



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

INSTITUTO DE PESQUISAS HIDRÁULICAS



PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E
SANEAMENTO AMBIENTAL

**EFEITO DO CONTROLE DE MONTANTE NA PREVISÃO
HIDROLÓGICA DE CURTO PRAZO COM REDES NEURAIIS: APLICAÇÃO À
BACIA DO IJUÍ**

ALEX BORTOLON DE MATOS

Dissertação de Mestrado

Porto Alegre, 20 de Dezembro de 2012.



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



**EFEITO DO CONTROLE DE MONTANTE NA PREVISÃO
HIDROLÓGICA DE CURTO PRAZO COM REDES NEURAIS: APLICAÇÃO À
BACIA DO IJUÍ**

ALEX BORTOLON DE MATOS

Orientador: Olavo Correa Pedrollo

Co-orientadora: Nilza Maria dos Reis Castro

Banca Examinadora:

Prof. Dr. Carlos de Oliveira Galvão (UFCG)

Prof. Dr. José Antônio Saldanha Louzada (IPH/UFRGS)

Prof. Dr. Juan Martín Bravo (IPH/UFRGS)

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.

Porto Alegre, 20 de Dezembro de 2012.

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais Maristela e Odeny, pelo amor, carinho e por compreenderem e apoiarem esse meu momento acadêmico.

À minha noiva, Mariana, pelo incentivo e apoio que me proporcionaram chegar a este momento.

Agradeço ao prof. Olavo e a prof^a Nilza, pelos conselhos e orientação, que tornaram possível a realização desta dissertação.

Aos professores do IPH por todo o conhecimento que me foi transmitido nos últimos dois anos.

Aos meus amigos que aqui fiz, que me ajudaram e apoiaram nesta caminhada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro deste estudo.

RESUMO

Neste trabalho foi avaliado o efeito do controle de montante em sub-bacias embutidas na previsão hidrológica de curto prazo, com a investigação conjunta de dois aspectos: variação da área controlada e a variação do detalhamento temporal dos dados de vazões de entrada do modelo. O local escolhido para essa pesquisa foi a bacia do rio Ijuí com exutório no posto fluviométrico da Ponte Mística e as suas sub-bacias embutidas de Santo Ângelo, Ponte Nova do Potiribu, Colônia Mousquer, Passo do Faxinal e Turcato. Os dados de vazão utilizados foram obtidos da Agência Nacional de Águas (ANA) e do projeto de monitoramento da bacia do Potiribu (Castro et al., 2010), enquanto que os dados de precipitação foram obtidos em Silva (2011), que calculou uma série histórica de precipitações médias de uma grade de chuvas interpoladas a partir dos dados de 65 postos pluviométricos da região. Para este estudo foram utilizados dados de 22/08/1989 à 01/06/1994 (1.743 dias). Esse período foi selecionado por ser o maior período com dados concomitantes em todos os postos fluviométricos. Os modelos escolhidos para esse estudo foram as redes neurais artificiais de múltiplas camadas, com utilização do algoritmo retropropagativo. As entradas nos modelos foram os dados de precipitação e as vazões diárias da bacia de Ponte Mística e de suas sub-bacias, e as saídas foram as vazões de Ponte Mística um dia à frente. Foram apresentadas oito alternativas de controle físico de montante. Também foram aplicadas, para cada uma das alternativas, componentes antecedentes, com a utilização dos dados de vazão com antecedência de 24h e 48h. A utilização de vazões horárias do Turcato foi comparada com uma alternativa que contempla o mesmo posto, mas com dados diários, para investigar se a utilização de dados com um maior detalhamento temporal pode produzir melhores resultados. Para a análise do desempenho da rede foi aplicado como estatística de qualidade o coeficiente de Nash-Sutcliffe (NS). A avaliação estatística apresentou bons resultados na previsão de vazão para todas as alternativas de controle, sendo o menor NS de 0,91 e o maior de 0,97. A utilização de um maior detalhamento temporal, com aplicação de vazões horárias, provocou uma redução no desempenho do modelo, com o NS caindo de 0,91 para 0,89. Observou-se também que, quanto maior a área controlada das bacias, melhores são os resultados para a previsão de vazão. A análise da influência de cada variável explicativa foi feita por um método apresentado por Maier e Dandy (1997), revelando-se um recurso valioso para a compreensão das

relações de importância das variáveis e do funcionamento do sistema. As contribuições das vazões das bacias de montante foram sempre mais influentes do que as precipitações diárias sobre toda a bacia, sendo demonstrado que, neste sentido, mesmo uma bacia muito pequena pode ser importante para a previsão. Além disso, esta técnica revelou-se importante para auxiliar na identificação das defasagens que são mais importantes, e também revela que, mesmo componentes que apresentam menor influência, podem atuar como potencializadoras de outras variáveis ou componentes, cuja ação atua no sentido de incrementar o desempenho das previsões do modelo.

ABSTRACT

This study evaluated the effects of the amount of controlled area with sub-basins embedded for real time hydrologic forecasting. Two aspects were studied together: The variation in the amount of controlled area and the temporal variation of detail data flow model input. The site chosen for this research was the Ijuí river basin with outlet in the gaging station of Ponte Mística and its sub-basins, namely the gaging stations at Sant'Angelo, Ponte Nova do Potiribu, Colônia Mousquer, Passo do Faxinal and Turcato. The streamflow data used were obtained from the National Water Agency (ANA) and the monitoring project of the Potiribu basin (Castro et al., 2010), while precipitation data were obtained in Silva (2011), who calculated the series of average precipitations from a grid of rainfalls resulting from the data interpolation of 65 raingauge stations in the region. For this study we used data from 22/08/1989 to 01/06/1994 (1.743 days). This period was selected because it is the longest period with complete data in all fluviometric stations. The models chosen for this study were the artificial neural networks of multiple layers, with training by the backpropagation algorithm. The entries of the models were the daily rainfall data and the streamflow of Ponte Mística basin and its sub-basins, and the outputs were the streamflows of the gaging station of Ponte Mística one day after. Eight alternatives of upstream control were presented. There were also applied, to each of these alternatives, the antecedent components, namely, the previous streamflow data of 24h and 48h. The model which uses hourly streamflows of Turcato was compared with an alternative that makes the same job, but with daily data, to investigate if the former, with the use of data with greater temporal detail, can produce better results. For the analysis of network performances it was applied the Nash-Sutcliffe coefficient (NS). Statistical evaluation showed good results in predicting streamflow for all control alternatives, being 0.91 and 0.97 the lowest and the highest NS, respectively. Using a more detailed temporal, applying hourly streamflows, caused a reduction in the performance of the model, with the NS falling from 0.91 to 0.89. It was also observed that the larger the controlled basins area, the better the results for predicting flow. The analysis of the influence of each explanatory variable was made by a method developed by Maier and Dandy (1997), proved to be a valuable resource for understanding the importance of relationships of variables and operating system. The contributions of flow from upstream basins have revealed always more influential to the

forecasting than the daily precipitation over the whole basin, and demonstrated that, in this sense, even a very small basin may be important for forecasting. Furthermore, this technique proved important to help identify the more important lags, and also reveals that, even components that have less influence, can act for potentiating the other variables or components whose actions acts to increase the performance of the model predictions.

SUMÁRIO

AGRADECIMENTOS.....	iii
RESUMO	iv
ABSTRACT	vi
LISTA DE FIGURAS	x
LISTA DE TABELAS	xii
1. INTRODUÇÃO	1
2. OBJETIVO	2
3. REVISÃO BIBLIOGRÁFICA	5
3.1. Controle de Montante e Efeitos de Escala	5
3.2. Modelos Hidrológicos	8
3.2.1. Classificação dos Modelos	9
3.2.2. Modelo Chuva-Vazão	10
3.2.3. Previsão de Vazão.....	11
3.3. Redes Neurais Artificiais Progressivas.....	12
3.3.1. Introdução.....	12
3.3.2. Histórico	14
3.3.3. O Neurônio Artificial	14
3.4.4. Arquitetura das Redes Neurais Artificiais Progressivas	17
3.4.5. Aspectos do Treinamento.....	19
3.4.6. Regra Delta.....	20
3.4.7. Algoritmo Retropropagativo	22
3.4.8. Superajustamento.....	24
3.4.9. Análise de sensibilidade	25
3.4.10. Previsão de vazão com RNA.....	28
4. MATERIAIS E MÉTODOS.....	31
4.1. Área de Estudo.....	31

4.2. Dados Pluviométricos.....	34
4.3. Dados Fluviométricos.....	41
4.4. Métodos	46
5. RESULTADOS.....	52
6. CONCLUSÕES E RECOMENDAÇÕES	65
6.1. Conclusões referentes à pesquisa	65
6.2. Recomendações e sugestões	66
7. REFERÊNCIAS BIBLIOGRÁFICAS	68

LISTA DE FIGURAS

Figura 3.1. Representação esquemática de um modelo geral.....	8
Figura 3.2. Neurônio Biológico	13
Figura 3.3. Conexões entre neurônios.....	13
Figura 3.4. Neurônio Artificial	15
Figura 3.5. Principais funções de ativação	16
Figura 3.6. Rede neural de múltiplas camadas.	18
Figura 3.7. Modelo com redes neurais.	20
Figura 3.8. Taxa de aprendizado.....	21
Figura 4.1. Localização da bacia no Estado do RS.....	31
Figura 4.2. Bacia de Ponte Mística e as sub-bacias embutidas	32
Figura 4.3. Valores médios, mínimos e máximos, mensais de chuva (entre 1991 e 2010) do posto pluviométrico de Cruz Alta.	34
Figura 4.4. Postos de chuva da ANA.....	35
Figura 4.5. Distribuição dos postos de precipitação na bacia do Potiribu	37
Figura 4.6. Comparação da precipitação média mensal de Ponte Mística no ano 1989 com a da série histórica de Cruz Alta (entre 1991 e 2010).	39
Figura 4.7. Comparação da precipitação média mensal de Ponte Mística no ano 1990 com a da série histórica de Cruz Alta (entre 1991 e 2010).	39
Figura 4.8. Comparação da precipitação média mensal de Ponte Mística no ano 1991 com a da série histórica de Cruz Alta (entre 1991 e 2010).	39
Figura 4.9. Comparação da precipitação média mensal de Ponte Mística no ano 1992 com a da série histórica de Cruz Alta (entre 1991 e 2010).	40
Figura 4.10. Comparação da precipitação média mensal de Ponte Mística no ano 1993 com a da série histórica de Cruz Alta (entre 1991 e 2010).	40
Figura 4.11. Comparação da precipitação média mensal de Ponte Mística no ano 1994 com a da série histórica de Cruz Alta (entre 1991 e 2010).	40
Figura 4.12. Disposição dos postos fluviométricos na bacia em estudo.	42
Figura 4.13. Limites temporais utilizados na previsão.	43
Figura 4.14. Vazões das médias dos meses na bacia da Ponte Mística (1989 a 1991)...	44
Figura 4.15. Vazões das médias dos meses na sub-bacia de Santo Ângelo (1989 a 1991).	44

Figura 4.16. Vazões das médias dos meses na sub-bacia de Colônia Mousquer (1989 a 1991).	44
Figura 4.17. Vazões das médias dos meses na sub-bacia de Passo do Faxinal (1989 a 1991).	45
Figura 4.18. Vazões das médias dos meses na sub-bacia de Potiribu (1989 a 1991).	45
Figura 4.19. Vazões das médias dos meses na sub-bacia de Turcato (1989 a 1991).	45
Figura 5.1. Gráfico da vazão calculada x vazão observada para a alternativa 1.	55
Figura 5.2. Gráfico da vazão calculada x vazão observada para a alternativa 2.	55
Figura 5.3. Gráfico da vazão calculada x vazão observada para a alternativa 3.	55
Figura 5.4. Gráfico da vazão calculada x vazão observada para a alternativa 4.	56
Figura 5.5. Gráfico da vazão calculada x vazão observada para a alternativa 5.	56
Figura 5.6. Gráfico da vazão calculada x vazão observada para a alternativa 6.	56
Figura 5.7. Gráfico da vazão calculada x vazão observada para a alternativa 7.	57
Figura 5.8. Gráfico da vazão calculada x vazão observada para a alternativa 8.	57
Figura 5.9. Gráfico da vazão calculada x vazão observada para a alternativa 9.	57
Figura 5.10. Proporção de área controlada das bacias de montante e a eficiência do modelo.....	63

LISTA DE TABELAS

Tabela 4.1. Postos de chuva da ANA.....	35
Tabela 4.2. Postos de chuva do projeto da bacia do Potiribu.....	38
Tabela 4.3. Postos Fluviométricos utilizados nesse estudo.....	41
Tabela 4.4. Alternativas de entradas das redes neurais usadas como controle para estimativa da vazão na Ponte Mística.	49
Tabela 5.1. Resultados dos autocorrelogramas (Ponte Mística com Ponte Mística) e dos intercorrelogramas (Ponte Mística com postos de controle de montante).	52
Tabela 5.2. Entradas da rede, proporção de área controlada (%), número de registros e ciclos e estatísticas de desempenho da RNA na previsão de vazão.....	53
Tabela 5.3. Resultados da análise de sensibilidade.	59

1. INTRODUÇÃO

As previsões de curto prazo são baseadas em dados de variáveis de estado, que são atualizados continuamente no tempo. Para cada “tempo atual”, uma previsão é emitida para o futuro próximo. Esta previsão costuma ser feita para intervalos pequenos, desde minutos até alguns dias (Lettenmaier e Wood, 1993), pois o intervalo entre a previsão e a realização é uma região temporal desconhecida, não controlada, e quanto maior for esse intervalo, maiores serão as incertezas da previsão. No caso específico das previsões hidrológicas, as ocorrências hídricas neste intervalo, cujo limite extremo é o horizonte de previsão, são informações desconhecidas (Pedrollo, 2000).

A previsão hidrológica de curto prazo é comumente utilizada na operação de sistemas hidráulicos e no sistema de alerta para ocorrências de desastres naturais. Na operação de sistemas hidráulicos ela é aplicada para a previsão de vazões afluentes a um reservatório, de modo a permitir melhores decisões quanto à operação do mesmo, visando à manutenção de um volume necessário, tanto para o pleno funcionamento do reservatório, no atendimento às condições de aproveitamento hídrico (Castanharo e Mine, 2001; Andreolli, 2003; Bravo et al., 2008a; Satarri et al., 2012), quanto para a manutenção de um volume de espera, para o controle de cheias (Bravo et al., 2008b). As previsões também podem ser usadas nos sistemas de proteção contra inundação (Koussis et al., 2003; Rabuffetti e Barbero, 2005; Napolitano et al., 2010; Alfieri et al., 2012), onde as previsões de níveis fluviais podem ser utilizadas para identificação de áreas que serão, conseqüentemente, inundadas (Todini, 1999), possibilitando que posteriormente, se necessário, sejam tomadas providências, como o fechamento de comportas, alerta de enchentes e mobilização da defesa civil. Além desses usos, a previsão de curto prazo também é utilizada na irrigação (Tucci et al., 1987).

Uma bacia hidrográfica pode ser dividida em sub-bacias, cada uma das quais possuirá uma seção de controle própria, que é seu exutório. Em previsão hidrológica, quando são utilizados modelos com uma componente de propagação fluvial, tem-se uma região não controlada, entre a seção de montante e o exutório, onde são feitas as previsões. A seção fluviométrica de controle das entradas a montante de onde deseja-se fazer a previsão pode ser chamada, simplesmente, de controle de montante. As bacias embutidas ocorrem normalmente na natureza, com seus limites delimitados em função da determinação de um controle de montante, e consiste em uma bacia menor encaixada

em bacias maiores, onde existe a transferência de informações das bacias menores para as maiores.

Vários tipos de modelos podem ser usados para se fazer previsão de vazões, entre eles, os modelos estocásticos (Benedito et al., 2007), os modelos de base física (Brun e Tucci, 2001), e os modelos de redes neurais artificiais (RNA) (Figueiredo et al., 2007). Os modelos de RNAs foram os escolhidos para este estudo, pois seu uso na modelagem de sistemas não lineares complexos tem apresentado resultados encorajadores. Nestes modelos, pode ser usado o algoritmo de treinamento retropropagativo (Rumelhart et al., 1986), baseado na retropropagação dos erros, que primeiro viabilizou o treinamento de redes de múltiplas camadas. Alguns exemplos podem ser citados, como Dawson e Wilby (2001), Machado (2005) e Sousa e Sousa (2010), que utilizaram RNAs como modelos chuva-vazão para este fim. Batista (2009) realizou um estudo no Rio Grande em Minas Gerais para a previsão de vazões utilizando RNAs, produzindo resultados que podem ser utilizados em tomadas de decisões na operação de reservatórios destinados à geração de energia elétrica. Gomes et al. (2010) utilizaram uma rede neural de múltiplas camadas com treinamento com o algoritmo retropropagativo para a previsão de vazão, obtendo bons resultados na bacia do rio São Francisco.

Uma forma de se avaliar a importância das entradas em modelos com RNAs é através da comparação do desempenho destes com a utilização ou não das informações de cada uma delas. Em sub-bacias embutidas, o modelo para a previsão de vazões utilizando RNAs pode ser aplicado sistematicamente, da menor para a maior bacia, através da utilização, além das precipitações, de dados das afluições observadas, exclusivamente, em cada uma das respectivas seções de controle.

As séries temporais podem ter dados registrados com diferentes períodos, em minutos, horas, dias, meses, sendo que cada detalhamento temporal pode produzir resultados com diferentes desempenhos, quando aplicadas como entradas em modelos hidrológicos.

A influência relativa de cada sub-bacia, bem como de cada alternativa investigada, pode ser estimada pela comparação dos desempenhos dos modelos utilizados, desde que estes pertençam à mesma categoria de modelos, e sejam genéricos o suficiente para uso nas diferentes situações, o qual é o caso das RNAs.

Além disso, existem recursos para a análise da influência relativa de cada variável explicativa, que participa do modelo de RNA (Olden et. al., 2004), os quais, neste

trabalho, podem desempenhar um papel importante, na medida que possam confirmar ou complementar os resultados obtidos.

Ao se trabalhar com modelagem hidrológica é sempre importante possuir algum conhecimento do local onde os dados foram coletados e dos dados em si. Nos modelos de RNA é necessária uma análise dos dados a fim de se descobrir, por exemplo, onde estão localizadas temporalmente, nas séries, as maiores vazões, os picos de chuvas, os períodos onde existem falhas, e assim fornecer suporte para a seleção dos dados para a aplicação das redes neurais.

A realização deste estudo na bacia do rio Ijuí no RS é motivada, principalmente, pela existência de conhecimento e dados acumulados ao longo de uma sequência de projetos desenvolvidos nesta área, pelo IPH – UFRGS, em convênio com algumas instituições de pesquisa e apoio à pesquisa (ORSTOM, CNPq, FAPERGS, FINEP). Contribuiu para esta escolha o fato de que esta bacia não é afetada por grandes obras hidráulicas, permitindo que a pesquisa possa ser efetuada com modelos hidrológicos apenas, sem ter de considerar intervenções operacionais. A influência antrópica atua, principalmente, no que diz respeito à ocupação do espaço e à variação de técnicas de cultivo. Este último aspecto afetou a escolha dos períodos de tempo utilizados no estudo.

2. OBJETIVO

Este trabalho se desenvolveu a partir da formulação das seguintes hipóteses:

1. O controle em uma sub-bacia de montante pode fornecer melhorias significativas nos resultados de previsão de vazão no exutório da bacia principal, sendo dependente da proporção da área controlada;
2. A utilização de vazões de entrada com um maior detalhamento temporal (vazões horárias) que as vazões de saída podem proporcionar melhorias importantes na previsão.

O objetivo deste trabalho é analisar o efeito do controle de montante em sub-bacias embutidas na previsão hidrológica de curto prazo, com a investigação conjunta de dois aspectos: variação da área controlada em bacias a montante; e variação do detalhamento temporal dos dados de vazões de entrada do modelo (dados diários e horários).

O trabalho foi realizado em 3 etapas, sendo que, em todas elas, foi estimada a vazão média diária para um dia à frente em um mesmo posto, utilizando para isso, além dos dados diários de vazão deste posto: a) diferentes alternativas de postos de controle a montante, com as respectivas áreas de contribuição; b) dados diários e horários de vazão para a bacia de contribuição menor (19,5 km²); c) dados atuais (tempo t) e dados de 24 hs (t-1 dias) e 48 hs (t-2 dias) anteriores ao dia da previsão.

Foram utilizados modelos construídos com redes neurais artificiais, e as experimentações foram feitas na bacia do rio Ijuí, considerando o exutório no posto fluviométrico da Ponte Mística.

3. REVISÃO BIBLIOGRÁFICA

3.1. Controle de Montante e Efeitos de Escala

A bacia hidrográfica é um conjunto de terras drenadas por um rio principal e seus afluentes, que faz convergir os escoamentos para um único local de saída, conhecido como exutório da bacia (Guerra, 1966).

Esse estudo levará em conta os fatores de escala através da compreensão dos processos que ocorrem em bacias embutidas, analisando a transferência de informações das bacias menores para as maiores e a influência que elas causam.

A transferência e a utilização de informações entre bacias de diferentes tamanhos encaixadas umas nas outras depende da existência de características similares entre elas, como limites geomorfológicos (De Boer, 1992).

Para Franchini et al. (2011), a distância entre as bacias montante e o exutório é muito importante. No caso da previsão de variáveis hidrológicas quanto menor é a distância, maior é a área controlada, porém, o horizonte temporal de viabilidade para a previsão fica reduzido.

Existe também a perda de eficiência conforme se aumenta o horizonte de previsão, para a mesma bacia incremental, pois parte das informações necessárias para a previsão estão dentro do horizonte temporal, portanto, ainda indisponíveis. Goswami e O'Connor (2007) verificaram no seu trabalho que conforme o horizonte de previsão aumentou, diariamente, de um para seis dias, o coeficiente NS do seu modelo de previsão foi reduzido de 0,90 para 0,52.

O comportamento hidrológico de uma bacia pode ser analisado em diferentes escalas, podendo ser micro, meso ou macro-escala. Ao se trabalhar em uma micro-escala os resultados encontrados são mais precisos, porém, esses resultados serão pontuais, como por exemplo, a coleta de água em um rio. Para bacias de pequeno e médio porte, é preciso analisar o comportamento hidrológico em uma meso-escala. Através do estudo de sub-bacias embutidas é possível observar a mudança no comportamento das variáveis hidrológicas em função das sub-bacias utilizadas (Mendiondo, 1995; Mendiondo e Tucci, 1997). Se considerarmos como pequenas bacias aquelas menores que 50 km², é possível constatar que existe uma carência de dados

fornecidos pela ANA, já que a rede hidrometeorológica brasileira contempla praticamente apenas bacias de grande porte, maiores que 500 km² (Silveira, 1997).

