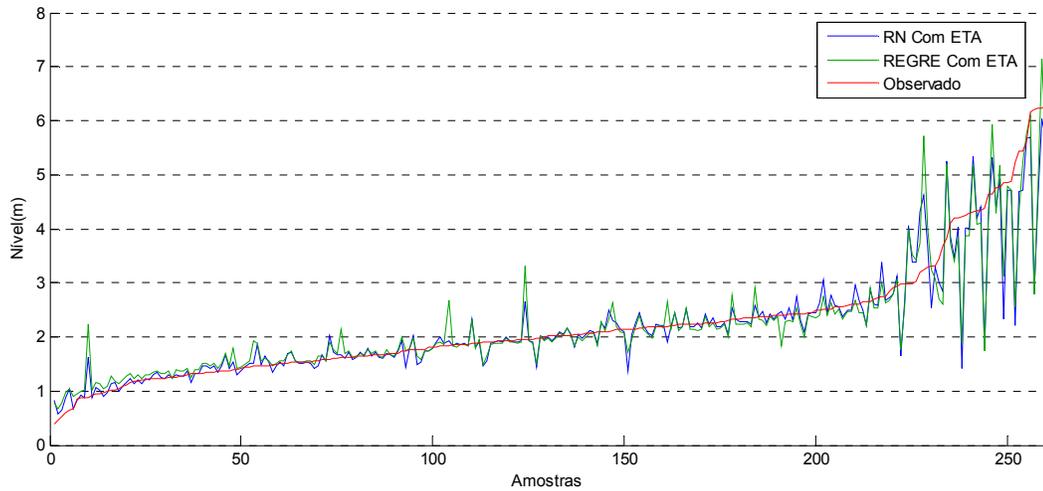


Figura 5.37 - Previsões e observações para horizonte de 1 dia – ordem crescente – RN e REGRE COM previsão de chuva.

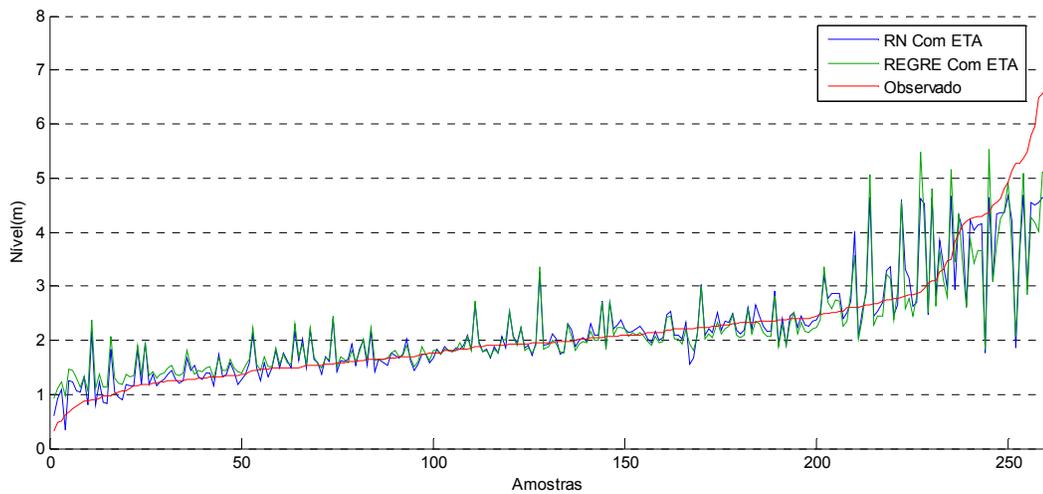


Figura 5.38 - Previsões e observações para horizonte de 2 dias – ordem crescente – RN e REGRE COM previsão de chuva.

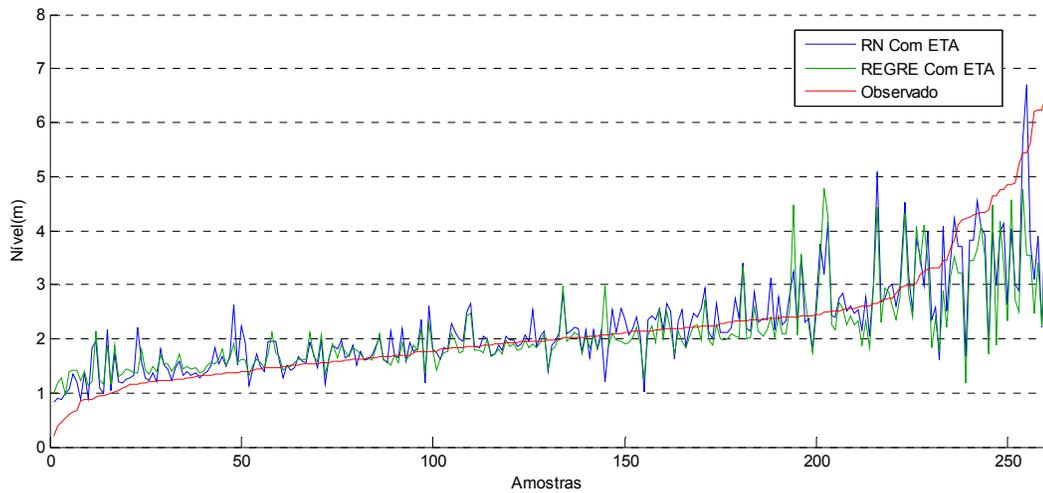


Figura 5.39 - Previsões e observações para horizonte de 3 dias – ordem crescente – RN e REGRE COM previsão de chuva.

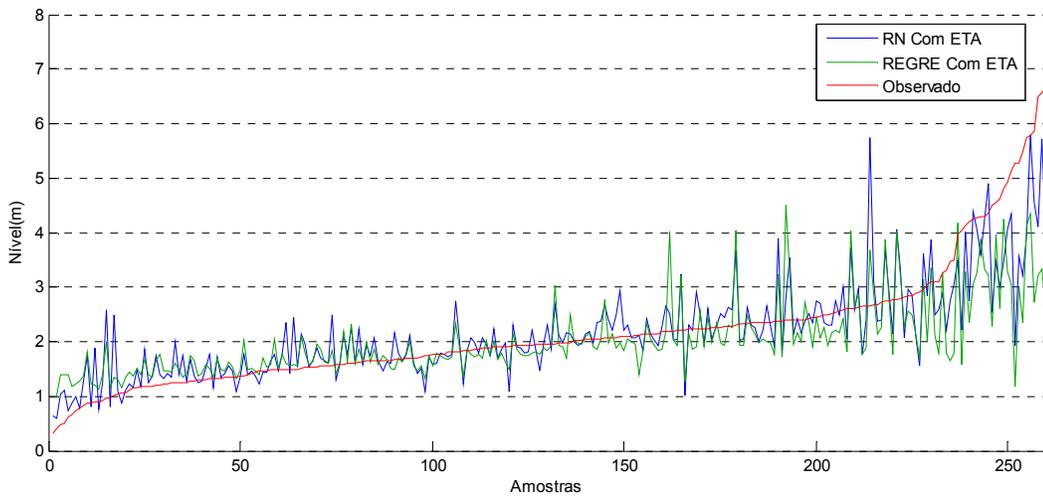


Figura 5.40 - Previsões e observações para horizonte de 4 dias – ordem crescente – RN e REGRE COM previsão de chuva.

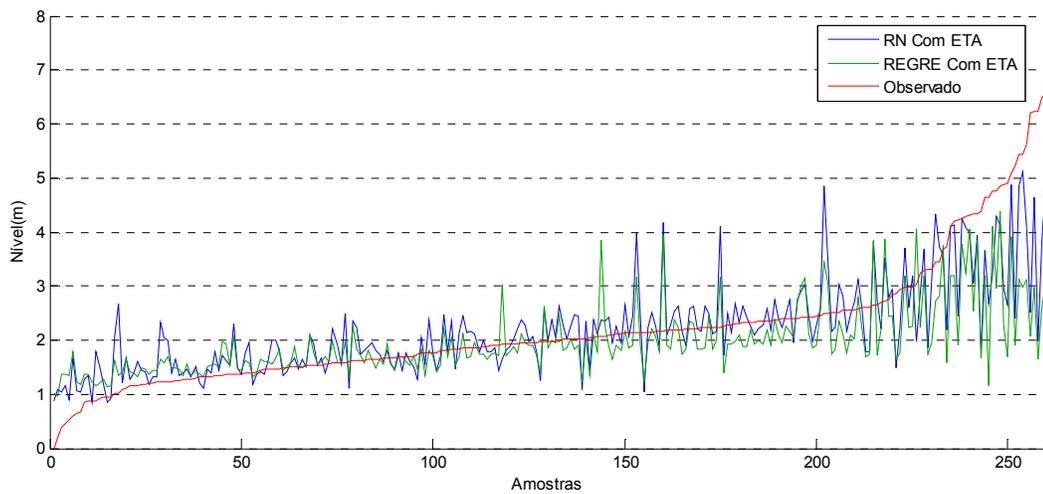


Figura 5.41 - Previsões e observações para horizonte de 5 dias – ordem crescente – RN e REGRE COM previsão de chuva.

Os resultados do modelo por regressão para os menores horizontes apresentaram desempenho semelhante ao do modelo por redes neurais, porém sua qualidade decai mais acentuadamente em função do horizonte, principalmente por erros de subestimação de nível em boa parte dos dados da amostra.

Também, para os maiores horizontes, o modelo por regressão apresentou qualidade inferior ao do modelo por redes neurais para prever os maiores níveis, notavelmente no extremo direito nos gráficos em ordem crescente.

Uma avaliação melhor do desempenho para valores extremos pode ser feita através das Tabelas 5.34 a 5.43, onde são apresentados os 4 maiores erros por “Alerta Falso” e por “Incapacidade de Previsão”, juntamente com as variáveis de entrada (níveis anteriores e previsão de precipitação acumulada) e os níveis anteriores ao nível do horizonte de previsão, sendo apresentados estes últimos apenas a título de visualização do comportamento do nível, previamente ao dia de interesse de previsão.

Tabela 5.34 - Maiores erros por “Alerta Falso” – horiz. 1 dia – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	Prev. 1° dia	Erro (m)
7,360	6,690	0,0	3,250	5,720	2,470
2,034	2,016	42,9	1,954	3,316	1,362
6,301	5,962	0,1	3,836	5,195	1,359
0,999	1,069	33,2	0,888	2,238	1,350

Tabela 5.35 - Maiores erros por “Incapacidade de Previsão” – horiz. 1 dia – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	Prev. 1° dia	Erro (m)
3,462	3,102	0,0	6,200	2,786	-3,414
2,030	2,066	17,2	5,229	2,559	-2,669
1,824	1,775	0,0	4,378	1,751	-2,627
0,919	0,964	25,3	4,233	1,893	-2,340

Tabela 5.36 - Maiores erros por “Alerta Falso” – horiz. 2 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	Prev. 2° dia	Erro (m)
4,378	7,295	0,0	6,239	2,880	5,484	2,604
7,360	6,690	0,0	3,250	2,665	5,054	2,389
6,301	5,962	0,1	3,836	2,790	4,563	1,773
5,441	5,778	10,4	4,311	3,100	4,798	1,698

Tabela 5.37 - Maiores erros por “Incapacidade de Previsão” – horiz. 2 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	Prev. 2° dia	Erro (m)
1,824	1,775	20,3	4,378	7,295	2,418	-4,877
0,919	0,964	26,2	4,233	5,272	2,069	-3,203
3,462	3,102	6,2	6,200	5,485	2,831	-2,654
1,490	1,454	9,8	2,976	4,332	1,836	-2,497

Tabela 5.38 - Maiores erros por “Alerta Falso” – horiz. 3 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	Prev. 3° dia	Erro (m)
7,360	6,690	0,0	3,250	2,665	2,491	4,780	2,289
4,378	7,295	0,0	6,239	2,880	2,401	4,480	2,079
6,301	5,962	2,3	3,836	2,790	2,501	4,281	1,779
4,233	5,272	30,6	4,648	3,490	2,658	4,426	1,767

Tabela 5.39 - Maiores erros por “Incapacidade de Previsão” – horiz. 3 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	Prev. 3° dia	Erro (m)
1,902	2,217	44,5	2,186	3,473	7,360	2,497	-4,863
1,824	1,775	20,3	4,378	7,295	6,239	2,243	-3,996
2,644	2,673	18,1	3,462	3,102	6,200	2,466	-3,734
0,888	0,894	24,5	0,919	0,964	4,233	1,172	-3,062

Tabela 5.40 - Maiores erros por “Alerta Falso” – horiz. 4 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	Prev. 4° dia	Erro (m)
7,360	6,690	0,0	3,250	2,665	2,491	2,390	4,509	2,119
4,378	7,295	0,0	6,239	2,880	2,401	2,192	4,013	1,821
6,301	5,962	2,3	3,836	2,790	2,501	2,293	4,033	1,740
4,233	5,272	30,6	4,648	3,490	2,658	2,605	4,041	1,435