Girardi et al. (2011) buscaram avaliar os efeitos de escala de bacias embutidas através da análise dos dados de chuva e vazão em bacias localizadas no noroeste do Rio Grande do Sul, com os resultados indicando que a chuva apresenta distribuição similar em todas as bacias, porém diferentes escalas de bacia sob mesma condição de chuvas proporcionaram diferentes respostas para a vazão específica, no que se refere a variações entre valores extremos e o amortecimento das vazões máximas.

Silva Júnior (2001) e Silva Júnior et al. (2003) analisaram o comportamento dos processos hidrológicos em diferentes escalas, de forma a identificar os erros potenciais das estimativas das variáveis hidrológicas de pequenas bacias a partir da regionalização destas variáveis com base em dados das grandes bacias. Neste estudo foram utilizados dados da bacia do Potiribu, afluente do rio Ijuí, que contém bacias embutidas em diferentes escalas (0,125 a 19,5 km²), para o período de 1989 a 1998. Também foram utilizados dados das bacias maiores (628 a 9.420 km²) na região do rio Ijuí. Foram analisados os volumes de cheia, as vazões máximas e as vazões mínimas, além da curva de permanência. Os resultados mostraram que a menor bacia (bacia de Anfiteatro de 11 ha), apresenta pouca regularidade de vazão, passando a maior parte do tempo sem vazões, de forma que praticamente só existem vazões quando chove. Foi verificado que essa bacia de 11 ha apresenta comportamento similar aos das bacias de meso-escala para as variáveis hidrológicas estudadas. Os resultados também mostraram que para vazões médias de cheias, a extrapolação superior não apresenta grandes incertezas e na inferior o erro foi pequeno para bacias até 20 km². Para as vazões $Q_{7,10}$ verifica-se uma boa extrapolação superior e inferior até 10 km², para bacias menores que 10 km² ocorre a superestimativa.

Castro et al. (1999) estudaram os efeitos que a mudança do uso do solo pode causar nos processos erosivos e hidrológicos nas bacias embutidas de pequena escala de, Anfiteatro (0,14 km²), Donato (1 km²) e Turcato (19,5 km²). A comparação dos escoamentos em diferentes escalas, variando de uma pequena área para bacias de vários km², indicou que uma relativa diminuição no escoamento nas encostas leva a um maior fluxo sub-superficial de água. Os resultados mostraram que a mudança no uso do solo de plantio convencional para o plantio direto causou uma redução na perda de solo. Com relação ao coeficiente de escoamento para as diferentes escalas, foi possível observar que, para a bacia de Anfiteatro, que não possui um canal permanente, o

coeficiente de escoamento foi significativamente grande no caso do plantio convencional se comparado com o método do plantio direto, enquanto que, para a bacia do Donato, que possui um canal de rio permanente, essa diferença foi muito menor. Já para a bacia do Turcato a diferença é reversa, o escoamento superficial tende a aumentar com a mudança do uso do solo do plantio convencional para o plantio direto.

A utilização de bacias a montante é muito importante, visto que, nos exutórios destas bacias, que podem ser chamados de seções de controle de montante, ou apenas controle de montante, são coletadas informações sobre a bacia maior em um determinado ponto no seu interior, informações estas como picos de vazões, que podem ser amortecidas durante o percurso e não serem apresentados no exutório da bacia principal.

Pedrollo e Lanna (1991) apresentam um estudo de previsão de cheias em tempo atual com a utilização de modelos empíricos lineares e um modelo empírico-conceitual, na bacia do Alto Iguaçu (24.900 km²), nos estados de Santa Catarina e Paraná, onde é avaliada a influência das contribuições laterais, do trecho entre as bacias de montante (Porto Amazonas (3.662 km²), Rio Negro (3.379 km²), Fluvópolis (18.300 km²) e o exutório em União da Vitória (24.211 km²)).

Madsen e Skotner (2005) também destacam a importância das contribuições laterais nos trechos entre bacias de montante e no exutório, para a previsão de vazão em tempo real com o modelo conceitual MIKE 11, em Manila Bay (611 km²), nas Filipinas. Foram utilizadas informações de bacias de montante (San Juan (90,4 km²), Marikina (354,7 km²) e Pasing (514 km²)) para prever as vazões no exutório.

Fadiga et al. (2008) utilizam as informações das sub-bacias de montante para a previsão de vazão no exutório. Foram utilizados os modelos SMAP (soil moisture accounting procedure) e MEL (modelo estocástico linear) na bacia do rio Paraná (150.900 km²), no trecho compreendido entre as usinas hidrelétricas de Rosana, Porto Primavera e Itaipu. A bacia incremental de Itaipu apresenta 68% da sua área de drenagem controlado por 5 postos fluviométricos, Estrada Iguatemi (4,76%), Ivinhema (21,14%), Novo Porto Taquara (22,80%), Balsa Santa Maria (13,65%) e Flórida (5,65%). As informações utilizadas foram vazões e precipitações (observadas e previstas) e os resultados foram bons quando as entradas nos modelos foram informações observadas, porém, os resultados pioraram significativamente quando as precipitações previstas foram utilizadas.

Na Índia, um país que sofre com enchentes causadas principalmente pelas monções, Tiwari e Chatterjee (2010) elaboraram um modelo de previsão com redes neurais artificiais com seus resultados sendo utilizados na tomada de decisão para reduzir o risco de inundação na bacia do rio Mahanadi (141.589 km²), e para tanto foram utilizadas informações horárias de níveis do rio em 5 postos de montante. Com os resultados foi possível observar a melhoria dos resultados conforme são acrescentadas informações das bacias de montante.

No trabalho de Kerh e Lee (2006), foram utilizadas informações procedentes das bacias de montante na previsão de vazões de curto prazo com redes neurais artificiais, no exutório da bacia em Lilin Bridge (3.257 km²), no sul de Taiwan. Neste trabalho foram utilizados dados de vazões de três postos de controle de montante (Shinfa Bridge (1.373 km²), Sanlin Bridge (802 km²) e Santimen (642 km²)), além de informações fisiográficas, onde foram encontrados coeficientes NS acima de 0,91 para todas as alternativas aplicadas.

3.2. Modelos Hidrológicos

Modelo é uma representação simplificada de um objeto ou sistema, de fácil acesso e uso, desenvolvido com o objetivo de entendê-lo e encontrar respostas para diferentes circunstâncias (Tucci, 1998). Com os modelos é possível encontrar respostas (saídas) importantes de uma bacia hidrográfica a partir de informações (entradas) dela (Figura 3.1).

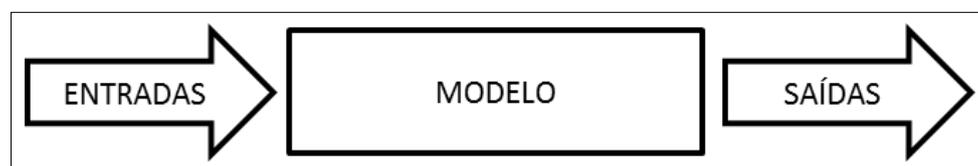


Figura 3.1. Representação esquemática de um modelo geral.

Segundo Chow (1964), dados científicos podem ser classificados quantitativamente em dois tipos, experimentais e históricos. Os dados experimentais podem ser medidos e obtidos através de experimentos. Os dados históricos, por outro lado, são coletados de fenômenos naturais e só podem ser observados uma vez.

Os modelos hidrológicos são ferramentas matemáticas utilizadas para representar o comportamento dos elementos que compõem o ciclo hidrológico de modo a produzir resultados próximos aos encontrados na natureza. Devido à complexidade de se representar os fenômenos naturais, a modelagem hidrológica trabalha com simplificações desses fenômenos.

3.2.1. Classificação dos Modelos

Segundo Chow (1964), Dooge (1973), Salas (1993) e Tucci (2007), os modelos hidrológicos podem ser classificados em: contínuo e discreto; concentrado e distribuído; estocástico e determinístico; conceitual e empírico; estacionários e não estacionários.

Um sistema é considerado contínuo quando os fenômenos que o formam são contínuos no tempo, e discreto quando as mudanças de estado se dão em intervalos discretos. Um exemplo da utilização de uma variável contínua no tempo são os níveis de um rio, que é registrado de forma contínua através de um linígrafo mecânico, sendo a variável discreta a anotação do registro feita pelo observador, que têm a função de coletar os dados em uma determinada hora do dia.

O modelo é concentrado quando não leva em conta a variabilidade espacial das variáveis, considerando como uniformes as características da bacia e valores médios para estas variáveis. No modelo distribuído, por outro lado, as variáveis e parâmetros do modelo dependem do espaço e/ou tempo.

Um modelo é considerado determinístico, se todas as variáveis forem consideradas sem aleatoriedade, assim, para uma determinada entrada o sistema produzirá sempre a mesma saída. As características do modelo devem possuir relações exatas e não funções de densidade de probabilidade. Por outro lado, se qualquer uma das variáveis presentes no modelo é considerada como variável aleatória e o conceito de probabilidade é introduzido no modelo, este é denominado estocástico.

Os modelos são tidos como empíricos ou “caixa-preta” quando se procura ajustar os dados calculados aos dados observados, sem considerar explicitamente a relação entre as funções utilizadas e os processos físicos. Já nos modelos conceituais, os processos físicos são levados em conta quando da elaboração das funções que irão compor o modelo. Para a aplicação de modelos conceituais existe a necessidade de uma

grande quantidade de dados, tais como, precipitação, evapotranspiração, vazão, entre outros, o que dificultar a sua utilização.

Um processo é dito estacionário caso suas propriedades estatísticas não sofram alterações com o tempo, e não-estacionário quando ocorre o oposto. Em uma série estacionária em relação à média, esta não se altera ao longo do tempo, enquanto que as séries não estacionárias podem apresentar tendências de subida ou descida, ou ainda periodicidade dos dados.

Os modelos chuva-vazão empíricos com redes neurais artificiais vem sendo muito utilizados com interesse apenas nos resultados, sem buscar o entendimento do funcionamento físico dos processos, enquanto alguns autores vêm aplicando as RNAs justamente para buscar este entendimento (Maier e Dandy, 2000; Dawson e Wilby, 2001).

3.2.2. Modelo Chuva-Vazão

Existe uma grande quantidade de modelos chuva-vazão, desde os mais simples, como o método racional, até os mais complexos, como os modelos conceituais distribuídos, que consideram a variabilidade espacial e temporal de um evento chuvoso, bem como as características da bacia.

Um dos primeiros modelos chuva-vazão foi desenvolvido pelo U.S. Army Corps of Engineers em 1958, o SSARR (Streamflow Synthesis and Reservoir Regulation), um modelo conceitual que tinha por finalidade simular o ciclo hidrológico e a regularização de vazão no rio Columbia. Outros modelos importantes desenvolvidos nessa época foram o STANFORD IV (Crawford e Linsley, 1966); o HEC-1 Flood Hydrograph Package do U.S. Army Corps of Engineers criado em 1973; e o Mero, modelo desenvolvido por Clarke (1973). Os modelos mais antigos buscavam representar melhor o ciclo hidrológico.

Com a evolução tecnológica a partir dos anos 80, os modelos passaram a mudar um pouco o foco, tentando resolver situações específicas como fazer previsões de cheias, melhorando o ajuste dos parâmetros e avaliando a interligação entre os parâmetros e as características físicas da bacia.

Os modelos mais complexos tendem a produzir resultados mais precisos, porém a necessidade de uma grande quantidade de dados se torna um empecilho para sua

utilização. Assim, uma rigorosa análise dos dados existentes fornece subsídios para a escolha, entre os modelos mais simples ou mais complexos, do que melhor se adequa.

Os modelos hidrológicos apresentam incertezas, geralmente, relacionadas com: a incapacidade de representar alguns processos; a existência de dados deficientes; e a variação dos parâmetros para representar o sistema.

Os principais usos para os modelos chuva-vazão são: o estudo do comportamento dos fenômenos hidrológicos; análise de consistência; preenchimento de falhas; previsão de vazão; previsão de cenários de planejamento; estudo dos efeitos resultantes da modificação do uso do solo (Tucci, 1998). Além disso, observa-se o uso em previsão de níveis, estudo do efeito de mudança climática, extensão de séries e criação de séries sintéticas.

3.2.3. Previsão de Vazão

Segundo Lettenmaier e Wood (1993), previsão é a estimativa de condições em um tempo específico futuro ou durante um determinado intervalo de tempo. Ela é diferente de predição, que realiza a estimativa de condições futuras em função de um tempo de recorrência. São exemplos de previsão, prever o nível ou a vazão de um rio em um determinado período de tempo. Enquanto isso, podemos chamar de predição a estimativa da cheia de 100 anos de tempo de retorno de um determinado rio.

A previsão de vazão é a estimativa futura dos valores de vazão para um determinado período de tempo. A previsão é classificada levando em conta o intervalo de tempo futuro em previsão de curto e longo prazo.

A mudança climática e fenômenos como o El Niño e La Niña, segundo Lima e Lall (2010) fazem com que as relações entre as variáveis hidrológicas utilizadas na previsão apresentem um comportamento diferente, o que pode afetar os resultados de modelos de previsão previamente ajustados.

Segundo Georgakakos e Krzysztofowicz (2001), a previsão de curto prazo pode ser realizada com uma antecedência de poucas horas até alguns dias, enquanto a previsão de longo prazo possui uma abrangência temporal bem maior, podendo, segundo esses autores, chegar a nove meses.

A previsão de curto prazo é realizada com horizontes pequenos de tempo, desde alguns minutos até alguns dias (Tucci et al., 2002). Essa previsão pode ser realizada

utilizando posto à montante além de dados de precipitação, ou mesmo previsão da precipitação (Dornelles, 2007).

A previsão de curto prazo é utilizada principalmente para o controle de inundações em regiões ribeirinhas e para melhorar a operação de sistemas hidrelétricos. Ela também é bastante utilizada para a previsão de níveis para a navegação, disponibilidade hídrica para a irrigação, abastecimento de água e alerta de cheias.

Andreolli (2003) utilizou a previsão de curto prazo para avaliar os benefícios da utilização de precipitações previstas para a estimativa de vazões, tendo como base o modelo meteorológico regional conjugado com o modelo hidrológico distribuído. Os resultados apresentaram benefícios pela utilização do modelo com precipitações previstas, tendo resultado em uma importante ferramenta na melhoria da operação de reservatórios. A previsão foi realizada no rio Uruguai com o exutório na hidrelétrica de Machadinho, entre os estados de Santa Catarina e Rio Grande do Sul.

Koussis et al. (2003) apresentam um modelo integrado hidro-meteorológico de previsão na bacia urbana de Kifissos em Atenas, Grécia. Esse autor através desse modelo buscou reduzir os danos causados por enchentes no local. Apesar de produzir resultados interessantes, o modelo é limitado pelas incertezas da previsão quantitativa da chuva, tendo sido encontrados inclusive erros bastante significativos.

Segundo Lettenmaier e Wood (1993), os erros que ocorrem quanto à previsão de vazão de longo prazo podem ser de três tipos: devido a erro no modelo, causado pela má conceitualização do modelo; erro de dados, causado pela utilização de dados problemáticos como entrada no modelo; e por erros na previsão meteorológica, através de erros causados na previsão de variáveis de entrada no modelo, como precipitação e temperatura.

3.3. Redes Neurais Artificiais Progressivas

3.3.1. Introdução

O sistema nervoso dos seres humanos é composto basicamente por um conjunto de células, os neurônios. São os neurônios os responsáveis pela recepção e transmissão dos estímulos do meio interno e externo, tendo um papel fundamental no comportamento e funcionamento do corpo humano. Os neurônios biológicos são

formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída (Figura 3.2).

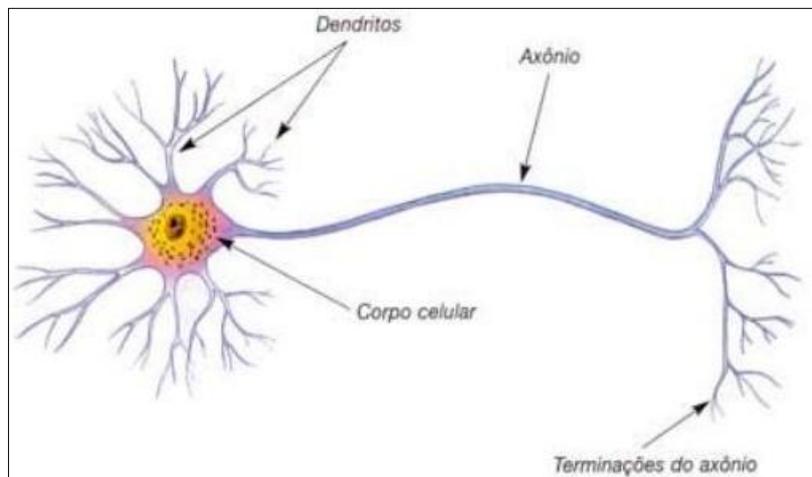


Figura 3.2. Neurônio Biológico (Fonte: Machado, 2005).

A comunicação entre os neurônios é realizada através da sinapse, local onde dois neurônios se conectam e a partir do qual os impulsos são transmitidos. Os impulsos recebidos por um neurônio através dos seus dendritos são acumulados no corpo central, o qual, após atingir certo limiar de carga, dispara, transferindo o impulso através do seu axônio para os dendritos de outro neurônio (Figura 3.3). Ao passar de um neurônio para outro esse sinal pode ser atenuado ou amplificado, dependendo de alguns fatores. É com base principalmente nesses processos que as RNA são utilizadas.

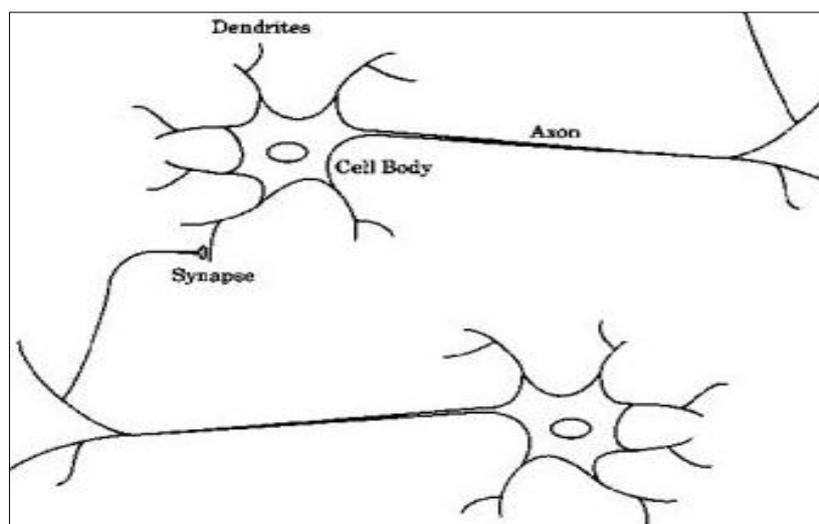


Figura 3.3. Conexões entre neurônios (Fonte: Hagan et al., 1996).

3.3.2. Histórico

Os primeiros estudos de modelos matemáticos baseados em um neurônio biológico foram realizados por McCulloch e Pitts (1943), onde o comportamento do neurônio natural é simulado, com uma saída para diversas entradas, estabelecendo-se uma analogia entre este e os processos eletrônicos. Já Hebb (1949), propôs um mecanismo de aprendizado das redes neurais artificiais em função dos mecanismos observados de aprendizado dos neurônios biológicos. A primeira aplicação prática das RNAs, porém, veio com o trabalho de Rosenblatt (1958), com a invenção da rede de uma camada denominada perceptron, sendo essa a primeira rede com a capacidade de identificar padrões, graças a um algoritmo próprio de treinamento.

Widrow e Hoff (1960) introduzem um novo algoritmo de aprendizado, a regra delta, utilizando-o no treinamento de uma rede neural adaptativa. Mesmo com a importante evolução das redes de uma camada, Minsky e Papert (1969) fizeram duras críticas às pesquisas sobre RNA por causa de suas limitações, como a incapacidade para aproximar funções não unívocas, além de não resolver o problema lógico da disjunção exclusiva. Conseqüentemente, os anos seguintes não produziram progressos significativos nessa área. Porém, essas críticas levaram os autores que pesquisavam RNAs a terem mais rigor nos seus trabalhos.

A partir dos anos 80, em função principalmente da evolução tecnológica, e com a descoberta do método retropropagativo por Rumelhart et al. (1986), houve um maior interesse sobre o assunto. Desde então, com o desenvolvimento e a utilização de ferramentas computacionais, as redes neurais artificiais vem sendo cada vez mais utilizadas, tendo produzido bons resultados.

3.3.3. O Neurônio Artificial

O neurônio artificial, como é adotado atualmente, é uma evolução do modelo proposto por McCulloch e Pitts (1943), principalmente com a adoção de pesos sinápticos representados como números reais, no lugar de conexões lógicas, e de espectro mais amplo de funções de ativação, contemplando inclusive saídas no domínio dos números reais. A partir destes melhoramentos, devidos principalmente a Widrow e

Hoff (1969), pode-se descrever o neurônio artificial, segundo Haykin (1994), como sendo formado, principalmente, por três elementos (Figura 3.4):

1. Um conjunto de sinapses ou elos de conexão, onde cada conexão possui um parâmetro de ponderação das entradas numéricas chamado peso sináptico, ou simplesmente peso, e cujo valor resulta de um processo de treinamento, feito a partir de amostragem. Diferentemente do cérebro humano, o valor numérico do peso sináptico de um neurônio artificial pode assumir valores tanto positivos quanto negativos;
2. Um somador, que é responsável por somar os sinais de entrada, sendo essa operação uma combinação linear dos dados que entram no sistema, resultando na entrada líquida;
3. Uma função de ativação ou de transferência, que serve para modificar a saída de um neurônio, conferindo à rede a capacidade de simular fenômenos não lineares, tendo como efeito secundário a modificação da amplitude da saída. Geralmente, os valores das amplitudes das saídas modificadas são limitados ao intervalo fechado de $[0,1]$ ou $[-1,1]$.

O termo de tendência b_k , apresentado na Figura 3.4, permite que a saída do neurônio possa assumir valores diferentes de zero, mesmo para entradas líquidas nulas.