Tabela 5.41 - Maiores erros por “Incapacidade de Previsão” – horiz. 4 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	Prev. 4° dia	Erro (m)
1,859	1,820	18,6	1,824	1,775	4,378	7,295	1,682	-5,613
1,902	2,217	44,5	2,186	3,473	7,360	6,690	2,336	-4,354
0,888	0,894	95,5	0,919	0,964	4,233	5,272	1,173	-4,099
4,300	4,268	8,2	4,208	5,137	6,230	6,480	3,209	-3,271

Tabela 5.42 - Maiores erros por “Alerta Falso” – horiz. 5 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	$N_{(i+5)}$	Prev. 5° dia	Erro (m)
4,378	7,295	0,0	6,239	2,880	2,401	2,192	2,077	3,853	1,776
6,301	5,962	2,3	3,836	2,790	2,501	2,293	2,163	3,932	1,768
4,233	5,272	30,6	4,648	3,490	2,658	2,605	2,644	3,851	1,206
1,889	1,676	12,4	1,459	1,177	1,015	0,883	0,604	1,783	1,178

Tabela 5.43 - Maiores erros por “Incapacidade de Previsão” – horiz. 5 dias – REGRE COM previsão de chuva.

$N_{(i-2)}$	$N_{(i-1)}$	P	$N_{(i+1)}$	$N_{(i+2)}$	$N_{(i+3)}$	$N_{(i+4)}$	$N_{(i+5)}$	Prev. 5° dia	Erro (m)
1,250	1,338	67,5	1,902	2,217	2,186	3,473	7,360	1,606	-5,754
1,859	1,820	18,6	1,824	1,775	4,378	7,295	6,239	1,658	-4,581
2,658	2,605	7,3	2,644	2,673	3,462	3,102	6,200	2,079	-4,121
2,910	2,877	70,9	2,754	2,749	3,451	5,868	6,484	2,618	-3,866

Comparando-se os desempenhos, por “Alerta Falso” e “Incapacidade de Previsão”, entre o modelo por redes neurais e o por regressão, pode-se notar um comportamento semelhante entre os dois modelos, prevalecendo menores erros para as previsões com redes neurais, principalmente para o erro de “Incapacidade de Previsão”. Observa-se que o modelo

por redes neurais não apresentou melhores resultados, apenas, para o erro de “Alerta Falso” com horizonte de 5 dias.

De modo geral o modelo de redes neurais apresentou índices de qualidade melhores que os do modelo de regressão linear multivariada. É apresentada vantagem, também, na comparação com o modelo de redes neurais que não utilizou, como entrada, a previsão de precipitação. Esta vantagem pode ser atribuída à maior capacidade destes modelos para a aproximação de funções, produzindo com mais facilidade associações válidas, independentemente da disponibilidade de informações completas sobre os fenômenos analisados.

5.5 Análise da aplicabilidade do Modelo Proposto de Previsão de Níveis Fluviais

A utilização de redes neurais em substituição a outros modelos empíricos pode ser mais vantajosa, na grande maioria das vezes, a exemplo do que foi apresentado na análise dos resultados desta pesquisa.

Assim como qualquer outro modelo empírico, a qualidade dos resultados depende diretamente dos dados utilizados na calibração (treinamento). Estes dados devem ser o mais abundantes possíveis e cobrir com uma densidade de frequência suficiente todo o domínio de aplicação desejada, de maneira a fornecer ao modelo a capacidade de reproduzir cenários já ocorridos. Infelizmente, para previsão de inundações com um modelo empírico, é necessário que ocorram diversos episódios de inundação para, assim, sensibilizar os parâmetros do modelo, e então promover uma previsão com qualidade.

O treinamento obtido a partir dos dados disponíveis para este trabalho indica que o uso de redes neurais na previsão de nível não é aconselhado para o caso de estudo selecionado. Entretanto, um modelo conceitual poderia ser o mais indicado para a situação atual, uma vez que os modelos baseados na física do sistema possuem, via de regra, capacidade de extrapolação, em certa medida, fora do domínio, o que não ocorre com os modelos empíricos, e menos ainda com as redes neurais. Porém, estes modelos, para serem representativos, exigem uma representação do sistema, sob forma descritiva, tanto física (topográfica, geológica, etc) quanto dos processos, com detalhamento específico para cada caso, o que, muitas vezes, constitui-se em investimento inviável. Talvez, portanto, havendo disponibilidade adequada de amostragem, seja mais conveniente o investimento em modelos empíricos, como o proposto neste trabalho.

Na hipótese do emprego de uma rede neural para prever o nível no rio Quaraí algumas recomendações de operação podem ser de imediato apontadas:

- Manter um grupo treinado para utilizar o modelo de previsão de nível;
- Prever a manutenção e melhora da qualidade do modelo, aferindo o medidor de nível do rio e refazendo o treinamento da rede neural periodicamente;
- Estar em condições de emitir o alerta, com base nas previsões realizadas, e com tempo hábil, tendo em conta a capacidade da defesa civil em remover população com probabilidade de ser atingida pela inundação.

Assim como toda modelagem matemática, a generalização dos resultados obtidos em um estudo específico não pode ser utilizada diretamente para outros casos (outras bacias). Deve-se ter consciência que o processo chuva-vazão em uma bacia é praticamente único, em especial para modelagem de eventos extremos, sendo a influência das características peculiares de cada caso de grande importância em modelagens matemáticas.

6. Conclusões

A pesquisa se propôs a investigar técnicas de modelagem que viabilizassem o uso de redes neurais na previsão de níveis. O caso em estudo foi a bacia do rio Quaraí, que tem características peculiares, tais como: coeficiente de escoamento alto, tempo de concentração de aproximadamente 28h e tempo entre picos (pico de precipitação e pico de nível) de 12h, conferindo à bacia uma rápida resposta aos eventos de precipitação.

O modelo de previsão de níveis proposto foi por redes neurais, que utilizou em sua entrada dados de níveis observados nos dois dias anteriores ao da execução da previsão, juntamente com a previsão numérica de precipitação para até 5 dias à frente.

O particionamento seqüencial da amostra mostrou-se conveniente para casos onde a série de dados tem forte componente sazonal e pequena abrangência temporal, acarretando problemas de representatividade das amostras particionadas tradicionalmente, em ordem cronológica. A técnica seqüencial permitiu que os 3 grupos amostrais (treinamento, validação e verificação) mantivessem as mesmas características estatísticas, o que é almejado na técnica de treinamento das redes neurais, sendo que a igualdade estatística das amostras foi fundamental no isolamento da banda aleatória, realizado pela técnica de validação cruzada.