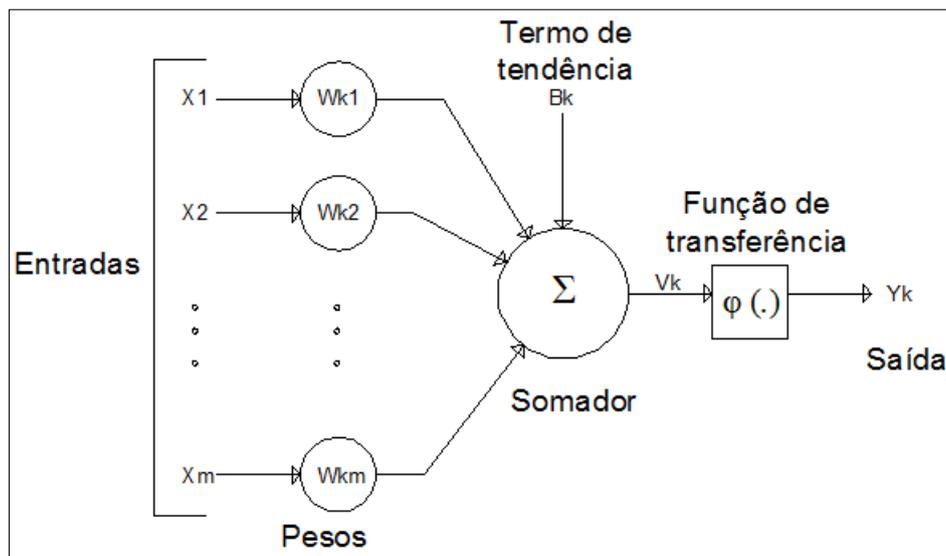


Figura 3.4. Neurônio Artificial.

A função de ativação afeta a saída de um neurônio a partir da transformação da entrada líquida. Kasabov (1996) classifica as principais funções de ativação utilizadas como: a) a função limiar, onde as saídas são classificadas em 1 ou 0; b) a função linear, que utiliza transformações lineares; c) a função sigmóide, cujo gráfico possui uma forma de “S” e é a principal função de ativação utilizada nas RNAs, e se caracteriza por ser uma função crescente, não linear, possuindo valores nos intervalos [0,1] para unipolar, ou [-1,1] para a bipolar. A Figura 3.5 apresenta algumas das principais funções de ativação.

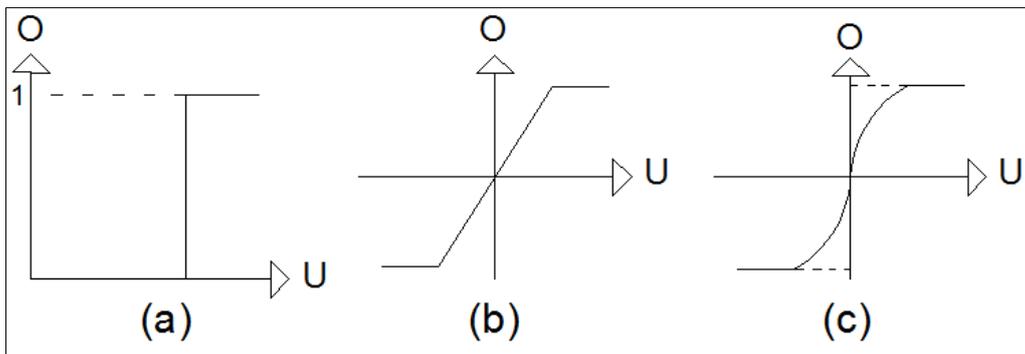


Figura 3.5. Principais funções de ativação (Fonte: Kasabov, 1996).

As equações 1 e 2 apresentam, respectivamente, as fórmulas da função de ativação sigmoide e da sua derivada, a qual é fundamental nos procedimentos de treinamento baseados na regra delta.

$$a = \frac{1}{1+e^{-n}} \tag{1}$$

$$f'_{(n)} = a(1 - a) \tag{2}$$

Onde:

a: é a saída da função de ativação;

n: é a entrada líquida ($n = WP + b$).

Pode-se estabelecer um mínimo para o resultado da função da derivada, de forma que o processo de treinamento não estacione em pontos de derivada zero, como ocorre nos extremos do domínio das variáveis de saída. Outro recurso muito utilizado para contornar a ocorrência da derivada zero é o escalonamento da variável de saída entre

extremos escolhidos com uma margem resultante além do domínio físico das variáveis reais, de forma que a variável de saída escalonada nunca resulte com os valores exatamente nos pontos extremos 0 ou 1.

3.4.4. Arquitetura das Redes Neurais Artificiais Progressivas

Redes neurais artificiais são, basicamente, compostas por estruturas lógico-matemáticas que simulam o funcionamento dos neurônios biológicos. Estas estruturas são chamadas de neurônios artificiais. A primeira etapa desta simulação consiste em uma soma ponderada das entradas (cujos pesos são representados graficamente por conexões), a qual é submetida a uma função (dita de ativação, e geralmente não linear). Estas operações, de soma ponderada e de submissão à função de ativação, ocorrem no núcleo do neurônio, que é o ponto de convergência das conexões, na representação gráfica. Os neurônios, em uma rede neural artificial, são, geralmente, dispostos em camadas, uma ou mais intermediárias e uma de saída (havendo uma camada anterior, de entrada, composta de nós, para receberem os sinais de entrada do modelo), o que facilita a construção de algoritmos de operação e de treinamento. As redes neurais progressivas podem ser, portanto, de uma ou mais camadas:

1. Rede neural de uma camada: Foi a primeira abordagem prática de redes neurais, sendo constituída por nós de entrada, conexões representadas pelos pesos sinápticos, e uma única camada de neurônios, cujas funções de ativação podem ser limiares (o Perceptron, de Rumelhart (1958)), lineares ou não-lineares (Widrow e Hoff, 1960). Ainda são muito utilizadas, principalmente em sistemas de comunicação, controle adaptativo e visão robótica;
2. Rede neural de múltiplas camadas: É a evolução natural das redes de uma camada, pela adição de camadas intermediárias entre os nós de entrada e as camadas de saída. O maior número de camadas intermediárias permite maior grau de liberdade, com o mesmo número de neurônios, para aproximação de funções. Porém, uma vez que apenas uma camada intermediária (figura 3.6), com número suficiente de neurônios, é

considerada eficiente, e tendo-se em conta as facilidades construtivas, esta é a arquitetura mais adotada.

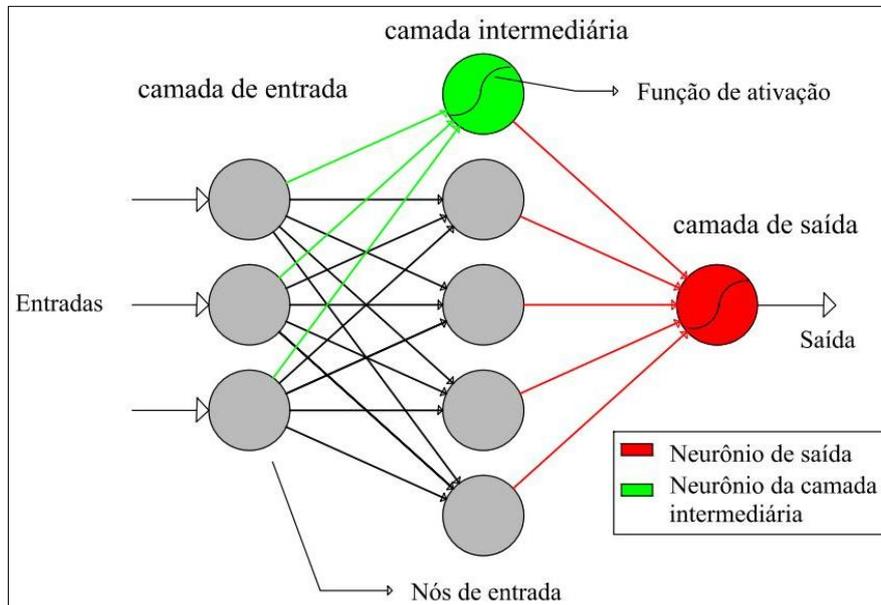


Figura 3.6. Rede neural de múltiplas camadas.

Uma vez que as funções de ativação utilizadas possuem domínio de saída restrito (Ex.: entre 0 e 1), as redes neurais constituem-se, na maioria dos problemas práticos, em partes de modelos, compostos também de transformações dos dados, as quais podem ser lineares ou não-lineares. Com o uso de escalonamento linear, tanto para as entradas quanto para as saídas, o modelo resultante pode ser representado pela equação 3:

$$\frac{(yt-bu)}{au} = \text{RN} \left(\frac{(xt-be)}{ae} \right) \quad (3)$$

onde:

xt e yt : Variáveis de entrada e de saída, respectivamente;

au e bu : Parâmetros de escala e de posição das saídas do modelo;

ae e be : Parâmetros de escala e de posição das entradas do modelo;

RN: Rede neural utilizada.

As redes neurais de múltiplas camadas são eficientes para aproximação de funções e possuem a capacidade de distinguir padrões complexos. Porém, inicialmente, embora seu potencial fosse sustentado por um teorema de Kolmogorov de 1957, o qual foi

posteriormente enunciado para redes neurais como o teorema de Kolmogorov-Nielsen (Hecht-Nielsen, 1990), não existia um método para seu treinamento. Este teorema estabelece que, para qualquer relação contínua com n entradas e m saídas, existe sempre uma rede neural progressiva com apenas uma camada interna de $2n+1$ neurônios capaz de aproximá-la.

As redes progressivas servem para fazer mapeamentos de entradas e saídas, porém apenas as redes de múltiplas camadas conseguem fazer esse mapeamento para processos não lineares e não necessariamente unívocos.

As entradas das redes neurais dependem diretamente do tipo de estudo que está sendo realizado. No caso das previsões de vazões, são as variáveis envolvidas no processo na área de abrangência do estudo, como precipitação e vazão. Porém, nem todas as variáveis resultam contribuições válidas nos modelos. Em alguns casos uma variável que não contribui pode piorar os resultados. Nessa linha, Maier e Dandy (1997) apresentam um estudo onde são utilizadas três metodologias diferentes para determinar as melhores opções de entradas em modelos multivariados de séries temporais, buscando assim, a redução do tamanho da rede e do tempo de treinamento. O primeiro método utilizou intercorrelações entre as séries temporais; O segundo método é o da análise de sensibilidade, com redes neurais artificiais, com cada variável sendo modelada separadamente, para fins de identificação das defasagens temporais (“lags”) de cada variável; já no terceiro, são considerados os fatores físicos conhecidos, como o tempo de deslocamento de massa de água ao longo de um rio. Os resultados mostraram que as três alternativas são boas para se determinar as melhores opções de entradas na rede, sendo o segundo método considerado o mais indicado por ser mais rápido e simples de ser utilizado. Os autores criticaram a avaliação com base nos correlogramas, por estes identificarem apenas os padrões lineares.

Von Zuben (2003) descreve a tipologia das aplicações para redes neurais. Esse trabalho foi importante, pois apresenta a conceituação e a exemplificação dos tipos de redes adequadas a cada tipo de problema, de uma maneira geral e de fácil compreensão.

3.4.5. Aspectos do Treinamento

Nas redes neurais progressivas é utilizado o treinamento supervisionado. Nesse treinamento, são submetidos à rede neural pares de entradas e saídas, com um conjunto

de saídas observadas sendo comparadas com as saídas calculadas. Assim, se houver diferenças entre as saídas observadas e as calculadas, a rede realiza um ajustamento dos pesos sinápticos de forma a minimizar os erros da rede neural.

Este treinamento é utilizado em recursos hídricos na aplicação de modelos que utilizam redes neurais, principalmente na previsão de variáveis hidrológicas como níveis, vazão, precipitação e umidade.

O escalonamento de dados tem por objetivo realizar uma transformação nestes, de modo a acelerar e melhorar o processo de aprendizagem da rede. Os parâmetros de transformação devem ser agregados ao modelo para operações futuras e para a recuperação da escala original dos resultados (Figura 3.7). Os cálculos dos parâmetros das transformações devem ser executados com dados representativos de todo o domínio desejado, inclusive para o uso futuro da rede. O escalonamento dos dados de entrada, quando se trabalha com diferentes séries temporais, se faz necessário, pois existe a possibilidade de as séries possuírem amplitudes de valores bem diferentes, o que afeta o treinamento, pois o procedimento favoreceria as variáveis de maior magnitude. O escalonamento dos dados de saída é utilizado em duas situações: quando existem mais de uma saída e elas estejam em diferentes escalas, o que afetaria o treinamento, da mesma forma como as entradas de magnitudes diferentes; e para se ajustar as variáveis de saída aos contradomínios da função de ativação.

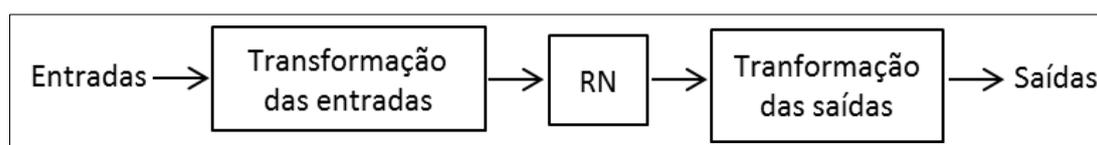


Figura 3.7. Modelo com redes neurais.

3.4.6. Regra Delta

A regra delta, proposta por Widrow e Hoff (1960), consiste em, inicialmente, se atribuir valores aleatórios aos pesos sinápticos e calcular o erro na saída da rede neural. O procedimento iterativo de treinamento é aplicado enquanto a estatística representativa dos erros não for aceita. Esta regra não só aproxima os pesos para o ideal, como faz isso de maneira eficiente. Inicialmente, a regra delta foi desenvolvida para redes de uma camada, e não era aplicada para redes mais complexas, pois esta é dependente do

conhecimento do erro na saída. A equação 4 apresenta a forma generalizada de correção dos pesos.

$$W_{k+1} = W_k + (\tau e_s \delta_k P_k) \quad (4)$$

Onde:

W são os pesos sinápticos; τ é a taxa de aprendizado; e_s são os erros das saídas da camada; δ_k é a derivada das funções ativação; e P_k são as entradas na própria camada.

A taxa de aprendizado é muito importante durante o processo de treinamento da rede neural, e afeta o “passo” de caminamento no espaço dos parâmetros. Se a taxa de aprendizado escolhida for muito grande, os pesos podem oscilar com uma grande amplitude, passando ao largo do mínimo global, enquanto que se a taxa for muito pequena, a convergência do algoritmo pode ser muito lenta, estacionando-se nas proximidades de um mínimo local (Kasabov, 1996), como apresentado na Figura 3.8.

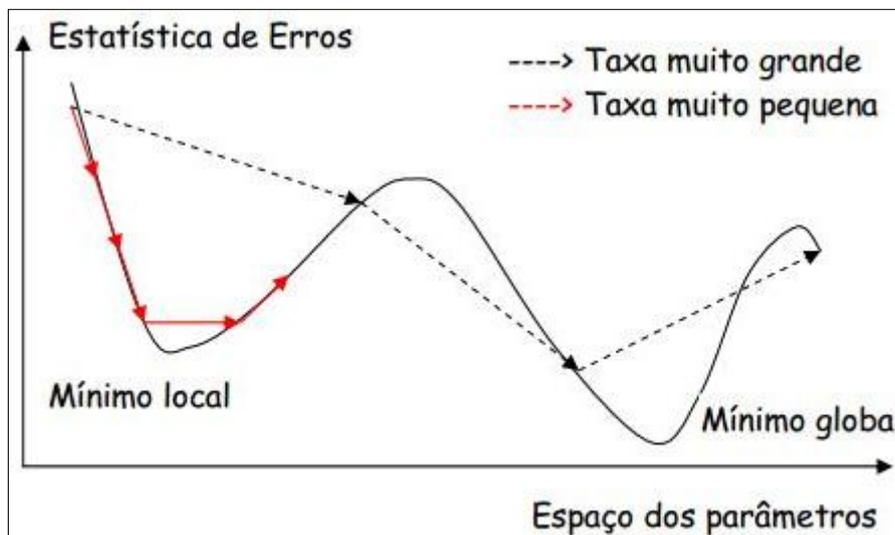


Figura 3.8. Taxa de aprendizado (Pedrollo, 2007).

A regra delta é importante, principalmente porque foi com base no seu funcionamento que se desenvolveu o algoritmo retropropagativo. Utiliza técnica de aprendizado do tipo gradiente descendente, com os erros das respostas provenientes de um neurônio afetando apenas as correções dos próprios pesos sinápticos. Apresenta um maior aprendizado para amostras com erros maiores, resultando assim, em classificações mais robustas, além de ajustes finais eficientes.

3.4.7. Algoritmo Retropropagativo

O uso de redes neurais disseminou-se a partir do desenvolvimento e apresentação, por Rumelhart et al. (1986), do algoritmo retropropagativo, o qual consiste de duas etapas, sendo que, na primeira, as entradas da rede são propagadas em um movimento para frente, camada por camada, até resultarem as saídas. As saídas calculadas são comparadas com as desejadas, gerando um erro. Na sequência, este erro é retropropagado, no sentido da entrada, e os pesos sinápticos da rede são ajustados conforme a regra delta de treinamento. A repetição deste processo fornece resultados cada vez melhores e erros cada vez menores, à medida que repetições (ciclos) do procedimento são aplicadas. O ponto de parada é pré-determinado, ou pelo número de ciclos ou por uma precisão estabelecida.

O processo de funcionamento do método retropropagativo pode ser melhor explicado a partir da equação 5, para o cálculo do erro em uma camada com base em informações da camada posterior.

$$e_h = \sum(W_s e_s \delta_s) \quad (5)$$

Onde:

e_h é o erro na camada de entrada; W_s são os pesos sinápticos na camada de saída; e_s são os erros na camada de saída; e δ_s são as derivadas da função de ativação na saída.

Para cada ciclo, são realizadas as seguintes etapas:

1. Atribuição inicial de pesos sinápticos aleatórios;
2. Aplica-se a rede neural, e a partir dos resultados e das observações respectivas, são calculados os erros da saída;
3. Com os erros, os pesos que foram atribuídos e as derivadas da saída, são calculados os erros da camada anterior (equação 5);
4. Com os erros da saída, suas derivadas, a taxa de aprendizado e entradas (resultantes da camada anterior), a regra delta (equação 4) é utilizada para atualizar os pesos sinápticos;
5. Com os erros da camada intermediária (obtidos na etapa 3), suas derivadas, taxa de aprendizado e entradas da rede, são atualizados os pesos desta camada (equação 4, regra delta);
6. O processo é repetido, desde a etapa 2, até ser obtida a condição de parada.

O principal critério de parada do treinamento é o da precisão desejada. Essa precisão pode ser representada por indicadores de duas naturezas: Erros (erro máximo, erro mediano, erro associado a uma frequência, etc.) admissíveis em um ciclo; e estatísticas de desempenho, onde, um desempenho mínimo, representado pelo erro quadrático, erro absoluto médio, etc., é requerido. É necessário um critério adicional, para a interrupção dos processos que não convergem, sendo o mais comum o número máximo de ciclos.

Em algumas aplicações o método retropropagativo não é muito eficiente, visto que exige um grande número de repetições para que haja uma convergência dos resultados (Vogl et al., 1988). Esse mesmo autor apresenta soluções práticas para melhoria do algoritmo retropropagativo, através de modificações do mesmo, buscando uma aceleração da convergência. Uma dessas modificações é a realização do aprendizado com uma taxa heurísticamente variada. Esta técnica consiste na aceitação dos pesos sinápticos com aumento da taxa de aprendizado, sempre que o erro, em um ciclo de treinamento sofrer redução. E na manutenção das estimativas anteriores dos pesos, com redução da taxa de aprendizado, quando o erro em um ciclo aumentar em relação ao erro no ciclo anterior. Os fatores multiplicativos recomendados, para a redução ou o aumento da taxa são, respectivamente, 0,5 e 1,1.

O método de treinamento é dependente das condições iniciais, a partir das quais o treinamento corre o risco de estacionar em mínimos locais. Este fenômeno é tanto mais frequente quanto mais complexa é a superfície de desempenho, cuja complexidade está associada à complexidade da rede e dos fenômenos aproximados.

Para contornar este problema, pode-se executar o treinamento com diversas partidas de pesos aleatórios, adotando-se o modelo cujo desempenho para a generalização (série de verificação) revelou-se melhor.

Dornelles (2007) apresenta um estudo onde o número de treinamentos a partir de condições aleatórias é experimentado, para o caso específico de modelos de previsões hidrológicas com redes neurais de múltiplas camadas, concluindo que, após 30 realizações, os melhoramentos possíveis de desempenho são muito pequenos.

3.4.8. Superajustamento

O superajustamento ocorre quando o treinamento consegue reproduzir até mesmo o comportamento individual, inclusive os erros e a aleatoriedade, das amostras de treinamento, o que prejudica a capacidade de generalização. Em geral, quando os resultados da verificação são muito bons, para os propósitos desejados, pode-se admitir que o superajustamento, ou não houve, ou foi irrelevante. Caso contrário, cuidados tornam-se necessários para evitá-lo.

Os métodos para evitar o superajustamento são a limitação da complexidade da rede (com graus de liberdade suficientemente reduzidos para que não permitam a reprodução das oscilações indesejadas), e a interrupção antecipada do treinamento (uma vez que, observa-se, a forma da reprodução proporcionada pela rede evolui a partir de uma explicação nula da variância em direção a complexidades crescentes).

O recurso mais conhecido de procedimento automático para a interrupção antecipada é a técnica da validação cruzada.

A técnica de validação cruzada utiliza, além da série de treinamento, uma série adicional (série de validação), para determinar o ponto de parada ótimo durante o treinamento, para que este não perca a sua capacidade de generalização, e dessa forma evitar o superajustamento. Outro conjunto de dados, chamado de série de verificação, que não faz parte daqueles dados utilizados para o treinamento da rede, é utilizado para a avaliação do desempenho da generalização. Nesta técnica verifica-se que o índice de desempenho do treinamento vai sempre diminuindo (indicando desempenho melhor), enquanto que o índice de desempenho da série de validação, a partir de determinado ciclo, torna a subir, indicando que um limiar foi atingido, a partir do qual a capacidade de generalização passa a estar comprometida. Este é o limiar de interrupção do treinamento (Stone, 1974).

Para a técnica de validação cruzada são utilizados três séries de dados, com proporções recomendadas de 50% para o treinamento, 25% para a verificação e os restantes 25% para a validação.

Em alguns casos, a utilização da validação cruzada é inviável, porque a quantidade de dados representativos disponíveis é excessivamente restrita, e esta técnica pressupõe a divisão dos registros amostrais em três séries distintas.

Quando o número de registros disponíveis não recomenda a divisão destes em três séries representativas, pode-se utilizar outros recursos, como:

1. A experimentação de número crescente de ciclos máximos, para treinamento do modelo em cada experimentação, com aproveitamento do treinamento que apresentou melhor desempenho, pois, a partir de um número exagerado de ciclos, ocorre o superajustamento. Adota-se, portanto, os pesos sinápticos resultantes do treinamento que resultou do número de ciclos utilizados anterior a este ponto;
2. O treinamento com grande número de ciclos, com precisões variáveis cada vez menores, e verificação de cada resultado. A partir de certo nível de exigência, pode ocorrer perda de capacidade de generalização, pois o excesso de treinamento está reproduzindo particularidades específicas dos dados de treinamento, revelando-se assim, o limite procurado. A rede que foi treinada logo abaixo deste limite é a adotada.

Para estes métodos, portanto utiliza-se apenas duas séries de dados, uma de treinamento (com maior proporção dos dados) e outra de verificação. A vantagem no que diz respeito ao aproveitamento dos dados é compensada, no entanto, pelo maior tempo consumido com os procedimentos de treinamento, o que torna-se mais significativo quando diversas arquiteturas de modelos devem ser experimentadas, além de diversas alternativas de conjuntos de variáveis de entrada.

3.4.9. Análise de sensibilidade

Nos modelos baseados em RNAs, o excesso de variáveis de entrada muitas vezes pode reduzir a eficiência da simulação, uma vez que os pesos internos do modelo são influenciados por todas as entradas, prejudicando o treinamento. Neste caso, os efeitos, sistematizados por Bowden et al. (2005), são: o aprendizado é dificultado, com o aumento da complexidade; o aumento de mínimos locais na superfície de convergência provoca convergência insuficiente e perda de precisão; a interpretação correta de modelos complexos com resultados semelhantes, em relação à de modelos mais simples, é mais difícil; a utilização de entradas irrelevantes podem prejudicar os resultados, pois fazem com que o modelo utilize recursos importantes para representar porções insignificantes do espaço de soluções, sendo requerida maior quantidade de dados e maior esforço de treinamento para compensar este efeito.

O método da análise preliminar das autocorrelações e intercorrelações (Salas et al., 1980) entre as variáveis explicativas e explicada é o mais popular, apresentando, porém, a desvantagem de não apontar as possíveis relações não lineares entre as entradas e saídas, resultando na omissão de entradas que seriam importantes.

Além disso, segundo Oliveira et al. (2011), pode ainda ocorrer que uma variável explicativa tenha seus efeitos potencializados pela presença de outra, que pode ou não ter sido classificada como importante para o processo, individualmente.

O método de, simplesmente, experimentar todas as combinações possíveis, pode ser inviável, mesmo para pequeno número de variáveis explicativas, pois todas as combinações devem ser treinadas e testadas com dados diferentes dos do treinamento, e os resultados devem ser examinados, podendo o método tornar-se ainda mais complexo à medida que seja verificada a ocorrência de superajustamento. No caso de modelos de séries temporais, o problema é agravado pela necessidade de pesquisa também das defasagens temporais.

A experimentação sistemática, passo a passo, pelo procedimento progressivo (inclusão, uma a uma, de novas variáveis) ou pelo regressivo (exclusão, uma a uma, das variáveis explicativas), esbarra na dificuldade adicional, além do custo representado pelo tempo investido, de que os dois procedimentos nem sempre conduzem à mesma conclusão (Olden e Jackson, 2002), pois os resultados são afetados pela ordem das inclusões ou exclusões.

Os métodos mais utilizados entre os que extraem informações de redes já ajustadas são, segundo Bowden et al. (2005), os chamados métodos de análise de sensibilidade, os quais são baseados em interferências sobre cada uma das variáveis de entrada e na verificação de seu efeito sobre as variáveis de saída.

O termo análise de sensibilidade das variáveis de entrada refere-se, realmente, à influência que estas variáveis têm sobre as saídas do modelo, ou seja, à sensibilidade do modelo a modificações induzidas sobre cada variável de entrada. A hipótese básica é de que variáveis cujas modificações influenciam mais as saídas são as mais importantes para estas.

Os métodos que pressupõe interferência nas variáveis pela substituição destas por um valor constante, ou por valores constantes em seu domínio, com análise sucessiva (Lek et. al., 1996), não são eficientes para casos em que as entradas são, em sua maioria, zero, como é o caso das precipitações.

Existem dois métodos conhecidos para a análise de sensibilidade das variáveis de entrada a perturbações impostas sobre estas, segundo estas perturbações sejam constantes (Maier e Dandy, 1997) ou aleatórias (Scardi e Harding, 1999), sendo este chamado de método das perturbações, por Gewrey et al. (2003). No primeiro método, pode-se optar por analisar o efeito de perturbações de diferentes magnitudes (Olden et al., 2004). No segundo, os resultados são também aleatórios, e as conclusões dependem da aplicação de muitas simulações e da análise da distribuição das respostas.

O método utilizado por Maier e Dandy (1997) revelou-se simples e eficiente para a verificação da influência de diferentes defasagens temporais em séries de entrada dos modelos de redes neurais. Um índice, chamado índice de sensibilidade (“sensitivity”) S, é calculado pela equação 6:

$$S(i) = \frac{\% \text{ das modificações provocadas sobre as saídas}}{\% \text{ das modificações induzidas sobre as entradas}(i)} \times 100 \quad (6)$$

Os passos para a aplicação deste índice são:

Aplicação do modelo a um conjunto de séries de dados reais, composto de n variáveis de entrada e da variável de saída:

T_c = modelo (variáveis de entrada com dados originais (= $P(i, i=1:n)$);

Para cada variável explicativa i, faz:

A variável i de entrada tem seus valores modificados, sendo estas modificações correspondentes a um incremento de 5% sobre seus valores originais:

$P_m(i) = P(i)$ modificada pela adição de 5%;

O modelo é aplicado, com a variável i de entrada modificada:

T_m = modelo (variáveis de entrada com dados originais para as demais variáveis, e modificados para a variável $i = P(1), \dots, P_m(i), \dots, P(n)$);

A proporção da alteração induzida nas saídas e o índice de sensibilidade são calculados:

$Prop(i) = \text{Soma}((T_m - T_c)/T_c) * 100$; $S(i) = 5\% / Prop(i)$;

Até a última variável explicativa n

A razão para o uso das proporções (prop (i)) é que as magnitudes de cada variável de entrada podem ser muito diferentes, afetando os resultados.

3.4.10. Previsão de vazão com RNAs

Estudos similares ao apresentado aqui, na aplicação de RNAs para a previsão de vazão, foram elaborados anteriormente por diversos autores, dentre os quais:

Sousa e Sousa (2010) utilizaram um modelo de redes neurais de múltiplas camadas para a previsão de vazão mensal na bacia do rio Piancó, no semiárido paraibano. A rede neural que apresentou o melhor desempenho estatístico foi a que possuía 15 neurônios na camada intermediária e resultou em um coeficiente de NS 0,77.

Para o reservatório de Furnas, em Minas Gerais, Bravo et al. (2008a), utilizaram as redes neurais no desenvolvimento de previsões de curto prazo para prever as vazões afluentes ao reservatório, onde o modelo utilizado produziu um desempenho melhor que os até então utilizados no sistema operacional, e com o uso da previsão de chuva, a qual revelou-se uma variável explicativa importante para o modelo de previsão de curto prazo nesse local.

Nessa mesma linha, na bacia do rio Iguaçu, em uma região que possui diversas hidrelétricas, as redes neurais foram utilizadas na previsão de vazão utilizando dados diários de vazão e precipitação, obtidos a partir de postos de controle, e de precipitação obtida através de previsão. Apesar dos postos de controle possuírem séries de dados extensas, o período foi limitado a 6 anos em função da disponibilidade de dados de chuva obtidos através da previsão de precipitação. Foram utilizados diferentes tipos de modelos de RNA de múltiplas camadas, sendo o modelo com o algoritmo retropropagativo o que apresentou melhores resultados (Figueiredo et al., 2007).

Gomes et al. (2010), utilizaram uma rede neural de múltiplas camadas, treinada com algoritmo retropropagativo, para a previsão de vazão de curto prazo, na bacia do rio São Francisco, apresentando resultados satisfatórios. Foi observado que a adição de vazões de dias anteriores reduziu o desempenho do modelo.

Batista (2009) utilizou modelos distintos para previsão de vazão no Rio Grande, em Minas Gerais, com o modelo de RNAs apresentando valores de previsão mais precisos que os obtidos pelos outros modelos. Foram encontrados erros quadráticos

médios variando entre 779,59 e 968,86. O autor considera as RNAs uma ferramenta importante na previsão de vazões naturais, tendo em conta os bons resultados.

Cruz et al. (2010) também utilizou modelos distintos para a previsão de vazão. Neste caso foram utilizados o modelo DPFT (diferenças primeiras da função de transferência) e um modelo simples de redes neurais artificiais. Para o modelo DPFT, foi utilizado uma amostra de observações de eventos chuva-vazão e um algoritmo iterativo para a identificação simultânea do hidrograma unitário (função de transferência) médio da bacia e de uma série de precipitações efetivas associadas a cada evento. O outro modelo é uma rede neural com uma camada interna, treinada com o algoritmo retropropagativo. Esses modelos foram aplicados em duas bacias no estado de Minas Gerais, a bacia do Rio das Velhas e a bacia do Rio Abaeté. Foram elaboradas diferentes alternativas para cada um dos modelos conforme algumas de suas características eram modificadas. O modelo DPFT apresentou um desempenho ligeiramente superior ao das RNAs, entretanto, uma menor regularidade nos resultados. Para o modelo de RNAs foram encontrados coeficientes NS variando de 0,14 à 0,80 para a bacia do rio das Velhas e de 0,23 à 0,78 para a bacia do rio Abaeté.

Para o sistema hidrológico Chute-du-Diable, com 9700 km², no norte de Quebec (Canadá), Coulibaly et al. (2000) utilizaram diferentes modelos de previsão de vazão, com as RNAs apresentando coeficientes NS entre 0,92 e 0,99 para a previsão de um dia a frente. Já Kumar et al. (2005) utilizaram RNAs na previsão de vazão na bacia do rio Malaprabha (India), com 515,29 km², encontrando coeficientes NS variando entre 0,80 e 0,94. Em ambos os casos as RNAs foram treinadas com o algoritmo retropropagativo.

Paz et al. (2002) utilizaram o modelo de RNAs e o método de diferenças (modelo Prev) para a previsão de vazão em tempo real. O estudo foi realizado na bacia hidrográfica do Rio Doce (MG) e do Rio Uruguai (RS). A RNA proposta foi de múltiplas camadas com o treinamento com o algoritmo retropropagativo. O modelo Prev, desenvolvido no IPH/UFRGS, é um modelo empírico e determinístico que realiza previsão de níveis ou vazões em tempo real, com base na propagação do escoamento, utilizando uma equação linear das diferenças sucessivas das variáveis envolvidas. As RNAs apresentaram um desempenho melhor que o outro modelo, com coeficientes NS variando entre 0,82 e 0,95 para a bacia do Rio Doce e entre 0,88 e 0,98 para a bacia do Rio Uruguai. A utilização de vazões antecedentes não produziu uma melhora na previsão com RNAs. As duas metodologias apresentaram desempenhos semelhantes, limitados pelas informações disponíveis.

Kerh e Lee (2006) utilizaram um modelo de RNAs de múltiplas camadas com o algoritmo retropropagativo para prever vazões no exutório de uma bacia sem informações (Lilin Bridge (3.257 km²)), no sul de Taiwan, a partir de informações de bacias de montante. As informações utilizadas foram os dados de vazões de três controles de montantes (Shinfa Bridge (1.373 km²), Sanlin Bridge (802 km²) e Santimen (642 km²)) e das características fisiográficas das três sub-bacias que elas formam. Além das vazões no tempo atual (dia t), foram inseridas vazões com componentes antecedentes (dias t-1, t-2 e t-3). Foram feitos vários modelos, onde houve uma variação em algumas entradas (neste caso, as características fisiográficas), e com coeficientes NS acima de 0,90 para todos os modelos.

Já Turan e Yurdusev (2009) utilizaram diferentes modelos, entre eles uma rede neural com algoritmo retropropagativo, para prever vazões no exutório da bacia Soyhières (924 km²), na Suíça, a partir de dados de vazões de três controles de montante (Moutier (183 km²), Delémont (241 km²) e Vicques (72 km²)). Para as RNAs foram elaborados 7 modelos, onde houve uma variação nos postos utilizados para cada um deles. Os resultados mostraram que quanto maior o controle de montante melhores são os resultados para as alternativas com apenas um controle de montante. Também foi possível observar que a utilização de mais de um controle produziu melhores resultados que aqueles com controles individuais, com o melhor resultados sendo encontrado na alternativa que contemplava os três postos, com coeficiente NS de 0,99.

4. MATERIAIS E MÉTODOS

4.1. Área de Estudo

A pesquisa foi aplicada em 6 bacias hidrográficas, todas embutidas, sendo a maior delas a bacia da Ponte Mística, que está localizada no noroeste do estado do Rio Grande do Sul, entre as coordenadas 27°58' e 29°04' de latitude Sul e 53°12' e 54°48' de longitude Oeste, com o exutório localizado no posto fluviométrico da Ponte Mística no município de São Luiz Gonzaga, com uma área de drenagem 9450 Km². As demais bacias são Santo Ângelo (5440 Km²), Colônia Mousquer (2160 Km²), Passo do Faxinal (1940 Km²), Ponte Nova do Potiribu (609 Km²) e Turcato (19,5 Km²), como apresentado nas Figuras 4.1 e 4.2.

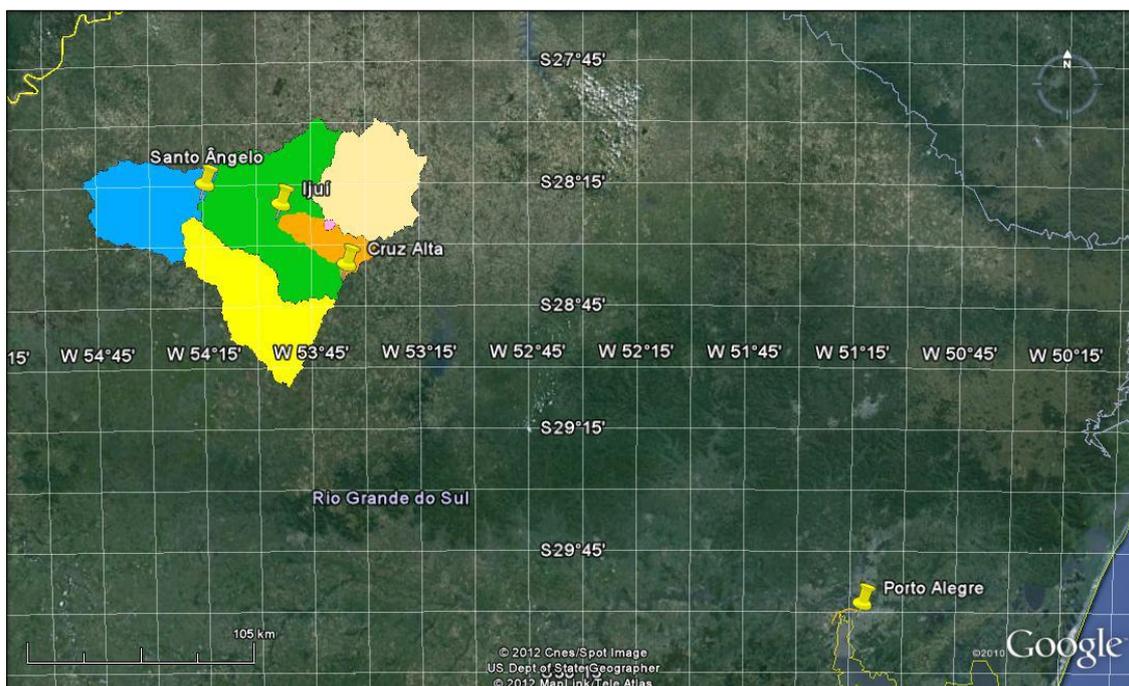


Figura 4.1. Localização da bacia no Estado do RS (Adaptado: Google Earth).

Essa bacia foi escolhida pelo fato de ser monitorada há mais de duas décadas por diversos projetos ligados ao IPH, como os projetos MATASUL, CLIMASUL e INTEGRA, e onde já foram realizados uma grande quantidade de estudos, gerando várias publicações. Por ser monitorada há muito tempo esse local possui uma série de

dados para a aplicação das metodologias utilizadas nesse estudo (Castro et al., 2000; Castro et al., 2010).

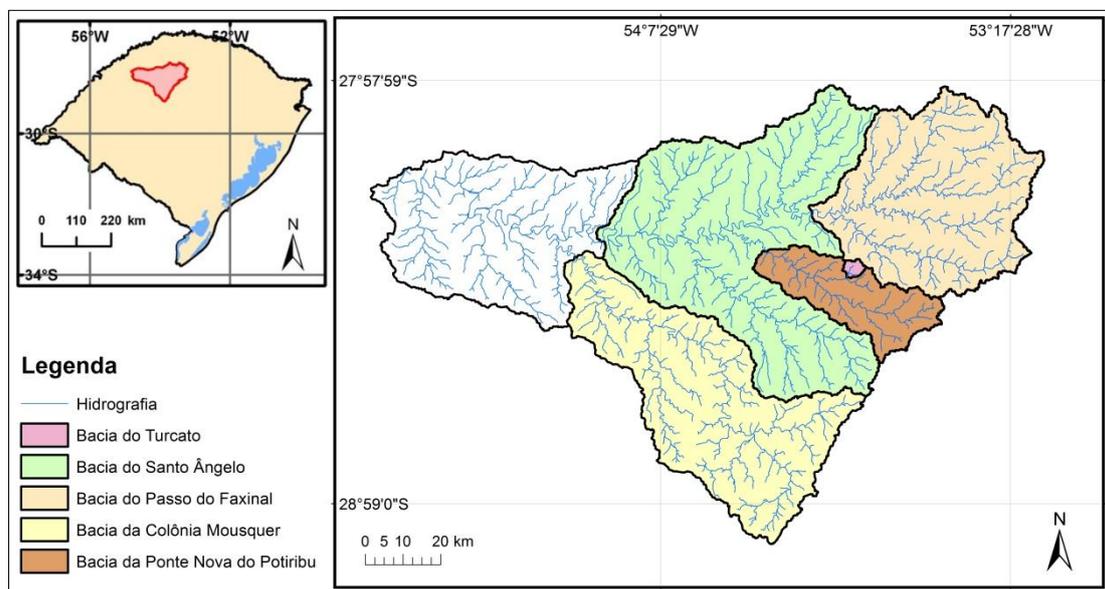


Figura 4.2. Bacia de Ponte Mística e as sub-bacias embutidas (Adaptado: Oliveira et al. 2011).

A bacia do rio Ijuí abrange total ou parcialmente 38 municípios do Rio Grande do Sul, com uma população urbana de 261.828 pessoas e rural de 79.740 pessoas. Seus principais rios formadores são o Ijuzinho, Conceição, Potiribu, Caxambu, Faxinal, Fiúza e Palmeira (SEMA-RS, 2008).

A bacia do rio Ijuí está localizada numa posição central do derrame basáltico sul-americano, sobre o planalto médio gaúcho com altitudes entre 420 e 700 m (Silva Júnior et al., 2003). Seu relevo é composto de coxilhas com declividades variando entre 3 e 15%. Esse planalto está situado sobre rocha basáltica, formada pela acumulação de sucessivas camadas vulcânicas datadas de 120 milhões de anos. Entre essas camadas, foram sendo depositadas camadas de arenito Botucatu que variam de alguns metros de profundidade até uma centena de metros (Silva, 2011).

Sobre esse planalto, segundo Viero (2004), os solos são muito úmidos, devido principalmente ao regime abundante de precipitação e por possuir solos bem desenvolvidos e profundos, podendo atingir até mais de 15m de profundidade. A maioria do solo da região é classificada como latossolos vermelho distroférico típico textura muito argilosa A moderado epieutrófico (LVdf). Apesar de ser um solo argiloso,

ele apresenta uma forte drenagem devido aos microagregados formados em todo o perfil resultando em uma importante macro-porosidade.

Segundo o IBGE (1986), as formações vegetais características da região são: região de savana e a região de floresta estacional decidual. A savana é caracterizada por vegetação gramíneo lenhosa, como hemicriptófitas, geófitas e caméfitas. Já a região de floresta estacional decidual é representada por dois estratos arbóreos diferentes: um emergente, aberto e decíduo, com altura variando entre 25 e 30 m, e outro, dominado e contínuo, com altura até 20 m.

As principais atividades econômicas dessa bacia estão ligadas ao setor primário da economia com o plantio principalmente de soja e milho no verão, trigo e aveia no inverno. Alguns municípios dessa região possuem também setores secundários e terciários mais desenvolvidos, destacando-se Ijuí, Santo Ângelo e Cruz Alta (Fepam, 2012). Essa bacia possui também potencialidade de geração de energia hidrelétrica, onde já existem algumas hidrelétricas instaladas, como as PCH gerenciadas pela Ceriluz, a usina das Andorinhas administrada pela Companhia Paulista de Força e Luz (CPFL), e a UHE São José da Ijuí energia S.A. (Ceriluz, 2012; Aneel, 2012).

O clima na bacia do rio Ijuí, segundo Nimer (1989), é classificado como mesotérmico brando superúmido sem seca (Cfa), pela classificação climática de Köppen, com temperatura média das máximas superior a 22 °C e a média das mínimas variando entre -3 e 18 °C e verão quente. A ocorrência desse clima deve-se às latitudes subtropicais da região, sujeitas constantemente à invasão de massas de ar frias de origem polar. Apresentam verões extremamente quentes e invernos bastante rigorosos com pelo menos um mês de temperaturas médias inferiores a 15 °C.

A região apresenta uma notável homogeneidade média na distribuição mensal de precipitação, devido, principalmente, ao regime de circulação atmosférica bastante regular ligado às passagens de frentes frias vindas do sul. Possui médias mensais de precipitação variando entre 105 e 170 mm, com um total médio anual de 1700 mm (Chevallier e Castro, 1991). O estado do Rio Grande do Sul sofre influência de dois fenômenos distintos, o El niño e La niña, que causam alterações na temperatura do oceano pacífico, causando profundos efeitos no clima, modificando o regime pluviométrico (Santos, 2008).

A figura 4.3 apresenta valores médios, mínimos e máximos, mensais de chuva (entre 1991 e 2010) do posto pluviométrico do INMET, de Cruz Alta, localizado no município de mesmo nome. Apesar de possuir dados pontuais, por este posto se situar

no interior da bacia, ele serve de exemplo para a caracterização do regime de chuvas da região.