A avaliação do modelo proposto foi realizada utilizando-se 8 índices, dos quais 5 são tradicionalmente utilizados (erro médio quadrático, erro médio absoluto, erro médio padrão, coeficiente de correlação e coeficiente de persistência), e os 3 restantes são índices associados à frequência do erro absoluto.

A utilização dos índices de erro associado à frequência mostrou-se bastante pertinente à avaliação dos resultados dos modelos, informando de maneira direta a magnitude do erro para as frequências de 50, 75 e 90%. Este índice mostrou-se de acordo com os demais, seguindo a tendência de piora da qualidade em função do horizonte de previsão. Este índice permitiu uma compreensão mais palpável da magnitude do erro e do risco da previsão do nível, ao contrário da utilização pura do erro médio absoluto, onde não é fornecida esta noção. A frequência com que o valor do erro médio absoluto não foi superado ficou em torno de 75%, indicando que, para os dados disponíveis deste trabalho, o erro de previsão é maior que o erro médio absoluto em cerca de 25% do tempo.

Exemplificando-se o tipo de resultado obtido com o índice de erro absoluto associado à frequência, o modelo por redes neurais proposto obteve erros inferiores a 0,480 , 0,795 , 0,946 , 0,991 e 1,073 m, em 90% do tempo (90% da amostra de verificação), respectivamente para os horizontes de previsão de 1 dia a 5 dias.

A experiência obtida ao utilizar a aglutinação ponderada (nota ponderada) dos diversos índices mostrou-se válida. Contribuiu para resolver o dilema da ambigüidade em definir entre diversos conjuntos de índices de resultados, qual tem o melhor desempenho. Esta técnica conferiu agilidade e objetividade na eleição das redes neurais, na escolha da forma da equação de regressão, bem como nas comparações entre os modelos, indicando a vantagem relativa entre os resultados.

Nas etapas de eleição da arquitetura ótima de rede neural, para cada horizonte de previsão, foram executadas 158 comparações, para a verificação de qual conjunto de índices apresentou o melhor desempenho. Com este elevado número de repetições da aplicação da técnica de aglutinação ponderada dos índices, seria possível detectar a ocorrência de algum problema na sua utilização, o que de fato não ocorreu.

O problema de convergência para pontos de mínimos locais, nos treinamentos de uma rede neural, foi investigado repetindo-se o treinamento e analisando os seus resultados. Averiguou-se que cerca de 10% dos treinamentos caem em pontos de mínimo com desempenho muito inferior ao do melhor treinamento. Também foi constatado que o melhor índice de desempenho, para 30 repetições, é aproximadamente igual ao obtido com 100 repetições de treinamento, isso independentemente da arquitetura, ou do algoritmo de treinamento utilizado.

Assim, nesta pesquisa foi adotado o mínimo de 30 repetições, que se revelou um limite a partir do qual há uma certa estabilidade no que diz respeito à qualidade dos resultados, supondo-se (uma vez que não ocorrem melhoras significativas a partir deste número de repetições) que, possivelmente, já se está suficientemente próximo do ótimo.

O critério para definir o número mínimo de repetições foi avaliar a diferença relativa da qualidade dos resultados dos diversos treinamentos, graficados em ordem decrescente, e identificar a partir de que número de repetições esta diferença relativa deixa de ser significativa, ou seja, a curva passa a ter um comportamento assintótico.

A apresentação dos resultados dos modelos de previsão de níveis na forma gráfica tradicional por cotagramas com os dados ordenados cronologicamente, por vezes, oculta os erros do modelo, especialmente para as maiores magnitudes de nível. A apresentação dos resultados ordenados em função crescente do nível observado permitiu uma avaliação visual da baixa capacidade dos modelos em prever níveis extremos.

A incapacidade de prever níveis com altas magnitudes foi detectada observando-se os dados de entrada que causaram os maiores erros. Foi possível constatar, claramente, que o modelo proposto tem uma forte dependência da variável de entrada composta pelos níveis

observados anteriormente ao dia da previsão, o que criou um comportamento de persistência, prejudicando a resposta para variações abruptas de nível.

A qualidade do modelo de previsão hidrometeorológica foi avaliada separando-se os casos onde a previsão e a observação não foram nulas dos casos onde uma das duas, ou as duas, foram nulas. Os casos onde uma foi nula, e a outra não, apresentaram resíduos com pequena magnitude, tendo assim pouca influência no modelo de previsão de níveis. Já os resíduos para previsões e observações não nulas apresentaram valores elevados, especialmente para as previsões com grande magnitude e para os maiores horizontes de previsão. O modelo de previsão de precipitação consegue prever muito bem a ocorrência de eventos, porém acertar a magnitude do evento foi uma deficiência, revelada pela análise de resíduos para a amostra de dados utilizada neste trabalho.

A verificação do ganho de qualidade na previsão de níveis, proporcionado pelo emprego de previsões de precipitação na entrada do modelo por redes neurais, foi realizada comparando-se os resultados do modelo por redes neurais que não utilizasse a previsão hidrometeorológica com o que a utilizou. Apesar da baixa qualidade em acertar a magnitude do evento de precipitação, o uso da previsão hidrometeorológica mostrou ligeira vantagem sobre o que não a utiliza.

Com a finalidade de verificar a aplicabilidade da ferramenta redes neurais na previsão de níveis na bacia do Quaraí, foram comparados os seus resultados com os de um modelo tradicional de regressão linear multivariada. A modelagem por regressão teve, inicialmente, em sua fase de concepção, a escolha da melhor dentre quatro equações. As equações empregavam diferentes entradas, sendo uma delas, um ponderador da precipitação prevista em função da magnitude dos níveis observados anteriores ao dia de previsão de nível. Porém, o uso deste ponderador não agregou vantagem significativa, portanto, esta configuração foi descartada, ficando a equação que utiliza os dois níveis anteriores e mais a previsão de precipitação como o melhor modelo de regressão para ser o balizador da verificação dos resultados do modelo por redes neurais.

Os resultados do modelo de redes neurais obtiveram melhor qualidade que os por regressão, especialmente para os maiores horizontes de previsão (acima de 3 dias). Para os horizontes de 1 e 2 dias, os resultados foram praticamente equivalentes. A análise dos erros por “Incapacidade de Previsão” e “Alerta Falso” apontaram vantagem para o modelo de redes neurais.

Apesar da pequena diferença entre os resultados dos modelos, é possível perceber que o uso de redes neurais, em substituição a modelos empíricos menos flexíveis, é válido.