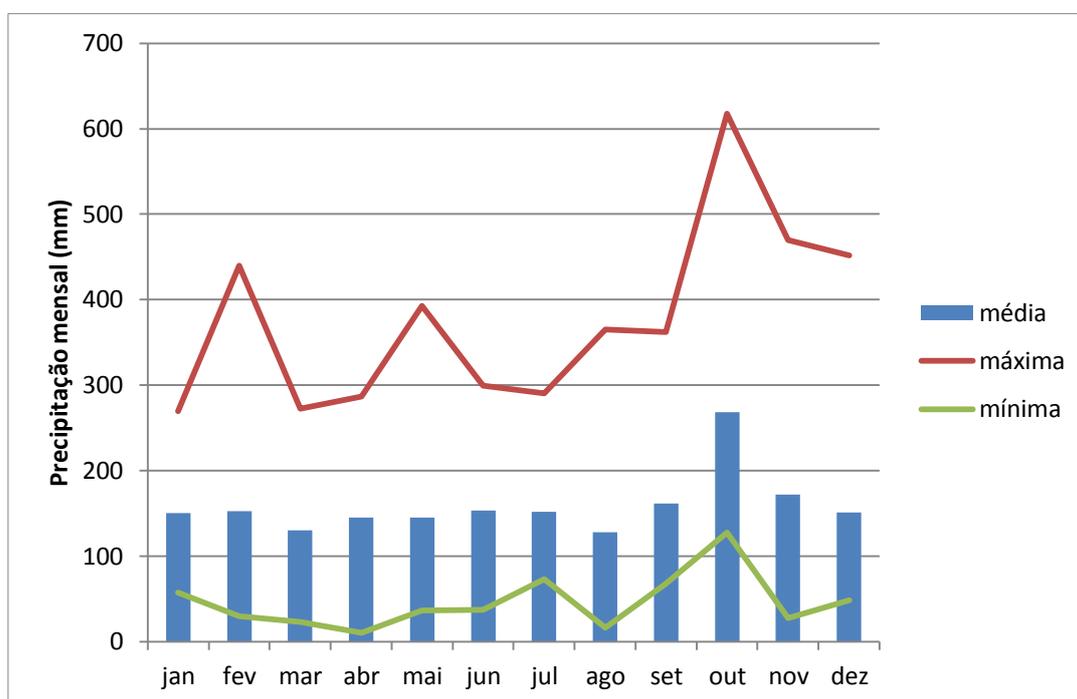


Figura 4.3. Valores médios, mínimos e máximos, mensais de chuva (entre 1991 e 2010) do posto pluviométrico de Cruz Alta.

É possível observar que as médias mensais de precipitação variam entre 128 mm e 254 mm, apresentando um regime regular de chuva o ano todo. Apesar desta homogeneidade média mensal, as precipitações mínimas podem ser muito pequenas como nos meses de abril de 2009 (10 mm) e agosto de 2003 (16 mm), e muito grandes como no mês de outubro de 1997 (617 mm), devido ao fenômeno El Niño. Isto mostra que mesmo as médias mensais sendo muito homogêneas de um ano para o outro podem ocorrer grandes variações.

4.2. Dados Pluviométricos

Os dados pluviométricos utilizados neste estudo foram extraídos de Silva (2011). O autor utilizou o método do vizinho natural como interpolador para gerar grades de precipitações com quais foi feito o cálculo das precipitações médias para a bacia da Ponte Mística a partir de dados de 65 postos pluviométricos e pluviográficos localizados

na região no período de 22/08/1989 a 31/12/2010. Os dados observados na bacia foram obtidos por aparelhos pertencentes à ANA (Agência Nacional de Águas) e por pluviômetros e pluviógrafos do projeto de monitoramento da bacia do Potiribu (Castro et al., 2010). Nos pluviômetros pertencentes ao projeto, as leituras foram feitas diariamente às 8 hs da manhã, e esses valores corresponderam à precipitação acumulada nas 24 hs anteriores a esse horário (Silva, 2011).

Foram utilizados 44 postos de precipitação da ANA para a criação da série histórica interpolada, que podem ser acessados através do site da Hidroweb e são apresentados na Tabela 4.1. A Figura 4.4 apresenta a disposição dos postos na bacia em estudo.

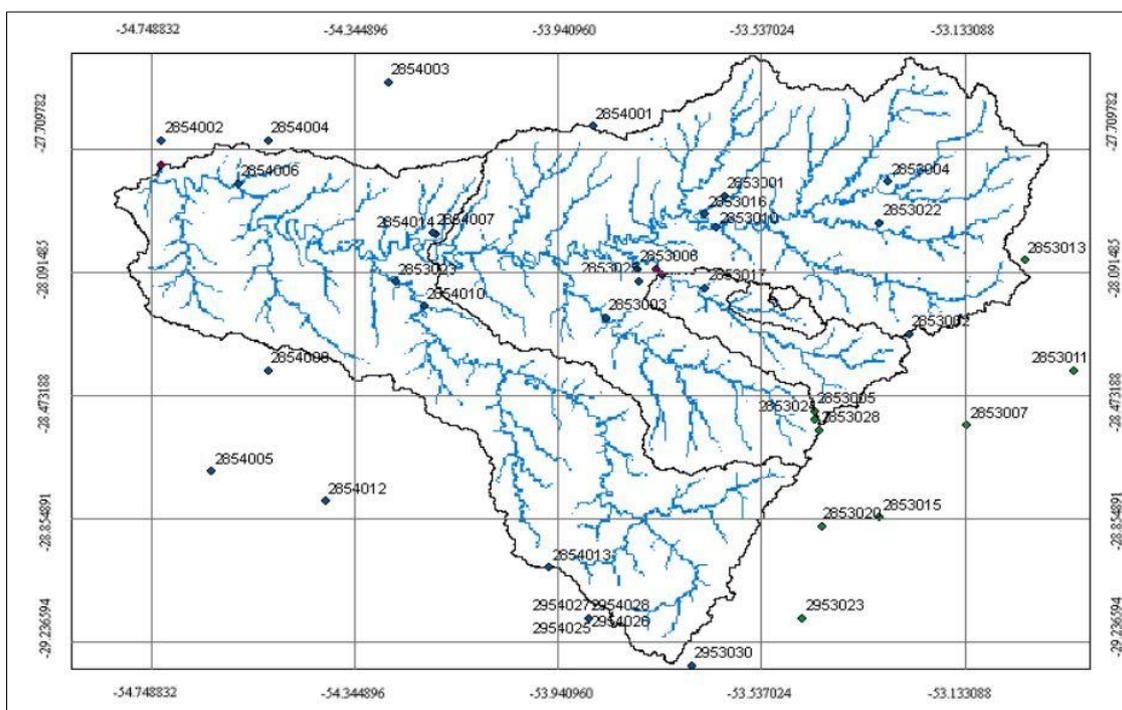


Figura 4.4. Postos de chuva da ANA (Adaptado: Silva, 2011).

Tabela 4.1. Postos de chuva da ANA.

Código	Nome	Longitude-Oeste	Latitude-Sul
02753005	Palmeira as Missões 83880	53°26'00''	27°53'00''
02754010	Esquina Araújo	54°06'59''	27°58'05''
02853002	Belisário	53°27'00''	28°29'00''
02853003	Conceição	53°58'15''	28°27'18''
02853005	Cruz Alta 83912	53°36'42''	28°37'28''

02755001	Porto Lucena	55°01'21''	27°51'16''
02853006	Ijuí	53°55'00''	28°22'00''
02853010	Passo Faxinal	53°46'48''	28°17'21''
02853011	Ponte Santo Antônio	53°10'00''	28°33'00''
02853012	Saldanha Marinho	53°05'00''	28°23'00''
02853013	Santa Barbara do Sul	53°15'00''	28°21'00''
02853015	Três Capões	53°30'00''	28°49'00''
02853022	Panambi Pindorama 83910	53°30'00''	28°17'00''
02853023	Condor	54°19'55''	28°23'21''
02853026	Chapada	53°03'58''	28°03'31''
02853027	Ibiruba 83932	53°07'00''	28°37'00''
02853028	Anderson Clayton	53°36'17''	28°39'31''
02854001	Boa Vista	53°59'33''	28°06'25''
02854002	Cerro Largo	54°44'00''	28°08'00''
02854003	Girua	54°20'37''	28°01'35''
02854005	Passo Major Zeferino	54°38'52''	28°44'01''
02854006	Passo Viola	54°36'08''	28°12'38''
02854007	Santa Angelo 83909	54°16'00''	28°18'00''
02854011	São Luiz Gonzaga 83907	54°58'00''	28°24'00''
02854012	Coimbra	54°27'07''	28°47'16''
02854013	São Bernardo	54°04'04''	28°54'30''
02854014	Santo Angelo-Ipagro	54°15'45''	28°18'13''
02855002	Passo do Sarmiento	55°19'11''	28°12'43''
02855001	Garruchos	55°38'13''	28°11'16''
02855005	Faz. Santa Cecília do Butuí	55°40'27''	28°59'23''
02855007	Santo Antônio das Missões	55°13'51''	28°29'33''
02953017	Santa Maria	53°43'12''	29°43'27''
02953030	Tupancireta	53°49'09''	29°05'08''
02954004	Ernesto Alves	54°44'08''	29°21'58''
02954005	Furnas do Segredo	54°30'07''	29°21'32''
02954007	Jaguari	54°41'02''	29°29'25''
02954019	Quevedos	54°41'00''	29°21'05''
02954020	Santiago	54°51'21''	29°11'12''
02954030	Florida	54°35'54''	29°15'06''
02954031	Esquina Lima (S. Barbara)	54°30'34''	29°44'00''

02955002	Cachoeira Santa Cecília	55°28'31''	29°11'46''
02955006	Ponte do Miracatu	55°17'28''	29°27'33''
02955007	Unistalda	55°09'04''	29°25'01''
02955008	Manoel Viana	55°29'09''	29°35'38''

Os pluviômetros e pluviógrafos do projeto do IPH na bacia do Potiribu foram instalados em novembro de 1989, de maneira a cobrir a região da bacia do Taboão e as sub-bacias embutidas do Turcato (19,5 Km²) e Donato (1,1 Km²) (Castro et. al. 2000). Inicialmente os aparelhos eram mecânicos, com os registros feitos em papel e, em 1999, foram substituídos por aparelhos eletrônicos com registros em “loggers”. A Tabela 4.2 apresenta a localização dos pluviômetros e pluviógrafos, bem como seus nomes. A Figura 4.5 mostra a distribuição dos equipamentos na bacia. São 21 equipamentos que fornecem séries históricas de 22/08/1989 à 31/12/2010, com falhas em alguns períodos.

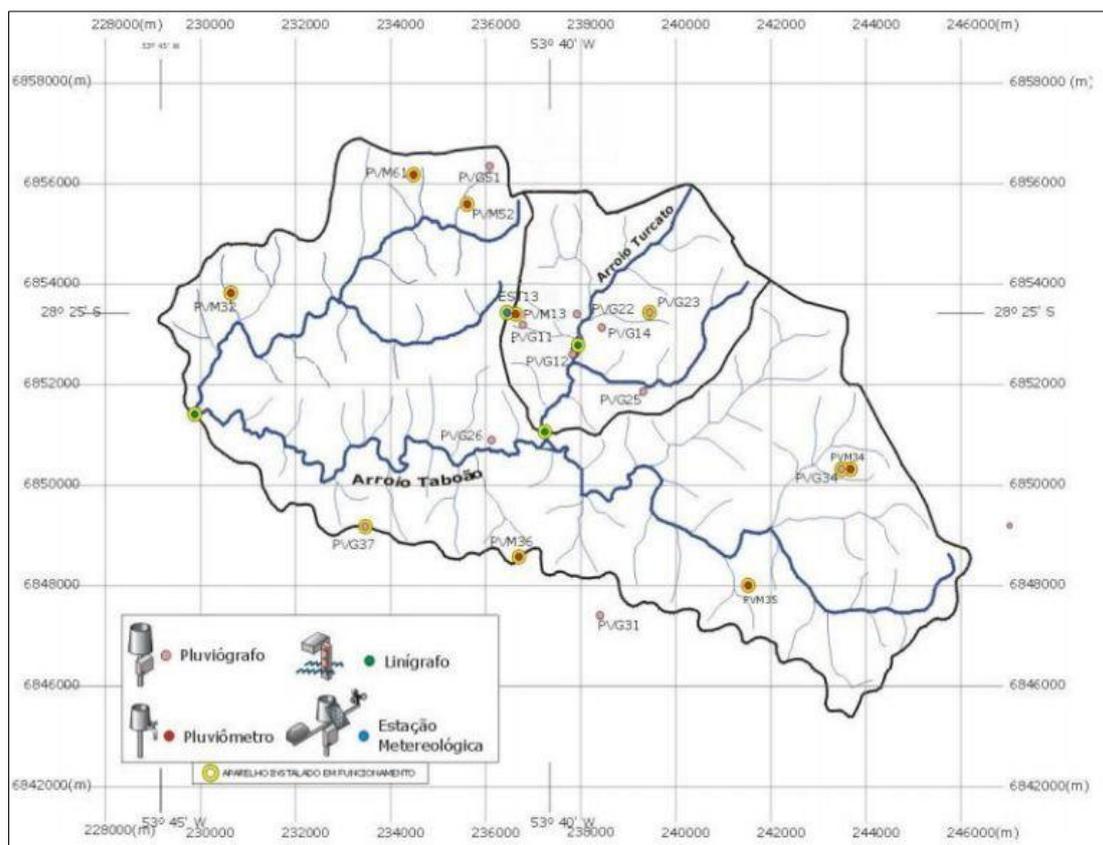


Figura 4.5. Distribuição dos postos de precipitação na bacia do Potiribu (Fonte: Silva, 2011).

Tabela 4.2. Postos de chuva do projeto da bacia do Potiribu.

Código	Nome	Longitude-Oeste	Latitude-Sul
PM 13	Alto Donato	53°41'14''	28°25'06''
PM 21	Pejuçara Norte	53°38'57''	28°24'11''
PM 24	Turcato Central	53°40'17''	28°24'55''
PM 32	Tincão do Jesus	53°44'34''	28°24'52''
PM 34	Alto Taboão	53°36'12''	28°27'21''
PM 35	Velha Estrada Cruz Alta	53°27'10''	28°26'53''
PM 36	Granja das Castanheiras	53°38'19''	28°27'46''
PM 52	Baixa Divisa	53°38'19''	28°27'49''
PM 61	Santa Lúcia	53°41'55''	28°24'08''
PM 62	Granja Santa Catarina	53°42'35''	28°23'39''
PVG 11	Donato Cental	53°37'13''	28°26'55''
PVG 12	Baixo Donato	53°43'37''	28°25'04''
PVG 14	Baixo Donato	53°41'13''	28°25'15''
PVG 22	Alto Turcato	53°40'35''	28°25'35''
PVG 23	Pejuçara Cidade	53°40'12''	28°25'18''
PVG 25	Pejuçara Leste	53°40'31''	28°25'09''
PVG 26	Baixo Turcato	53°39'53''	28°24'02''
EST 12	Estação Meteorológica	53°39'14''	28°25'05''
PVG 51	Euzébio	53°39'41''	28°26'00''
PVG 37	Foz Taboão Castanheira	53°41'39''	28°26'00''
PVG 31	Fazenda três irmãos	53°41'10''	28°24'50''

Para este estudo foram utilizados dados pluviométricos de 22/08/1989 à 01/06/1994 (1.743 dias).

As figuras de 4.6 a 4.11 apresentam as comparações das precipitações mensais, obtidas através dos dados de precipitação diária de Silva (2011) para a bacia de Ponte Mística, para cada ano que compreende este estudo (entre 1989 e 1994), com as precipitações médias mensais (entre 1991 e 2010) da série histórica do posto do INMET de Cruz Alta, de forma a caracterizar o regime pluviométrico da região no período de estudo. O posto pluviométrico de Cruz Alta foi um dos postos utilizados na criação da série de precipitação utilizada neste estudo.

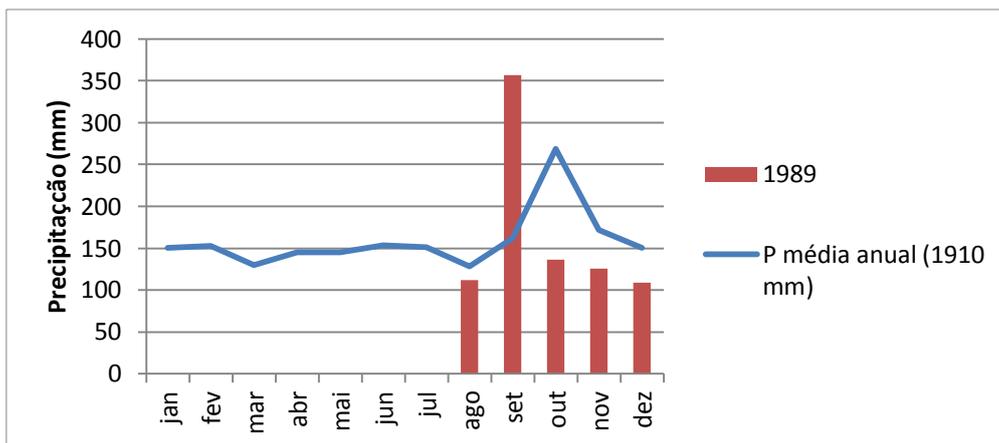


Figura 4.6. Comparação da precipitação média mensal de Ponte Mística no ano 1989 com a da série histórica de Cruz Alta (entre 1991 e 2010).

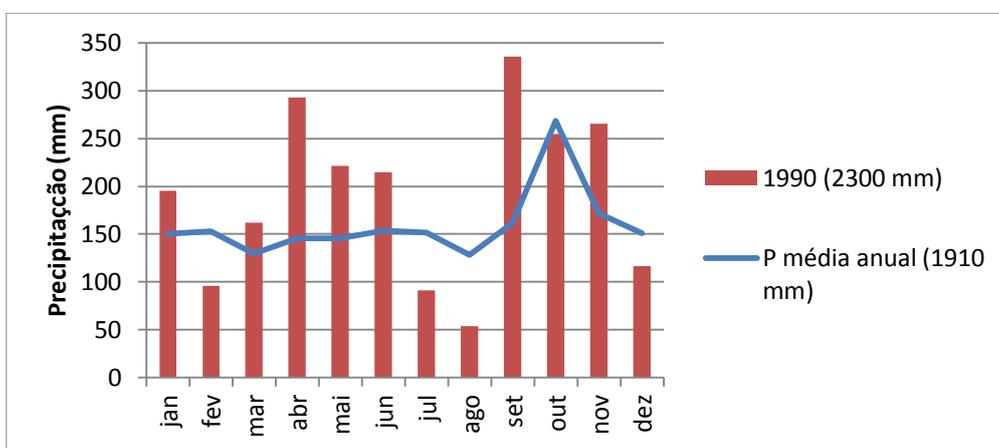


Figura 4.7. Comparação da precipitação média mensal de Ponte Mística no ano 1990 com a da série histórica de Cruz Alta (entre 1991 e 2010).

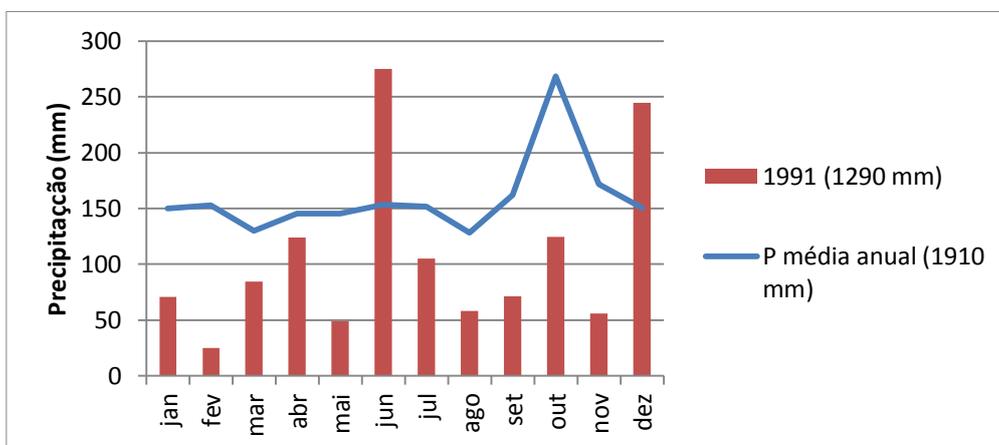


Figura 4.8. Comparação da precipitação média mensal de Ponte Mística no ano 1991 com a da série histórica de Cruz Alta (entre 1991 e 2010).

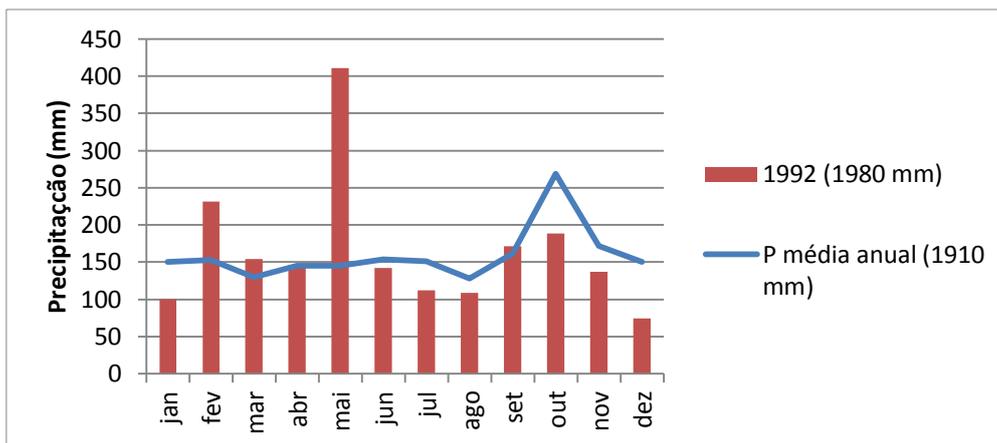


Figura 4.9. Comparação da precipitação média mensal de Ponte Mística no ano 1992 com a da série histórica de Cruz Alta (entre 1991 e 2010).

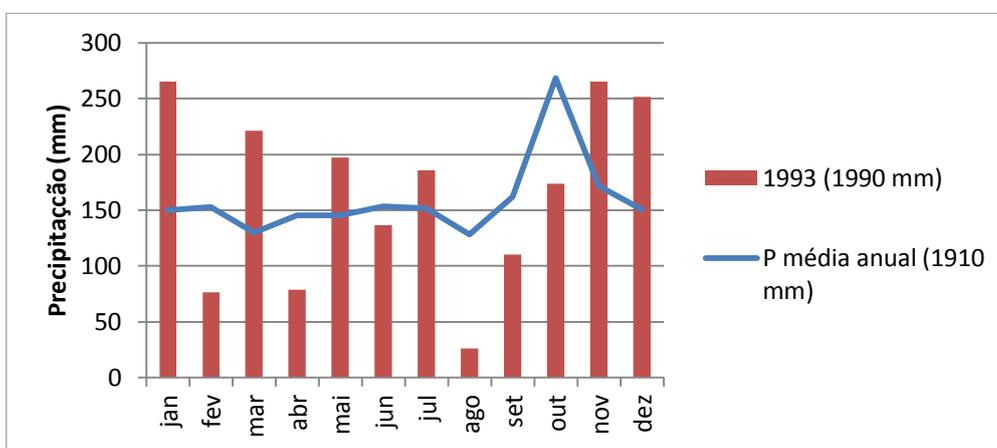


Figura 4.10. Comparação da precipitação média mensal de Ponte Mística no ano 1993 com a da série histórica de Cruz Alta (entre 1991 e 2010).