A baixa qualidade em prever altos níveis pode ser atribuída à forma de distribuição das magnitudes de níveis, que é uma característica do comportamento natural dos níveis fluviais. Modelos empíricos são treinados (calibrados) minimizando o somatório de resíduos resultantes para amostra disponível, porém, para amostras não abrangentes e com distribuição de frequência pouco homogênea, não é possível obter um bom ajuste para os valores extremos, ficando o modelo especializado apenas em prever níveis nas faixas de magnitude que tiveram o maior número de registros.

Do ponto de vista das redes neurais, pode-se dizer que, além disso, estas não possuem capacidade de extrapolação fora do domínio, para aproximação de funções. Então, constatou-se, como uma contribuição deste trabalho, que as redes neurais apresentam uma certa dificuldade de aproximação já em regiões pouco representadas do domínio. Ou seja, há uma região de pseudo-extrapolação nos extremos do domínio, cuja análise merece uma recomendação para estudos futuros.

Os resultados obtidos nesta pesquisa não encorajam a utilização do modelo proposto na implementação imediata de um sistema de alerta de cheias, para o caso do rio Quaraí, nas condições atuais de ocupação e disponibilidades amostrais de dados hidrometeorológicos. É necessário obter uma amostra de dados mais abrangente, com mais registros de níveis altos do rio, para assim, promover um treinamento eficiente do modelo, e então, prever melhor os eventos extremos.

Em casos com amostra não abrangente, o uso de um modelo conceitual pode ser mais indicado. Entretanto, no confronto de necessidades para cada tipo de modelagem (abrangência de dados para treinamento para os modelos empíricos, e para os modelos conceituais a compreensão e quantificação dos processos físicos), pode ser, em muitos casos, igual ou até mais vantajosa a opção pelos modelos de redes neurais, tendo-se em conta a capacidade teórica de aproximação exata de funções, mesmo desconhecidas, desde que bem representadas por dados amostrais.

Por fim, esta pesquisa mostrou-se importante para o estabelecimento de limites de aplicação, pois indica a necessidade de, ou ampliação amostral, ou modelagem física.

7. Recomendações

O não esgotamento de análises de resultados e implementações de novas metodologias, para atingir os objetivos desta pesquisa, apontam como recomendações a serem tratadas em pesquisas futuras os seguintes itens:

- Utilizar precipitação observada ao invés de precipitação prevista para avaliar a influência da incerteza que é propagada para a previsão de níveis.
- Aplicar um modelo conceitual para amostras não abrangentes, e verificar os resultados contra os de uma modelagem por redes neurais.
- Investigar as conseqüências nos resultados da modelagem com redes neurais ao manipular a amostra de dados disponíveis, de maneira a homogeneizar o histograma de freqüências, contemplando a mesma freqüência de observações para todos os blocos de classe, mesmo em detrimento do número de amostras que será reduzido.
- Definir critérios de determinação da validade do domínio amostral, identificando o ponto a partir do qual a densidade de dados é suficientemente baixa, criando uma região de pseudo-extrapolação para os resultados do modelo.
- Adotar, em outras pesquisas que usem a técnica de redes neurais, a metodologia de investigar o mínimo de treinamentos necessários para assegurar que a convergência do treinamento caia em um ponto de mínimo ótimo.
- Implementar um algoritmo de treinamento de redes neurais que privilegie um melhor ajuste para os picos, mesmo que em detrimento da qualidade para as magnitudes medias, caracterizando um treinamento especializado para atender o objetivo de um modelo de previsão de cheias.

8. Referências Bibliográficas

CHENADAMS, J. C.; ADAMS, B. J. 2005. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling . Ontario: Canada Department of Civil Engineering, University of Toronto.

CAJAL, S. R. 1984. Die Retine der Wirbelthiere. Weisbaden: J.F. Bergman.

DAWSON, C. W. ; WILBY, R. L. 2001. Hydrological modelling using artificial neural networks. Progress in Physical Geography, v. 25, n.1, p. 80–108.

DEMUTH, H.; BEALE, M. 2004. Neural Network Toolbox: User's Guide Version 4.0, for use with MATLAB. M.A : Mathworks. 1v.

DRAPER, N. R. ; SMITH, H. 1981. Applied Regression Analysis, New York: John Wiley and Sons, 709 p.

ERLANGER, J ; GASSER, H. S., 1924, The compound nature of the action current of a nerve as disclosed by the CR oscillograph. Amer. Jour. Of Physiology, v. 70.

FERREIRA, S. H. S. ; CAMARGO, H. Jr., sd. Tecnologia Espacial na Previsão do Tempo: Cap. 5. DSR/INPE.

FERREIRA, W. M. F° ; LIMA, C. H. R., 2003. Análise de Modelos de Redes Neurais Aplicados ao Processo Chuva-Deflúvio no Semi-Árido. In: Simpósio Brasileiro de Recursos Hídricos , 15., 2003 Curitiba, PR. Anais... Porto Alegre : ABRH, 1CD-ROM

JANJIC, Z.I., 1994. The step-mountain Eta coordinate Model: further developments of the convection, viscous sublayer, and turbulence closure schemes. J. Atmos. Sci., v.122, p.927-945.

KATZ, B., 1966. Nerve Muscles and Synapse – McGrawHill, New York.

KITANIDIS e BRAS, R. L., 1980. Real time forecasting with a conceptual hydrologic model 2: applications and results, *Water Resources Research* v. 16, n. 6 , pp. 1034–1044.

KOSKO, B. 1992. *Neural networks and fuzzy systems: a dynamical systems approach to machine intelligence*. Englewood Cliffs: Prentice Hall. 449 p.

KOVACS, Z. L., 1996. *Redes Neurais Artificiais: fundamentos e aplicações: um texto básico*. . São Paulo: Editora Livraria da Física. 3 ed.

KRZYSZTOFOWICZ, R., 1993. The theory of flood warning system. *Water Resources Research*, v. 29, n.12 , p.

LIMA, H. V. C. ; LIMA L. C. T. M. ; LIMA, C. H. R. 2003. *Modelagens Hidrológica Conceitual e por Redes Neurais Artificiais Aplicadas ao Processo Chuva-Vazão: uma análise comparativa*. Fortaleza, Ceará.

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

MOURA, A. D. 1996. Von Neumann e a previsão numérica de tempo e clima. *Estud. av.*, , v.10, n.26, p.227-236.

MULLER, M. ; FILL, H. D. 2003. *Redes Neurais Aplicadas na Propagação de Vazões IN: Simpósio Brasileiro de Recursos Hídricos , 15., 2003 Curitiba, PR. Anais... Porto Alegre: ABRH, 1CD-ROM*

PEDROLLO, O. C., 2000. *Previsão em Tempo Atual de Cheias com uso de Sistema Especialista Difuso*. 2000. 123f. Tese(Doutorado em Recursos Hídricos e Saneamento Ambiental) Universidade federal do Rio Grande do Sul. Instituto de Pesquisas Hidráulicas , Porto Alegre.