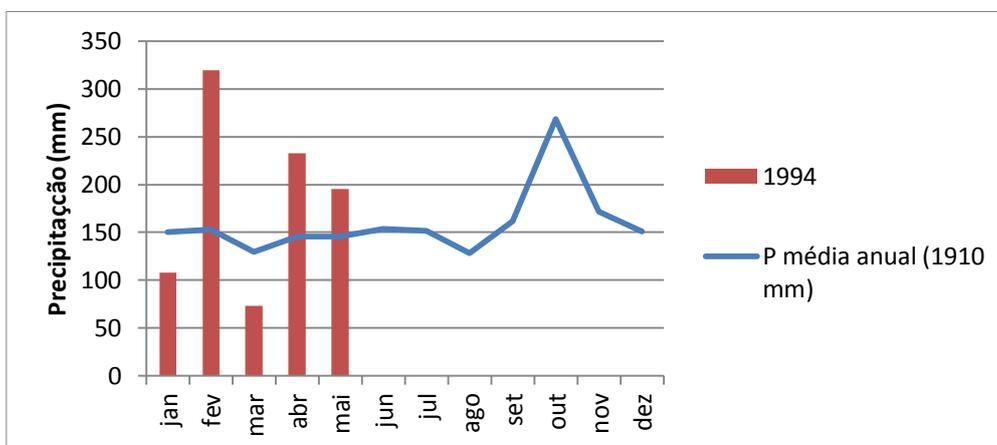


Figura 4.11. Comparação da precipitação média mensal de Ponte Mística no ano 1994 com a da série histórica de Cruz Alta (entre 1991 e 2010).

A comparação das precipitações mensais para cada ano que compreende este estudo (entre agosto de 1989 e maio de 1994), com as precipitações médias mensais (entre 1991 e 2010) da série histórica de Cruz Alta, apresentou algumas diferenças. Porém em ambas as séries, é possível observar um regime regular de chuvas, sem períodos de seca. Os anos de 1990, 1992 e 1993 foram os mais chuvosos, enquanto no ano 1991 a precipitação média anual ficou bem abaixo da média histórica registrada em Cruz Alta.

4.3. Dados Fluviométricos

O posto fluviométrico de Ponte Mística foi definido, neste estudo, como exutório da bacia do rio Ijuí e está localizado nas coordenadas Latitude 28°10'53'' e Longitude 54°44'18''. Da mesma forma, os postos de Santo Ângelo, Colônia Mousquer, Ponte Nova do Potiribu, Passo do Faxinal e Turcato são os exutórios das respectivas sub-bacias embutidas (Tabela 4.3). A Figura 4.12 apresenta a localização da cada posto na bacia em estudo.

Tabela 4.3. Postos Fluviométricos utilizados nesse estudo.

Código	Nome	Área (km ²)	Longitude-Oeste	Latitude-Sul
75320000	Ponte Mística	9450	54°44'18''	28°10'53''
75230000	Santo Ângelo	5440	54°16'06''	28°21'19''
75185000	Ponte Nova do Potiribu	609	53°52'32''	28°22'38''
75155000	Passo do Faxinal	1940	53°45'51''	28°17'13''
75295000	Colônia Mousquer	2160	54°19'51''	28°23'23''
-	Turcato	19,5	53°40'57''	28°27'42''

As séries históricas de vazão dos postos foram obtidas da página, na internet, da Hidroweb da ANA e de linígrafos monitorados desde 1989 (Castro et al., 2000). Os dados fornecidos pela ANA consistem em vazões médias diárias, resultantes das médias das vazões correspondentes aos dados de níveis coletados duas vezes ao dia, às 7 hs e às 17 hs. Já para o posto fluviométrico da bacia do rio Turcato, a menor delas, as vazões médias diárias foram obtidas a partir de dados discretizados em intervalos de 15 minutos, resultantes da aplicação da curva-chave aos níveis, com a leitura que corresponde a 1 dia iniciando-se às 9 hs do dia atual e tendo como tempo final as 8 hs

da manhã do dia seguinte. Também foram utilizadas vazões horárias para este posto, coincidentes com o mesmo intervalo temporal.

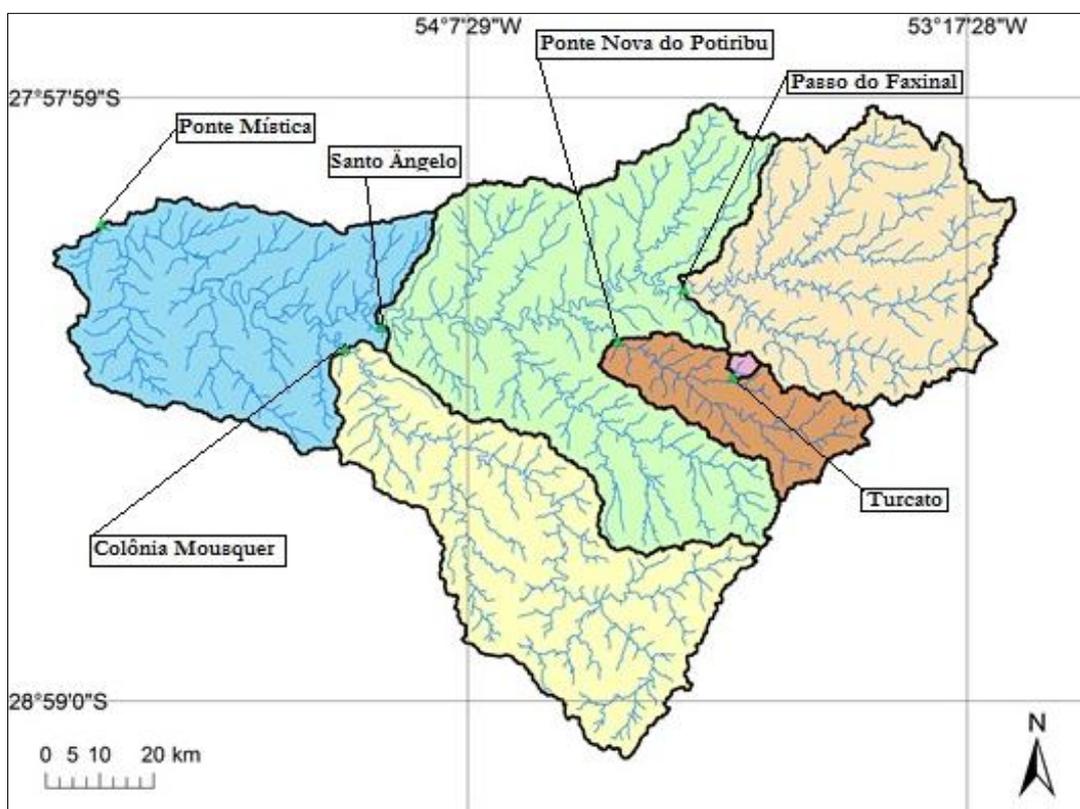


Figura 4.12. Disposição dos postos fluviométricos na bacia em estudo.

O local onde foram feitas as previsões (posto de Ponte Mística), assim como as demais bacias monitoradas pela ANA, possui dados de vazões médias diárias, onde a vazão média de um dia corresponde à média das vazões das 7 hs e 17 hs. As médias de vazões, obtidas desta forma, para um dia à frente (dia $t+1$), no exutório de Ponte Mística, foram os objetos das previsões. Como entradas nos modelos de previsão foram utilizados dados de precipitações diárias, acumuladas entre 9 hs (dia t) e 8 hs (dia $t+1$); vazões diárias dos postos da ANA (dia t); vazões diárias do posto do Turcato, onde as vazões de 1 dia são aquelas entre 9 hs (no dia t) e 8 hs (no dia $t+1$); e vazões horárias do posto do Turcato, entre 9 hs (no dia t) e 8 hs (no dia $t+1$). Portanto, o horizonte de informações (limite temporal para as entradas dos modelos) estende-se, para chuvas médias na bacia de Ponte Mística e para vazões do Turcato, até às 8 horas do próprio dia da previsão (dia $t+1$). Assim sendo, este horário corresponde, a cada dia, ao tempo atual, pois após começa o futuro, completamente desconhecido. A Figura 4.13 ilustra os limites temporais utilizados na previsão.

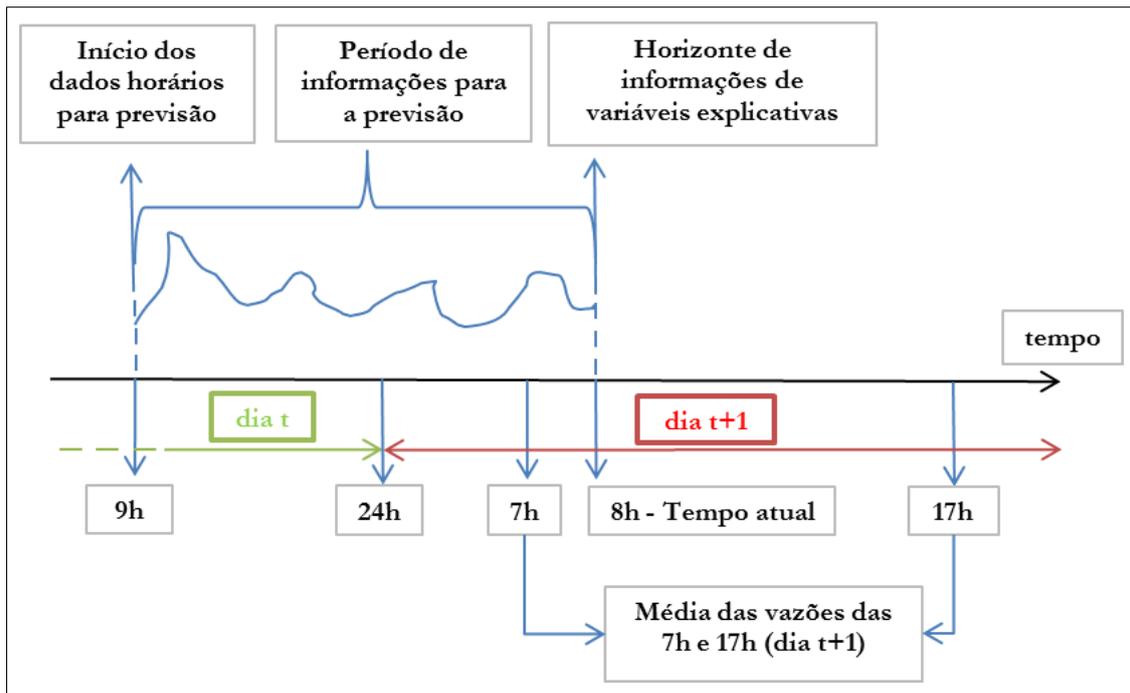


Figura 4.13. Limites temporais utilizados na previsão.

As séries históricas de vazão dos postos foram obtidas através da página da Hidroweb, da ANA, na internet, e de linígrafos monitorados pelo projeto do IPH na bacia do Potiribu e possuem uma longa série de dados, alguns com até mais de 50 anos. Porém, devido à metodologia utilizada neste estudo, será utilizado um período de abrangência de um pouco mais de 4 anos, de modo a coincidir com o período de dados de todos os postos fluviométricos, de 22/08/1989 à 01/06/1994. Além disso, no ano de 1994 ocorreu uma mudança na forma de uso do solo na bacia do Potiribu, passando do plantio convencional para o plantio direto. Portanto, no período de estudo, essa mudança não tinha acontecido.

As figuras de 4.14 a 4.19 apresentam as vazões médias mensais dos anos que compreendem este estudo (de 1989 a 1994), bem como as vazões máximas e mínimas para cada mês neste período.

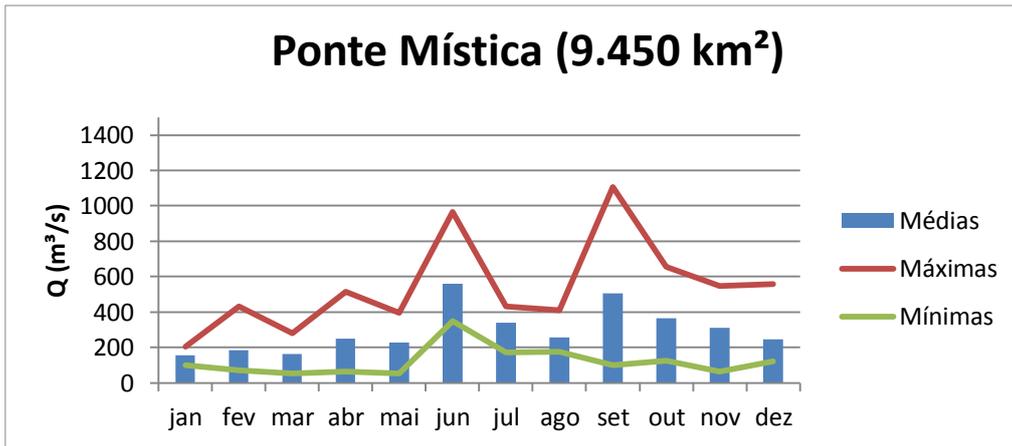


Figura 4.14. Vazões das médias dos meses na bacia da Ponte Mística (1989 a 1991).

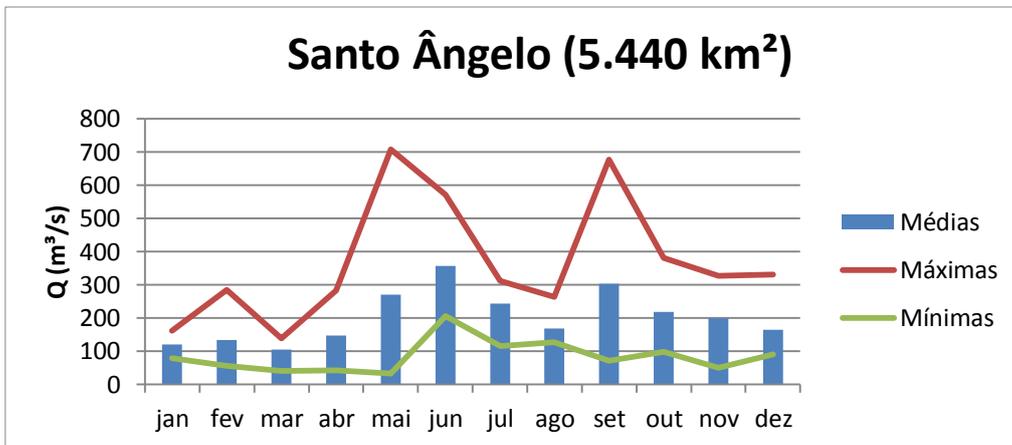


Figura 4.15. Vazões das médias dos meses na sub-bacia de Santo Ângelo (1989 a 1991).

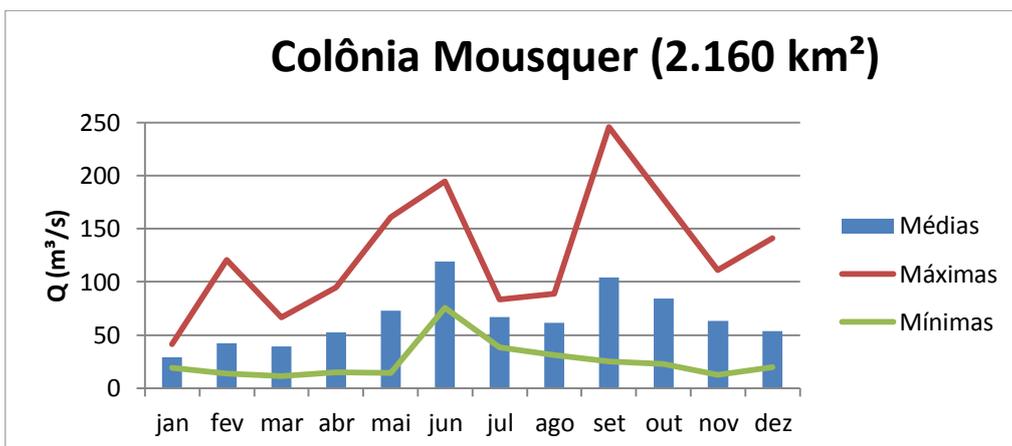


Figura 4.16. Vazões das médias dos meses na sub-bacia de Colônia Mousquer (1989 a 1991).

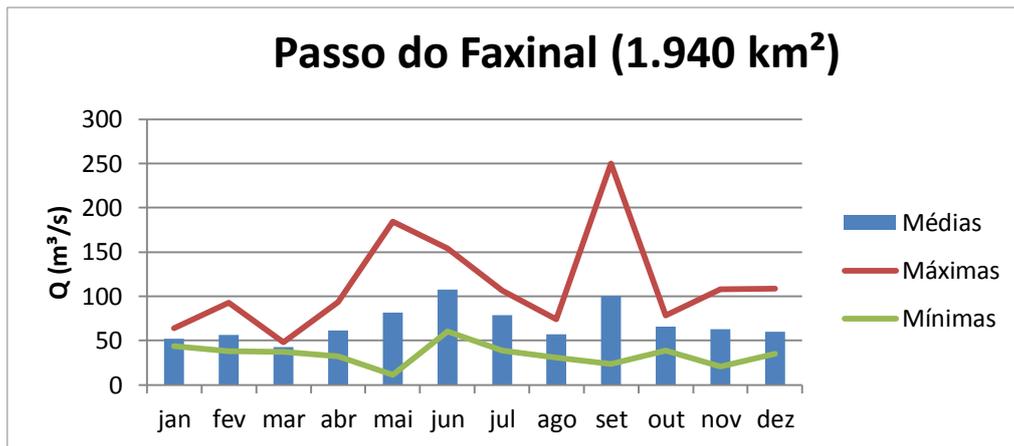


Figura 4.17. Vazões das médias dos meses na sub-bacia de Passo do Faxinal (1989 a 1991).

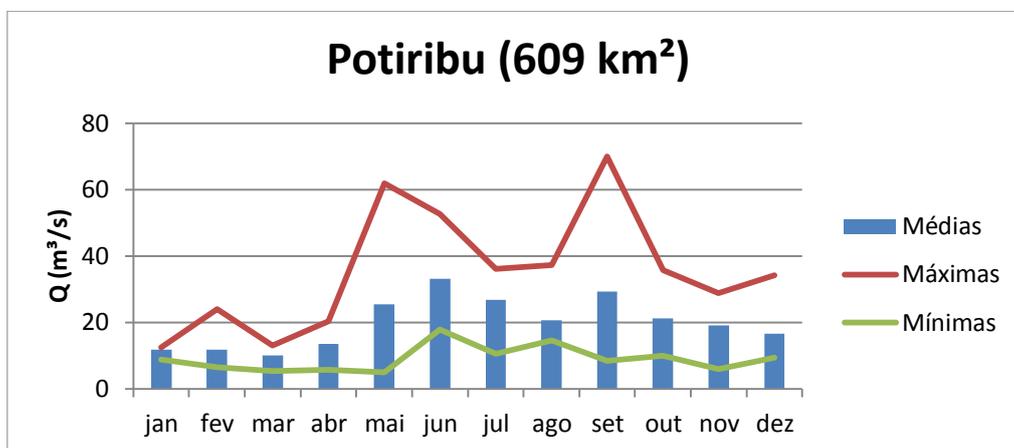


Figura 4.18. Vazões das médias dos meses na sub-bacia de Potiribu (1989 a 1991).

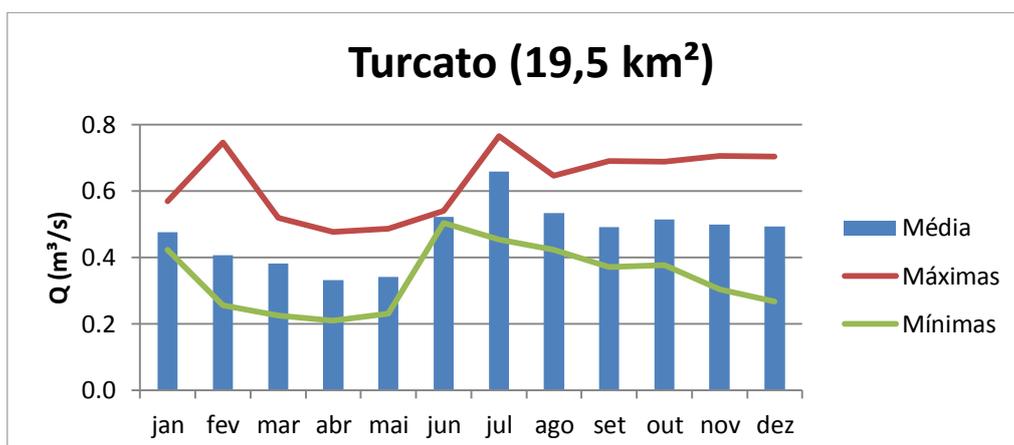


Figura 4.19. Vazões das médias dos meses na sub-bacia de Turcato (1989 a 1991).

As vazões médias mensais em Ponte Mística ficaram entre 155 m³/s (janeiro) e 559 m³/s (junho). É importante ressaltar que para todas as bacias estudadas existe um regime regular de vazões, com os rios possuindo vazões o ano inteiro (rios perenes) e com o período de menores vazões sendo de janeiro a março, que coincide com o verão no hemisfério sul. Mesmo nesses meses havendo uma chuva regular, o aumento da evapotranspiração causa uma redução nas vazões dos rios.

4.4. Métodos

Foram desenvolvidos modelos com nove alternativas de controle de montante, sendo seis delas com controles individuais, duas com controle simultâneo de dois postos e uma com dados horários da menor bacia, utilizando dados diários de precipitação (P) e vazão (Q) das sub-bacias embutidas para prever a vazão na Ponte Mística.

O tipo de redes neurais utilizado neste estudo foi a rede de múltiplas camadas com treinamento pelo algoritmo retropropagativo. Foi utilizada apenas uma camada interna na rede neural, composta por cinco neurônios. Este número de neurônios foi escolhido para atender à recomendação do teorema de Kolmogorov-Nielsen (Hecht-Nielsen, 1990) para o modelo mais simples (somente duas entradas – alternativa 1), porém mantendo o mesmo número de neurônios para todas as alternativas, e uma complexidade mínima para evitar o superajustamento. No quadro a seguir é apresentado um modelo genérico com as mesmas características dos modelos utilizados neste trabalho, elaborado no ambiente computacional MATLAB R2010a.