PEDROLLO, O. C., 2005. *Previsão de Níveis Fluviais com Redes Neurais: aplicação para Rosário do Sul – RS*. Porto Alegre: IPH/UFRGS, Simpósio de Recursos Hídricos do Sul, 1., 2005, Santa Maria , RS. Anais... Porto Alegre: ABRH 1 CD-ROM.

PPGICBRQ, 2005. Projeto Piloto de Gestão Integrada de Cheias na Bacia do Rio Quaraí . Informe Final. DNH (Dirección Nacional de Hidrografía del Uruguay) e IPH(Instituto de Pesquisas Hidráulicas, Brasil).

RUMMELHART, D., HINTON, WILLIAM, 1986. Learning Internal Representation by Internal Error Propagation, em Parallel Distributed Processing . MIT Pres, Cambridge: MIT Press.

SAJIKUMAR, N., THANDAVESWARA, B. S., 1999. A non-linear rainfall-runoff model using an artificial neural network. Journal of Hydrology, v.216, p.32-55.

SAJJAD A. ; SLOBODAN, P. S. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. Journal of Hydrology, v.315, p.236-251.

SPIEGEL, M., 1970. Estatística. São Paulo: McGraw-Hill do Brasil Ltda. 580p. 2ed..

TUCCI, C. E. M., 1998. Modelos Hidrológicos. Porto Alegre: Editora da Universidade/UFRGS/ABRH., 669p.

TUCCI, C. E. M. 2003 Inundações e Drenagem Urbana. In: TUCCI, Carlos E. M. e J. C. BERTONI Inundações Urbanas na América do Sul – Porto Alegre, ABRH. Cap. 3, p. 76.

ANEXO 1 – Superfícies de Resultado das Redes Neurais COM o uso de Previsão de Precipitação

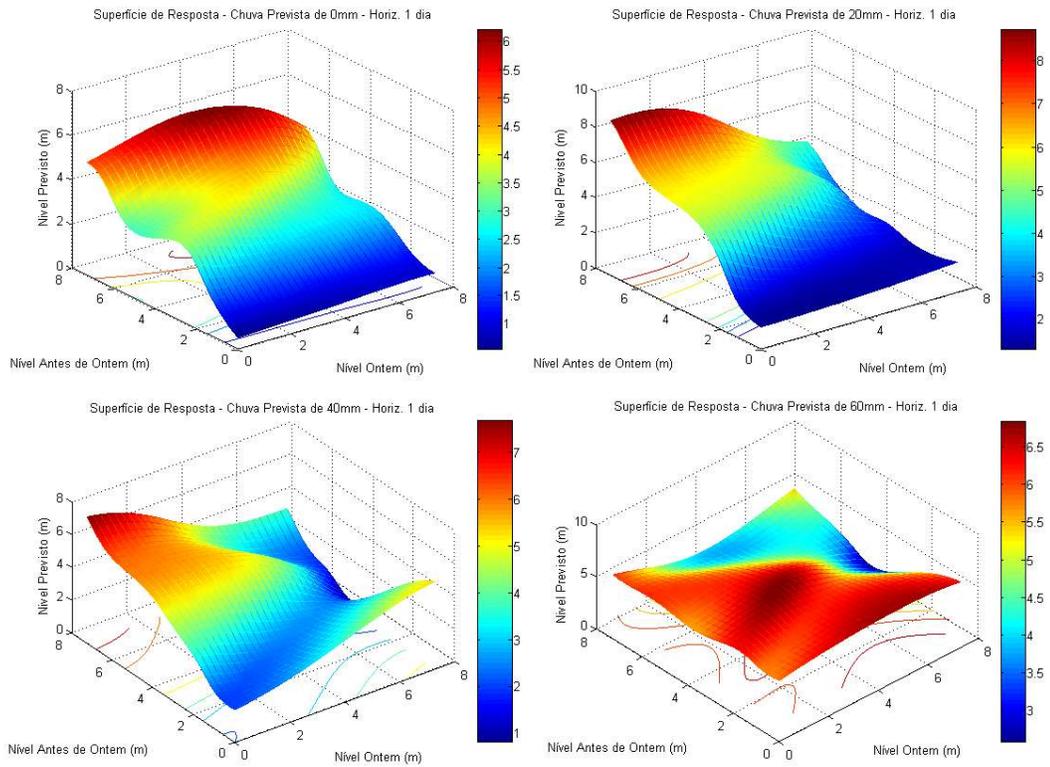


Figura A1 – Superfícies de resultado – RN com previsão de chuva – Horizonte 1 dia

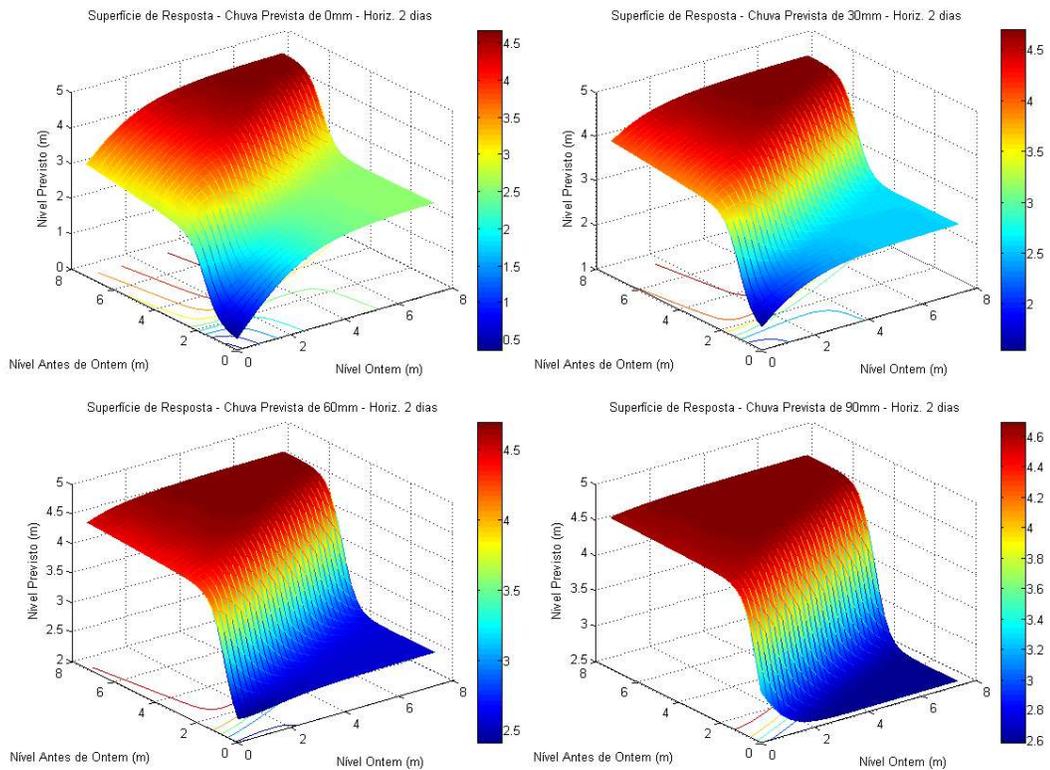


Figura A2 – Superfícies de resultado – RN com previsão de chuva – Horizonte 2 dias