Primeiramente, é feita uma leitura dos dados e a aplicação dos recursos previstos, como a função de ativação do tipo sigmoidal unisig (equação 1) e sua derivada dunisig cuja forma modificada (equação 7), foi adotada como um recurso para evitar que resulte zero em pontos extremos, além das funções envolvidas no escalonamento (esclin e reclin). Foi feita a separação dos dados para as entradas e saídas, bem como a eliminação dos dias que possuíam falhas.

$$f'_{(n)} = \max(a(1 - a); 0,01) \quad (7)$$

```

% Leitura dos dados
load dados
% Recursos previstos:
unisig=inline('1./(1+exp(-n))'); dunisig=inline('max(a.*(1-a),0.01)');
esclin=inline('(v-b*u)/(a*u)', 'v', 'a', 'b', 'u'); reclin=inline('(a*u).*s+b*u', 's', 'a', 'b', 'u');
% Montagem da matriz de dados e eliminação das falhas
p=[dados(1,:); dados(17,:)];
t=dados(20,:);
Var=[p;t];[i,j]=find(Var==-1); Var(:,j)=[]; P=Var(1:end-1,:); T=Var(end,:);
% Inspeção dos dados de saída
close all, plot(T,'b');

% ESCALONAMENTO DOS DADOS E SEPARAÇÃO DAS SÉRIES PARA TREINAMENTO E
VERIFICAÇÃO:
% Inspeção de máximos e mínimos e parâmetros para o escalonamento:
[min(P)' max(P)'], [min(T)' max(T)']
minP=[0 0 30]; maxP=[100 250 2300]; minT=30; maxT=2300;
[ae,be]=fnescaline(minP,maxP); [au,bu]=fnescaline(minT,maxT);
% Separação das amostras:
nTot=length(T); nT=round(nTot.*0.35);
P1=P(:,nT+1:end); T1=T(:,nT+1:end); P2=P(:,1:nT); T2=T(:,1:nT);
% Vetores auxiliares e escalonamentos:
ut=ones(1,length(T1)); pt=esclin(P1,ae,be,ut); tt=esclin(T1,au,bu,ut);
uv=ones(1,length(T2)); pv=esclin(P2,ae,be,uv); tv=esclin(T2,au,bu,uv);

% ARQUITETURA BÁSICA DA REDE:
As=unisig; Ds=dunisig; Ah=unisig; Dh=dunisig; nh=5;
% Treinamento com múltiplas inicializações e escolha do melhor resultado:
ciclos=10000; nh=5; Eqmin=10000.0; nit=50; Prec=0; freq=0; prec=Prec/au; clc, close all
modelo_1=['M1A1_' int2str(ciclos) '_' int2str(nh)]; disp(['modelo_1 = ' modelo_1])
t_ini=cputime;
for i=1:nit
    disp(['i = ' num2str(i)]);
    [wh, bh, ws, bs, Eq, Tx, De] = fnetropt(pt, tt, Ah, Dh, As, Ds, nh, ciclos, prec, freq);
    if Eq(:,end)<Eqmin;
        Eqmin=Eq(:,end);
        save(modelo_1,'Ah', 'Dh', 'As', 'Ds', 'nh', 'wh', 'bh', 'ws', 'bs', 'ae', 'be', 'au', 'bu', 'nit')
    end
end
t_fim=(cputime-t_ini)/60;
disp(['% Tempo de processamento = ' num2str(t_fim) ' minutos'])

% VERIFICAÇÃO DOS RESULTADOS:
load(modelo_1)
Tc=reclin(As(ws*Ah(wh*pv+bh*uv))+bs*uv),au,bu,uv);
% Coeficiente de Nash e Sutcliffe (NS):
Num=sum(((T2-Tc).^2));
Den=sum(((T2-mean(T2)).^2));
NS=1-Num./Den;
e=T2-Tc; eabs=abs(e);
disp([' NS = ' num2str(NS)]);
close all, plot(T2,'b'), hold on, plot(Tc,'r'), hold on, plot(eabs,'g'), title('real (azul) x calculado
(vermelho) x diferença (verde) ')

```

Para o escalonamento linear dos dados foi realizada uma investigação dos valores máximos e mínimos das entradas e saídas, de forma a escolher os limites inferiores e

superiores do domínio, buscando deixar uma “folga” entre os limites escolhidos e os valores dos extremos. Foi utilizada uma rotina própria (fnescaline) no escalonamento das entradas e saídas. Posteriormente foi realizada a separação das amostras, com 65% dos dados utilizados para o treinamento e 35% para a verificação, buscando selecionar o período que possuía os maiores valores para a série de treinamento. Os dados foram escalonados antes de serem utilizados no treinamento.

Foi realizado o treinamento da rede neural com a utilização de uma rotina própria para o algoritmo retropropagativo (fnretropp), onde foram apresentados os números de neurônios, número de interações (repetições do treinamento) e número de ciclos. A rede neural foi treinada 50 vezes, com o objetivo de minimizar os efeitos causados pela aleatoriedade das condições iniciais.

Nesse estudo optou-se pela não utilização da técnica de validação cruzada, que é mais frequentemente usada para evitar o superajustamento da rede neural, por considerarmos que as séries de dados não são muito extensas e a sua divisão em uma sub-série adicional para a validação iria reduzir ainda mais a quantidade de dados disponível para o treinamento. Assim, para evitar o superajustamento, foi feita a experimentação sistemática com número crescente de ciclos de treinamento, buscando-se aquele que apresentasse melhores resultados, através da avaliação da série de verificação, para todas as alternativas de controle de montante. A ideia é que se, a partir de um certo número de ciclos, a verificação sofresse redução de desempenho, este número de ciclos seria o limite para o treinamento sem o superajustamento. Foram realizadas simulações com incrementos de variações de 5 mil ciclos, até chegar a 120 mil. O ponto de parada do treinamento da rede neural foi o número total de ciclos.

Após o treinamento, o modelo completo (equação 3) é aplicado à série de verificação, resultando em valores, na escala original, da variável de saída. A comparação destes resultados com os valores observados, por inspeção visual e pela aplicação de estatísticas de desempenho, permite avaliar a qualidade do modelo.

Para a análise do desempenho da rede neural foi aplicado como estatística de qualidade o coeficiente de Nash-Sutcliffe (NS), o qual representa a proporção da variância que é explicada pelo modelo em relação à variância total dos dados observados (equação 8). O coeficiente NS pode variar entre negativo infinito até 1, com o valor 1 sendo considerado o ajuste perfeito.

$$NS = 1 - \frac{\sum_{i=1}^N (Q_{o_i} - Q_{p_i})^2}{\sum_{i=1}^N (Q_{o_i} - \overline{Q_o})^2} \quad (8)$$

Onde Q_{p_i} é o valor estimado pelo modelo; Q_{o_i} é o valor observado; $\overline{Q_o}$ é o valor médio dos valores observados no período de verificação; N é o número de valores do conjunto de verificação.

Foram utilizadas diferentes entradas para cada uma das oito alternativas de controle de montante, e sempre uma mesma saída, o posto fluviométrico de Ponte Mística, para a previsão de vazão de um dia à frente (dia $t+1$). As entradas são os dados de precipitação e vazão da bacia da Ponte Mística, além dos dados de vazões das sub-bacias embutidas, as quais funcionam como controle de montante, conforme esquematizado na Tabela 4.4.

Tabela 4.4. Alternativas de entradas das redes neurais usadas como controle para estimativa da vazão na Ponte Mística.

Alternativas	1	2	3	4	5	6	7	8	9	Área (km ²)	% da área controlada
Q Ponte Mística (t)	■	■	■	■	■	■	■	■	■		
Q Santo Ângelo (t)		■					■			5.540	58,6
Q Colônia Mousquer (t)			■				■			2.160	22,9
Q Passo do Faxinal (t)				■				■		1.940	20,5
Q Potiribu (t)					■			■		690	7,3
Q Turcato (t)						■			■	19,5	0,2
Q Turcato horário (t)									■	19,5	0,2
P Ponte Mística (t)	■	■	■	■	■	■	■	■	■	9.450	-

As variáveis de entrada foram escolhidas em função da disponibilidade de dados na região, em função da finalidade deste estudo. Também foram aplicadas, para cada uma das alternativas anteriores, componentes antecedentes, com a utilização dos dados de vazão dos dias anteriores, para avaliar sua influência na previsão de vazão. Para se determinar até quantos dias anteriores contribuiriam para a melhora do modelo, foram feitos correlogramas entre as séries de vazão de cada uma das alternativas de controle, com defasagem máxima de 10 dias. Na rede neural, as componentes antecedentes são inseridas como uma serie de dados de vazão iniciando um dia antes (dia $t-1$), no caso da componente de 24 hs, e um e dois dias antes (dias $t-1$ e $t-2$), no caso da componente de 48 hs de antecedência, e assim por diante.

A alternativa 9 corresponde a uma variação da alternativa 6, com o acréscimo dos dados de vazões horárias da sub-bacia do Turcato. Foram inseridas, nessa alternativa, como entradas na rede neural, 24 séries de dados de vazão correspondentes a cada hora das últimas 24 horas antes do horizonte de informações do dia, além dos dados diários de chuva e vazão. A comparação entre as duas alternativas permite investigar se a utilização de vazões de entrada com um maior detalhamento temporal pode produzir melhores resultados.

Uma vez que, neste trabalho, a verificação pela análise de sensibilidade a perturbações tem uma finalidade complementar, para verificação e crítica das premissas induzidas pelos métodos de decisão com base na análise preliminar (variáveis explicativas independentes e efeitos lineares ou aproximadamente lineares), um índice simples de calcular, robusto e suficientemente eficiente é requerido.

O índice utilizado foi semelhante ao que foi empregado por Maier e Dandy (1997), porém com as seguintes alterações:

1. A dificuldade relativa às diferenças de magnitude dos dados foi resolvida com a indução de alterações sobre a variável escalonada, e verificação do efeito sobre a variável de saída antes da transformação de retorno à escala original.
2. Os resultados não são calculados em porcentagem, e significam o grau de amplificação ($\text{abs}(S) > 1$) ou amortecimento ($\text{abs}(S) < 1$), nas saídas do modelo, das modificações induzidas. O sinal de S indica o sentido da variação conjunta da variável explicativa e da variável explicada.

Em geral, espera-se amortecimento do efeito de cada variável, tendo-se em conta que a característica da robustez das redes neurais pressupõe este efeito. Porém, variáveis explicativas cujas variabilidades são menos importantes para a variabilidade da variável de saída terão amortecimento maior (ou seja, valor absoluto de S menor).

As modificações não precisam ser grandes, e deve-se evitar ultrapassar, nos extremos, o domínio das variáveis. Assim, utilizou-se o valor fixo 1/1000 para o incremento em todas as variáveis, o que é razoável, tendo-se em conta que, após o escalonamento, todas possuem a mesma escala.

Descrição do algoritmo utilizado:

Escalonamento das entradas e das saídas: $p = f(P)$; $t=g(T)$;

Cálculo dos resultados da rede neural, com os dados originais:

$tc=RN(p)$;

Para cada variável explicativa i , faz:

A variável i de entrada tem seus valores modificados, sendo estas modificações correspondentes a um incremento de $1/1000$ sobre seus valores originais;

$pm(i) = p(i)$ modificada pela adição de $1/1000$;

O modelo é aplicado, com a variável de entrada modificada:

$tm = RN(\text{variáveis de entrada com dados originais para as demais variáveis, e modificados para a variável } i = p(1), \dots, pm(i), \dots, p(n))$;

Cálculo da influência da variável i :

$S(i) = \text{soma}(tm - tc)/\text{soma}(pm(i) - p(i))$;

Até a última variável explicativa n .

5. RESULTADOS

Os resultados dos correlogramas são apresentados na Tabela 5.1. Foi adotado como critério para escolha do número de componentes antecedentes, as correlações maiores que 0,60.

Tabela 5.1. Resultados dos autocorrelogramas (Ponte Mística com Ponte Mística) e dos intercorrelogramas (Ponte Mística com postos de controle de montante e de precipitação).

Defasagem (dias)	Ponte Mística	Colônia Mousquer	Santo Ângelo	Passo do Faxinal	Potiribu	Turcato	Prec.
1	0,90	0,87	0,92	0,87	0,85	0,62	0,32
2	0,71	0,73	0,79	0,81	0,77	0,67	0,46
3	0,51	0,55	0,59	0,59	0,59	0,39	0,41
4	0,35	0,38	0,42	0,45	0,42	0,18	0,26
5	0,26	0,27	0,31	0,32	0,29	0,14	0,13
6	0,21	0,19	0,24	0,24	0,22	0,11	0,08
7	0,18	0,15	0,19	0,19	0,18	0,09	0,05
8	0,15	0,12	0,16	0,15	0,14	0,08	0,05
9	0,13	0,10	0,13	0,13	0,11	0,06	0,08
10	0,12	0,09	0,10	0,10	0,08	0,03	0,10

As precipitações apresentaram melhores correlações para defasagens de 2 e 3 dias. Porém, estas foram relativamente pequenas, abaixo do limiar estabelecido como referência, portanto, optou-se pela utilização de modelos que utilizam precipitações apenas no tempo atual.

Os resultados da eficiência dos modelos de RNAs são apresentados na Tabela 5.2, com as nove alternativas de modelos, com as respectivas áreas controladas, número de registros e ciclos utilizados, bem como as estatísticas correspondentes. Foi escolhido o melhor modelo em função do coeficiente NS, que encontram-se hachurados nesta tabela.

Os melhores resultados para cada alternativa de controle de montante foram encontrados com diferentes números de ciclos. O número de ciclos que proporcionou o melhor ajuste faz parte do procedimento de treinamento, e não é uma característica estrutural da rede neural, tendo sido esgotados os esforços, em termos de número de ciclos, para o treinamento de cada modelo.

Foram encontradas, para todas as alternativas de controle de montante, bons coeficientes Nash-Sutcliffe, considerando-se a recomendação de alguns autores (Coulibaly et al., 2000), para os quais são considerados bons os resultados acima de 0,70. Os melhores resultados foram encontrados com as alternativas 2 e 7, com NS de 0,97, apresentando o mesmo resultado com e sem componentes antecedentes de vazão, portanto foi selecionado o modelo com menor número de parâmetros, que é o previsto com dados de vazão somente no dia t. Estes resultados demonstram a eficiência dos modelos apresentados para prever vazões de curto prazo, podendo estes modelos servirem de base para a elaboração de sistemas de alertas de enchentes para a região.

Tabela 5.2. Entradas da rede, proporção de área controlada (%), número de registros e ciclos e estatísticas de desempenho da RNA na previsão de vazão.

Alternativas	% de área controlada	Somente dia atual (t)			+ dados do dia t-1			+ dados dos dias t-1 e t-2		
		Nº de registros	Nº de Ciclos	NS	Nº de registros	Nº de Ciclos	NS	Nº de registros	Nº de Ciclos	NS
1	-	1.408	10.000	0,93	1.407	15.000	0,94	1.406	15.000	0,94
2	58,62	1.408	15.000	0,97	1.407	15.000	0,97	1.406	25.000	0,97
3	22,9	1.408	10.000	0,95	1.407	15.000	0,96	1.406	20.000	0,95
4	20,5	1.135	20.000	0,94	1.133	15.000	0,95	1.131	20.000	0,94
5	6,5	1.408	10.000	0,94	1.407	40.000	0,96	1.406	20.000	0,96
6	0,2	523	80.000	0,91	304	75.000	0,91	304	15.000	0,94
7	58,6 e 22,9	1.408	15.000	0,97	1.407	10.000	0,97	1.406	35.000	0,97
8	20,5 e 7,3	1.135	15.000	0,94	1.133	15.000	0,95	1.131	45.000	0,94
9	0,2	470	15.000	0,89	-	-	-	-	-	-

Os piores resultados foram obtidos para as alternativas 6 e 9, com NS de 0,91 e 0,89, respectivamente, onde foram utilizados dados da bacia de menor área (Turcato). A quantidade de registros válidos disponíveis para cada uma das alternativas de modelo foi diferente, pois cada série apresenta um padrão específico de falhas. Assim, as entradas da rede neural das alternativas 6 e 9, que apresentaram os menores coeficientes NS, contaram com apenas 523 e 470 registros, respectivamente, menos que a metade das demais. Uma vez que os registros válidos são em menor quantidade que os das outras alternativas (as quais possuem número de registros bastante semelhantes entre si), a comparação, em termos absolutos, entre as alternativas 6 e 9 e as demais, fica prejudicada, porque as séries utilizadas podem ter magnitude dos dados diferentes. Portanto, as alternativas 6 e 9 devem ser comparadas entre si, mas não com as demais. A utilização de dados horários (alternativa 9), ao contrário do esperado (devido à maior

quantidade de informações), produziu um resultado pior do coeficiente NS. Uma explicação para isso pode ser devido ao fato que ao serem consideradas as vazões horárias, o dado é naquela hora discreta, não considerando as flutuações entre as leituras, o que pode causar perda de informações para bacias da magnitude do Turcato (19,5 km²). Ao contrário, os dados diários são resultantes da integração das vazões em 24 horas com intervalo discreto de registro a cada 15 minutos, com menor perda de informações, reduzindo o espaço de tempo sem informações, onde um pico de vazão, por exemplo, poderia não ser analisado. Possivelmente por este motivo, os dados horários não contribuíram para melhoria da eficiência do modelo, causando até mesmo uma redução nesta. Outro motivo que pode explicar esta redução é que quando as variáveis explicativas não são independentes entre si, o acréscimo destas variáveis não necessariamente implica em melhoria dos resultados.

A utilização de componentes com 24 hs de antecedência apresentou melhores resultados em cinco das oito alternativas de controle (alternativa 1, 3, 4, 5 e 8). Já a utilização das componentes com 24 hs e 48 hs de antecedência apresentou uma melhora apenas na alternativa 6 (0,94). Isto confirma a ideia de que as vazões dos dias anteriores das bacias contribuintes são, em alguns casos, importantes para a previsão das vazões no exutório. É possível que, pela maior distância da menor bacia (Turcato) ao exutório, as vazões demorem mais tempo para completar o percurso, fazendo com que as vazões de dois dias (dia $t-2$) atrás constituam, neste caso, contribuição adicional às do tempo atual (dia t) e de um dia atrás (dia $t-1$).

Conforme os resultados apresentados, tomando-se como base a alternativa 1, onde o único controle seria no próprio exutório (Ponte Mística), e comparando-se com as demais alternativas de controle, que contemplam as sub-bacias embutidas no seu interior, com áreas controladas entre 0,2% e 58,6%, as alternativas de utilização de postos de montante apresentaram proporcionalmente melhores resultados.

As figuras de 5.1 a 5.9 apresentam os dados de vazão observados e calculados pelas RNAs para cada uma das 9 alternativas de controle de montante.

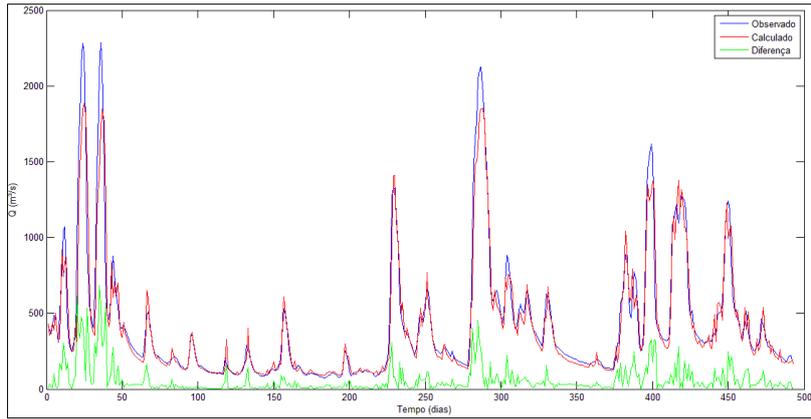


Figura 5.1. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 1.

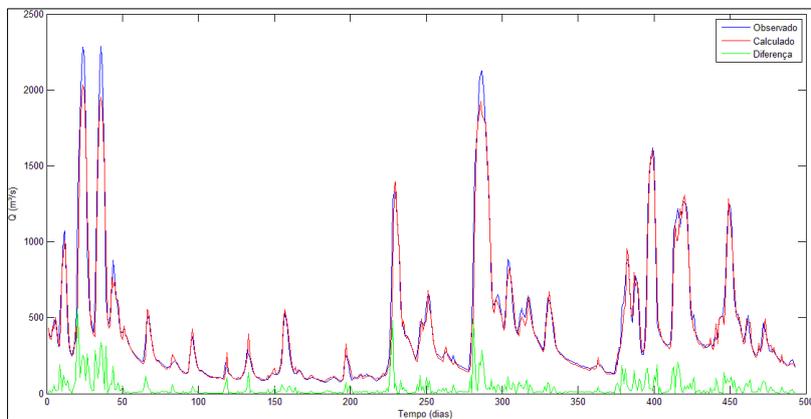


Figura 5.2. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 2.

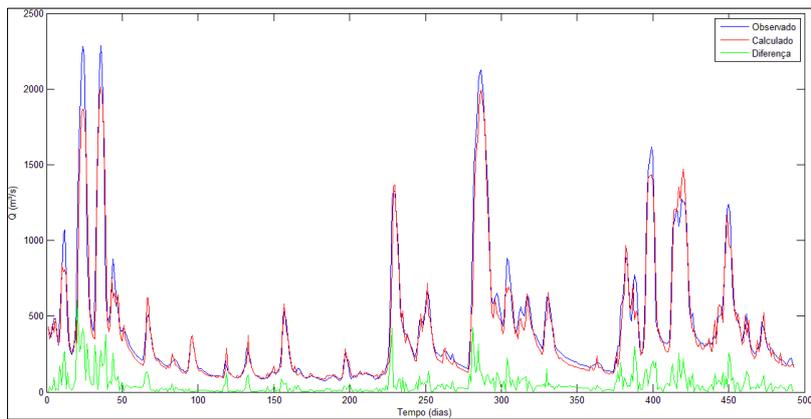


Figura 5.3. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 3.

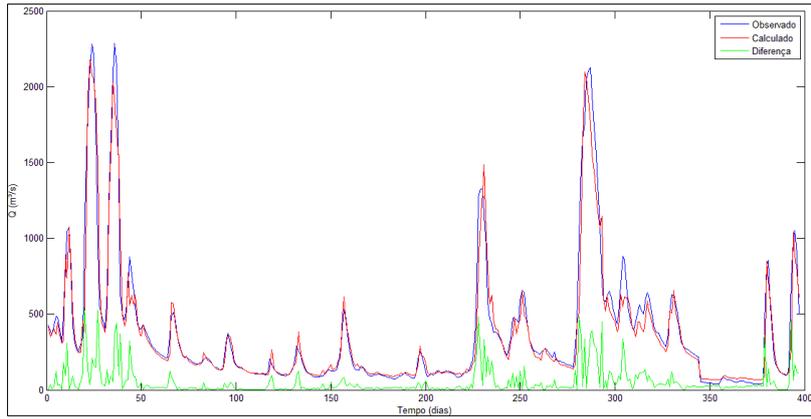


Figura 5.4. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 4.