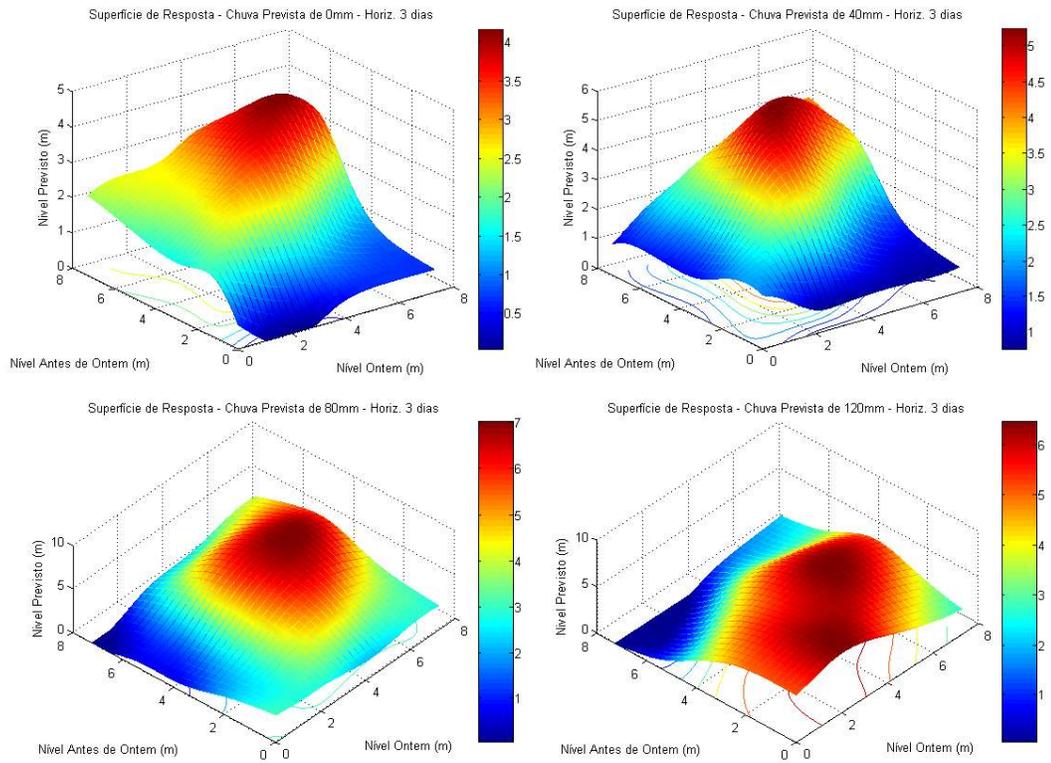


Figura A3 – Superfícies de resultado – RN com previsão de chuva – Horizonte 3 dias

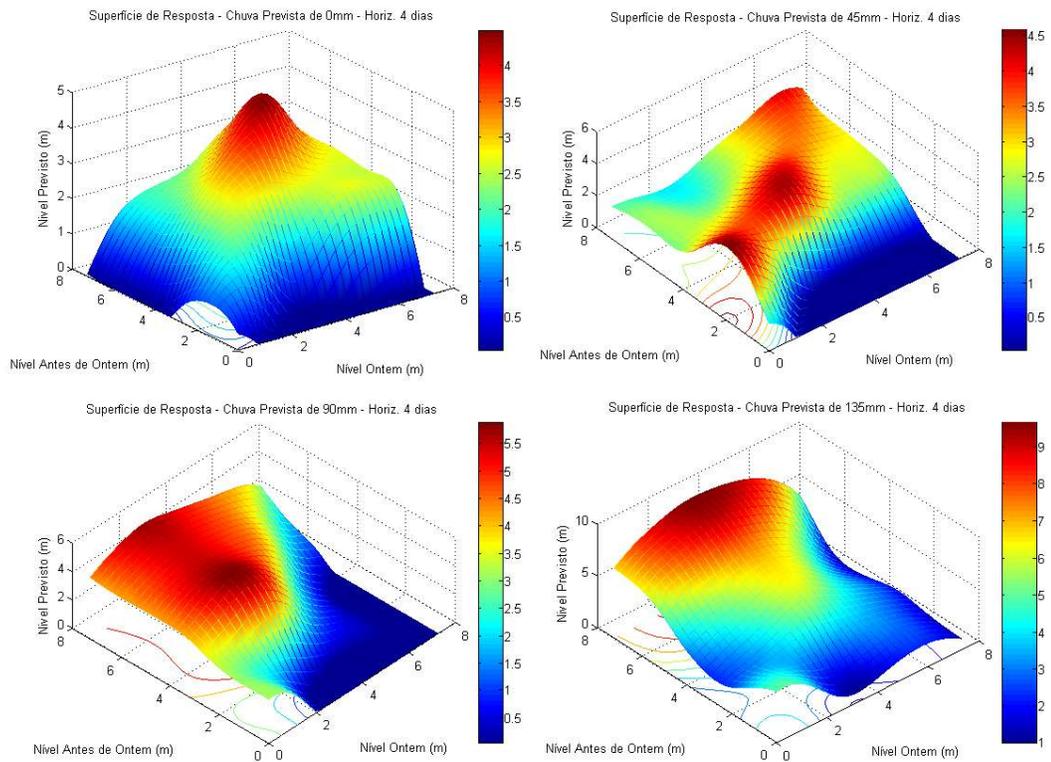


Figura A4 – Superfícies de resultado – RN com previsão de chuva – Horizonte 4 dias

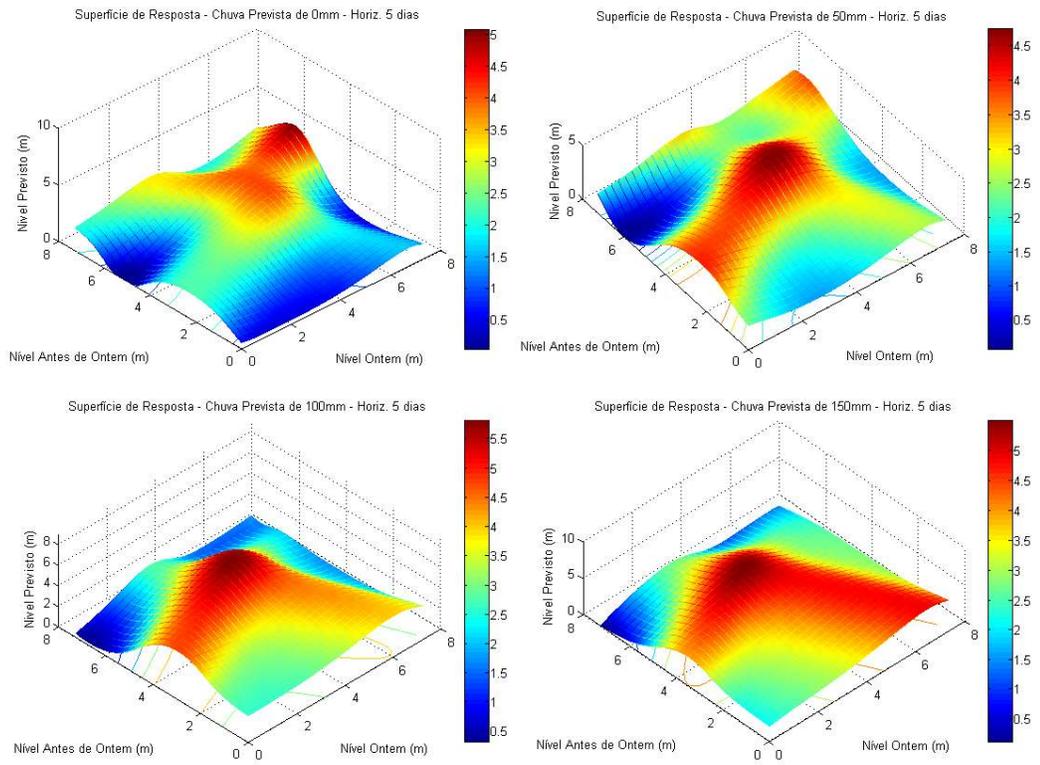


Figura A5 – Superfícies de resultado – RN com previsão de chuva – Horizonte 5 dias

ANEXO 2 – Superfícies de Resultado das Redes Neurais SEM o uso de Previsão de Precipitação

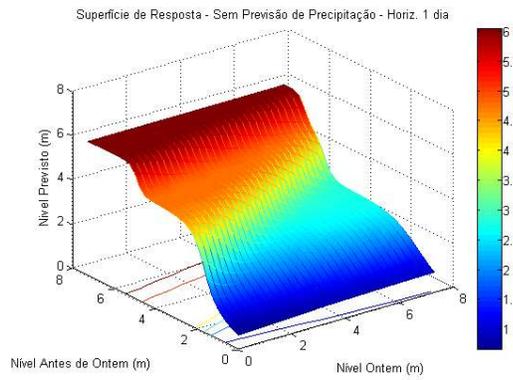


Figura A6 – Superfícies de resultado – RN sem previsão de chuva – Horizonte 1 dia

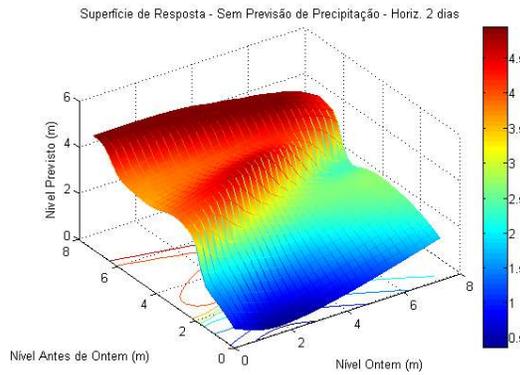


Figura A7 – Superfícies de resultado – RN sem previsão de chuva – Horizonte 2 dias

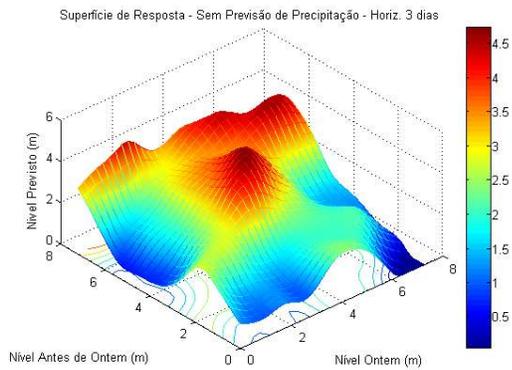


Figura A8 – Superfícies de resultado – RN sem Chuva ETA – Horizonte 3 dias

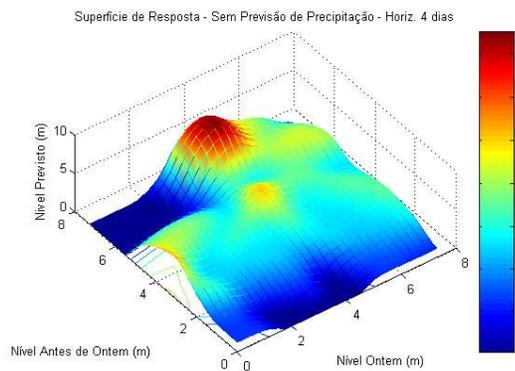


Figura A9 – Superfícies de resultado – RN sem previsão de chuva – Horizonte 4 dias

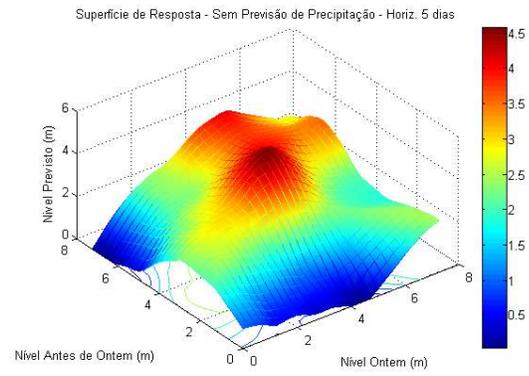


Figura A10 – Superfícies de resultado – RN sem previsão de chuva – Horizonte 5 dias