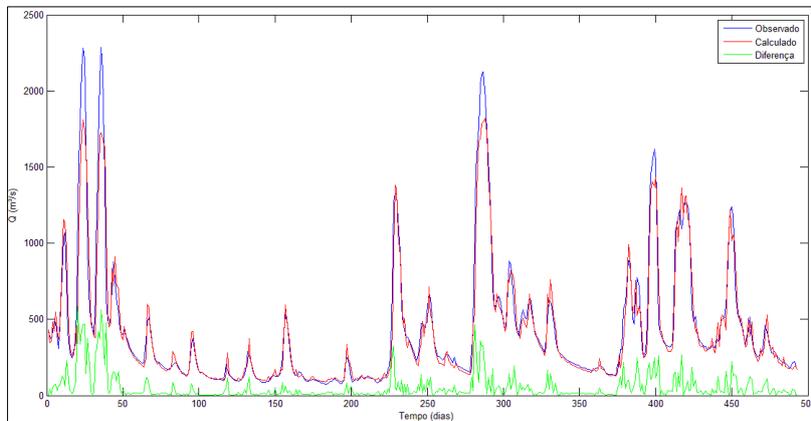


Figura 5.5. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 5.

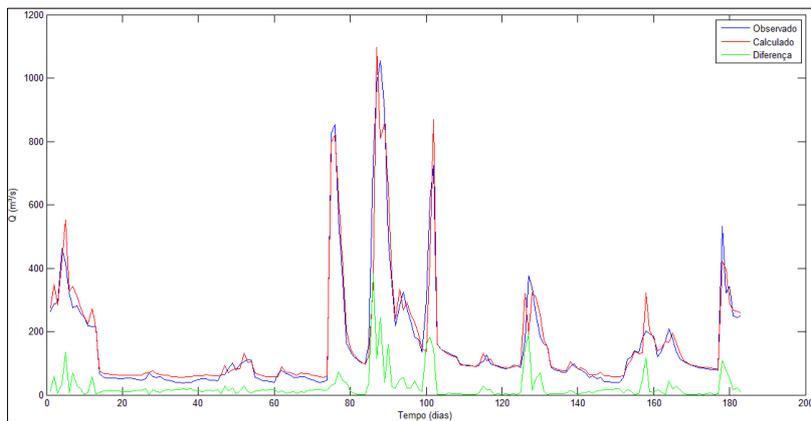


Figura 5.6. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 6.

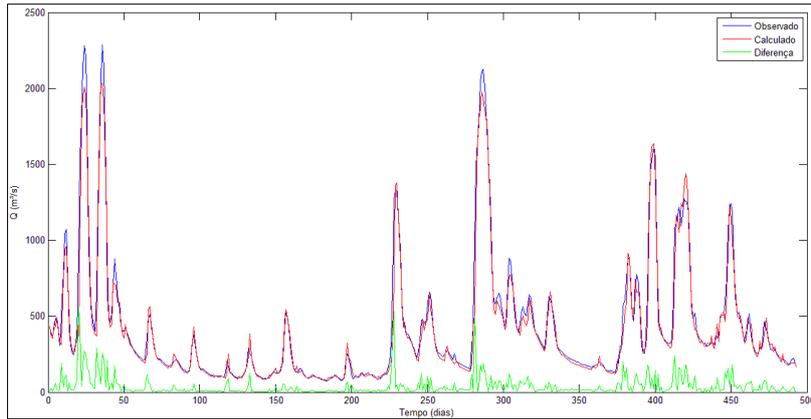


Figura 5.7. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 7.

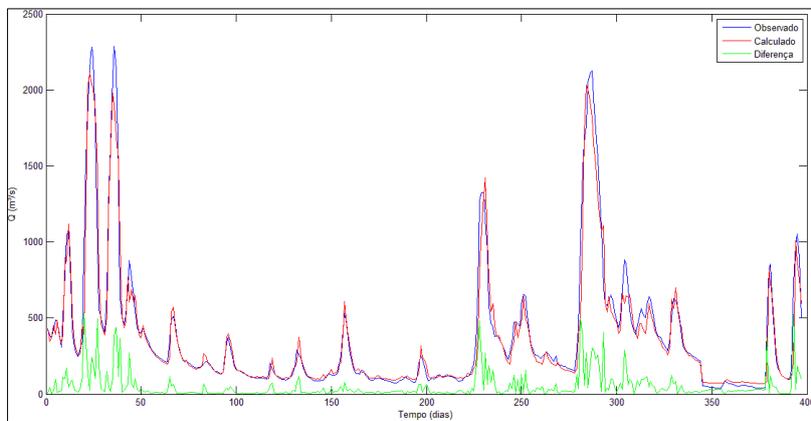


Figura 5.8. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 8.

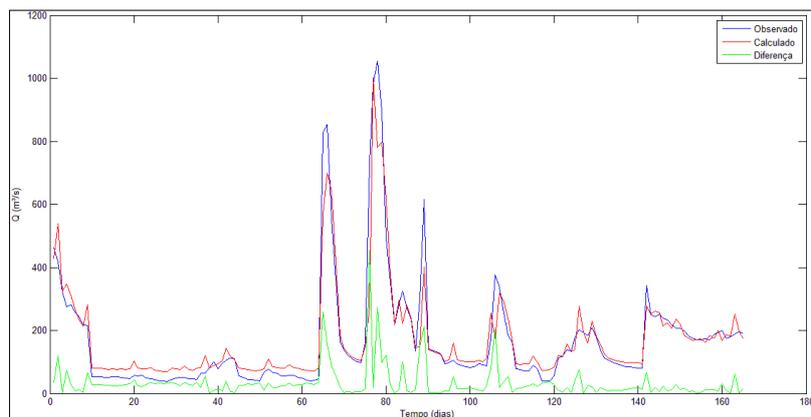


Figura 5.9. Gráfico da vazão calculada x vazão observada, e a diferença entre elas para a alternativa 9.

É possível observar que os as vazões calculadas foram muito parecidas com as observadas, porém não se conseguiu representar bem os picos com grandes vazões. Analisando-se as diferenças entre as vazões observadas e as vazões calculadas, é possível observar que as maiores ocorrem nos dias onde houve grandes picos de vazão. Isto significa que os modelos propostos conseguiram reproduzir melhor as vazões de menor intensidade do que as maiores.

A utilização dos dados de vazão referentes à bacia de Passo do Faxinal, juntamente com a bacia do Potiribu (alternativa 8), quando comparadas com quando se utilizou apenas os dados de vazão da bacia do Potiribu (alternativa 5), não produziu uma melhora nos resultados. Igualmente, os resultados do modelo não melhoraram, quando se comparou o uso de dados da bacia de Santo Ângelo (alternativa 2) com o uso simultâneo, além destes, dos dados da bacia de Colônia Mousquer (alternativa 7). Isso ocorre porque, às vezes, uma sub-bacia menor, neste caso, Potiribu (alternativa 5) e Santo Ângelo (alternativa 2), é bem representativa, possuindo informações que são proporcionais às da área maior. A presença de variáveis de estado redundantes pode reduzir a eficiência do modelo, pois os pesos sinápticos internos são influenciados por todas as entradas e uma variável desnecessária pode dificultar o procedimento de treinamento, prejudicando a representatividade dos fenômenos modelados.

A Tabela 5.3 apresenta os resultados da análise de sensibilidade, onde é possível verificar a influência as variáveis de entrada exercem sobre cada uma das alternativas de controle de montante. Esta tabela apresenta os resultados das alternativas de controle com e sem a utilização das componentes antecedentes.

A explicação da influência de cada variável de entrada, para cada uma das oito alternativas testadas, e para as três configurações, ou seja, com uma, duas ou três entradas de vazões, segundo as respectivas defasagens, $t-0$, $t-1$ e $t-2$ dias, para cada variável, resulta da análise da tabela 5.3:

Alternativa 1 (sem contribuições de bacias de montante): Apresenta influências muito pequenas para as vazões antecedentes, e predominantes para as vazões no tempo atual. Porém, esta predominância aumenta quando as vazões com antecedência de um dia são acrescentadas, com redução da influência das precipitações diárias, reduzindo-se com o acréscimo das componentes de dois dias de antecedência.

Tabela 5.3. Resultados da análise de sensibilidade.

Alternativas	Tempo	1	2	3	4	5	6	7	8
Precipitação	t	0.303	0.215	0.29	0.176	0.251	0.11	0.213	0.193
Q Colônia	t	-	-	0.262	-	-	-	0.190	-
Q Passo do	t	-	-	-	0.2662	-	-	-	0.2248
Q Potiribu	t	-	-	-	-	0.345	-	-	0.195
Q Santo Ângelo	t	-	0.455	-	-	-	-	0.439	-
Q Turcato	t	-	-	-	-	-	0.474	-	-
Q Ponte Mística	t	0.829	0.53	0.69	0.665	0.689	0.774	0.447	0.591
Alternativas		1	2	3	4	5	6	7	8
Precipitação	t	0.226	0.192	0.212	0.174	0.209	0.162	0.176	0.173
Q Colônia Mousquer	t	-	-	0.278	-	-	-	0.176	-
	t-1	-	-	-0.079	-	-	-	-0.026	-
Q Passo do Faxinal	t	-	-	-	0.246	-	-	-	0.202
	t-1	-	-	-	0.021	-	-	-	-0.002
Q Potiribu	t	-	-	-	-	0.203	-	-	0.196
	t-1	-	-	-	-	0.081	-	-	-0.013
Q Santo Ângelo	t	-	0.476	-	-	-	-	0.407	-
	t-1	-	-0.153	-	-	-	-	-0.095	-
Q Turcato	t	-	-	-	-	-	0.109	-	-
	t-1	-	-	-	-	-	0.339	-	-
Q Ponte Mística	t	0.901	0.612	0.786	0.654	0.804	0.773	0.535	0.628
	t-1	-0.073	0.026	-0.039	0.017	-0.083	0.021	0.027	-0.003
Alternativas		1	2	3	4	5	6	7	8
Precipitação	t	0.238	0.191	0.211	0.177	0.219	0.230	0.167	0.203
Q Colônia Mousquer	t	-	-	0.273	-	-	-	0.167	-
	t-1	-	-	-0.113	-	-	-	-0.062	-
	t-2	-	-	0.018	-	-	-	0.024	-
Q Passo do Faxinal	t	-	-	-	0.236	-	-	-	0.091
	t-1	-	-	-	0.150	-	-	-	0.205
	t-2	-	-	-	-0.168	-	-	-	-0.138
Q Potiribu	t	-	-	-	-	0.257	-	-	0.188
	t-1	-	-	-	-	0.131	-	-	-0.004
	t-2	-	-	-	-	-0.112	-	-	-0.128
Q Santo Ângelo	t	-	0.485	-	-	-	-	0.474	-
	t-1	-	-0.185	-	-	-	-	-0.15	-
	t-2	-	-0.001	-	-	-	-	-0.033	-
Q Turcato	t	-	-	-	-	-	-0.152	-	-
	t-1	-	-	-	-	-	0.284	-	-
	t-2	-	-	-	-	-	0.059	-	-
Q Ponte Mística	t	0.882	0.609	0.798	0.652	0.743	0.607	0.550	0.58
	t-1	-0.129	-0.015	-0.126	-0.033	-0.086	0.042	-0.013	0.062
	t-2	0.075	0.062	0.084	0.100	0.069	0.073	0.067	0.066

Alternativa 2 (contribuições de montante no posto de Santo Ângelo): A influência do posto de Santo Ângelo é grande, maior do que a das precipitações, embora menor do que a do próprio posto de Ponte Mística. O acréscimo de componentes de vazões antecedentes aumenta ligeiramente a influência das vazões no tempo atual, e diminui a das precipitações diárias. As influências das vazões com antecedência de dois dias são individualmente muito pequenas, podendo ser negativas.

Alternativa 3 (contribuições de montante no posto de Colônia Mousquer): A influência do posto de Colônia Mousquer foi, com as vazões do tempo atual apenas, menor do que a das precipitações diárias. Porém, com o uso das vazões antecedentes, tornou-se um pouco maior, além do que a influência das precipitações tende a reduzir significativamente, com o acréscimo de mais informações, em favor também das vazões do próprio posto de Ponte Mística. As influências das vazões antecedentes, porém, são, individualmente, muito pequenas, e por vezes negativas.

Alternativa 4 (contribuições de montante no Passo do Faxinal): A influência das vazões de Passo do Faxinal foram maiores do que as das chuvas, e, à medida que vazões antecedentes foram usadas, todas as demais contribuições passaram a ter menos influência. Com o uso de variáveis antecedentes de um e de dois dias, as influências destas foram significativas, de 0,15 e -0,17, respectivamente.

Alternativa 5 (contribuições de montante no posto de Potiribu): A influência das vazões no tempo atual foi maior do que a influência das precipitações diárias. Porém, com a introdução das componentes antecedentes de vazão, esta influência diminui para a mesma ordem de grandeza, uma vez que a influência destas precipitações também torna-se menor. A preponderância das vazões atuais do próprio posto de Ponte Mística, por sua vez, aumenta, sendo máxima quando são utilizadas as componentes antecedentes com defasagem de um dia, apenas.

Alternativa 6 (contribuições de montante no posto de Turcato): A influência da componente de tempo atual das vazões no Turcato são, inicialmente, maiores do que as das precipitações. Porém, à medida que são acrescentadas as componentes antecedentes, estas tendem a reduzir-se. A influência máxima das vazões do Potiribu ocorre, após a inclusão de variáveis antecedentes, com as vazões com antecedência de 24 horas em relação ao tempo atual.

Alternativa 7 (contribuições de montante dos postos de Colônia Mousquer e de Santo Ângelo): As influências das vazões no tempo atual de Colônia Mousquer são sempre da mesma ordem de grandeza que as influências das contribuições de Santo

Ângelo, as quais aproximam-se das influências das vazões no tempo atual em Ponte Mística. A introdução das componentes antecedentes de vazão resulta na redução progressiva da influência das precipitações diárias, porém, a maior predominância das vazões atuais de Ponte Mística ocorre com somente uma componente antecedente das vazões deste posto e dos demais. A influência das vazões da bacia de Santo Ângelo é muito maior do que a influência das vazões do posto de Colônia Mousquer.

Alternativa 8 (contribuições de montante dos postos de Passo do Faxinal e do Potiribu): As influências das vazões no tempo atual foram maiores do que as influências das precipitações diárias, inclusive quando introduzidas as vazões com antecedência de 24 horas, quando foi máxima a predominância da influência do próprio posto de Ponte Mística. As vazões antecedentes de 48 horas fizeram com que a influência predominante de Passo do Faxinal se deslocasse para o tempo $t-1$ dia. Também observa-se que a influência de Passo do Faxinal é da mesma ordem da do Potiribu, embora sua área seja bem maior.

A influência das vazões do posto de Santo Ângelo (alternativa 2), no tempo atual (dia anterior ao dia da previsão) foi significativa, sendo que as influências das contribuições antecedentes de um dia não foram suficientes para resultar um modelo mais eficiente, e as de dois dias de antecedência foram irrelevantes. Isto está coerente com a proximidade relativa deste posto ao de Ponte Mística. A alternativa 7, com adição de Colônia Mousquer, reduz apenas ligeiramente a influência deste posto, pois são pouco influentes as contribuições desta bacia, apesar da proximidade semelhantes, talvez em parte pela diferença da área de drenagem.

A influência das vazões no tempo atual da bacia controlada pelo posto do Potiribu (alternativas 4 e 5) foi, apesar da área bem menor, maior do que a influência respectiva do posto de Passo do Faxinal. Apenas quando foram consideradas as contribuições de vazões antecedentes de um dia, mas não as contribuições de dois dias, é que Passo do Faxinal apresentou maior influência, mas com pequena diferença, sendo esta a antecedência de vazões adotada, com base nos resultados globais de desempenho do modelo. Apesar das áreas de contribuição reduzidas, as influências das vazões foram da mesma ordem de grandeza, e, em geral, maiores do que as das precipitações diárias.

A bacia controlada pelo posto do Turcato (alternativa 6) foi a única que apresentou vantagens, em termos de desempenho, com as contribuições antecedentes de dois dias, o que pode ser explicado pela maior distância do exutório. Apesar da pequena área de drenagem, a sua influência foi sempre significativamente maior do que a das

precipitações diárias, apresentando-se maior para antecedências de um dia, e pouco significativa para antecedências de dois dias, embora estas vazões tenham contribuído para potencializar as demais, proporcionando melhores resultados. Neste caso, observou-se que as vazões de uma bacia muito pequena, e distante do exutório, podem ainda assim ser mais influentes sobre as previsões do que as chuvas médias diárias.

Os resultados mostram que para os modelos mais simples, apenas com dados no tempo t , as variáveis de entrada escolhidas são muito importantes, com os valores absolutos de influência variando entre 0,11 (na precipitação da alternativa 6) e 0,829 (na vazão de Ponte Mística da alternativa 1). A partir do momento que são inseridas componentes antecedentes é possível verificar que estas novas variáveis influenciam diretamente nas variáveis anteriores, com algumas delas apresentando valores muito baixos, chegando a 0,002 na vazão do passo do faxinal com dados no tempo $t-1$ da alternativa 8. Com a utilização das componentes antecedentes, houve uma melhora nas vazões de Ponte Mística no tempo t para quase todas as alternativas (1, 2, 3, 5, 7 e 8), com o maior resultado sendo encontrado para a alternativa 1 (0,901). As componentes antecedentes com dois dias de antecedência também apresentaram influência nos resultados, embora com valores baixos, fizeram com que houvesse uma redução na influência das vazões da Ponte Mística do dia t , nestes casos, consideradas as mais importantes, em quase todas as alternativas.

É possível verificar que algumas variáveis possuem valores absolutos de influência muito baixos, indicando que, para aquela situação específica, estas variáveis não seriam tão importantes. Porém, mesmo que algumas variáveis não tenham sido tão importantes, tem-se que salientar a sua contribuição para os resultados finais da previsão, que foram muito bons. Isto se deve ao efeito potencializador que umas variáveis ou componentes possuem sobre outras.

A Figura 5.10 apresenta uma relação entre as proporções das áreas das sub-bacias embutidas (áreas controladas) em relação à área total da bacia de Ponte Mística e os coeficientes de eficiência NS encontrados nas alternativas de controle de montante. Para esta análise não foram considerados os resultados dos modelos que possuem componentes antecedentes porque as séries de dados utilizadas em cada uma delas são diferentes para cada uma das alternativas, assim para algumas as informações dos dias anteriores são importantes e para outros não. Também não foram consideradas as alternativas que possuem controle simultâneo de dois postos.

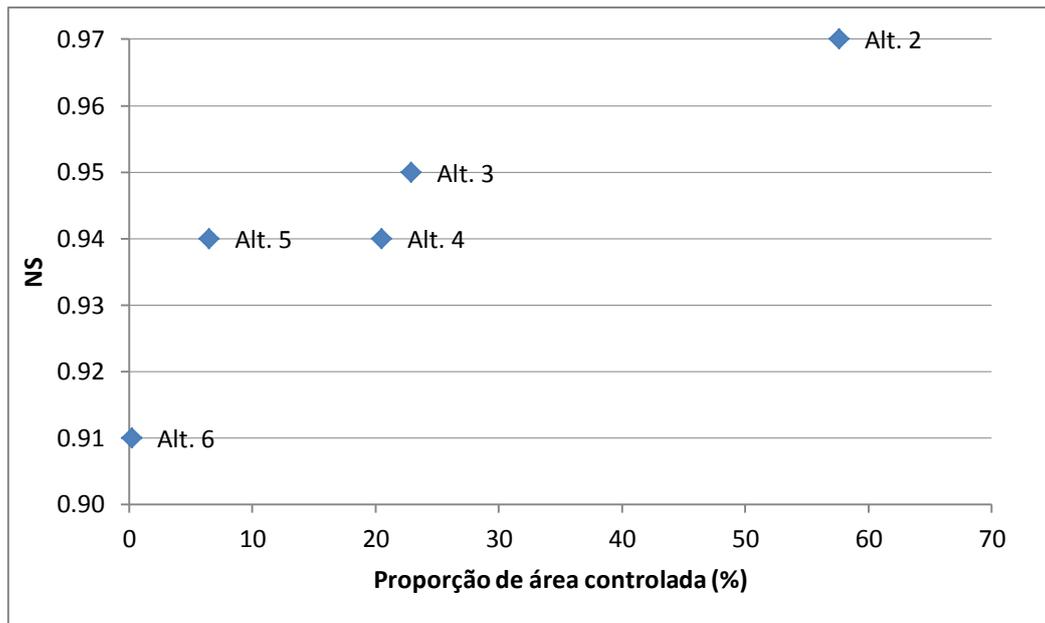


Figura 5.10. Proporção de área controlada das bacias de montante e a eficiência do modelo.

É possível verificar uma tendência de que, quando utiliza-se como dados de entrada no modelo de previsão de vazões diárias para um dia à frente, as vazões de controle de bacias de montante, além das vazões do próprio posto que deseja-se estimar, o modelo consegue uma eficiência que aumenta com a proporção de área controlada, até atingir uma determinada proporção a partir do qual o desempenho tenderá a diminuir.

Isto ocorre porque o aumento da proporção da área controlada significa maior quantidade de informações de vazão que contribuem para o modelo, com redução das incertezas (falta de informações) devidas à área não controlada, ou controlada unicamente por informações de precipitação. Porém, o aumento desta proporção provoca redução do tempo de deslocamento das contribuições fluviais. Se este tempo é menor do que o alcance temporal estabelecido para um modelo, parte das contribuições que são importantes para a previsão ainda não terão chegado, no tempo atual, à seção de montante considerada, tendo-se, então, outra fonte de incertezas, a qual é devida, pode-se dizer, ao espaço temporal não controlado. Quando, à medida que aumenta-se a proporção da área controlada, estas incertezas, devidas ao espaço temporal não controlado, passam a ser mais importantes que as incertezas devidas à área não controlada, passa a ocorrer redução do desempenho do modelo.

A melhora da eficiência do modelo, quando são consideradas as vazões diárias de bacias de controle a montante, mesmo para bacias muito pequenas (Turcato), deve-se ao

fato que, ao considerarmos estes dados, são adicionadas indiretamente informações hidrológicas muito importantes destas sub-bacias, cujos efeitos estão integrados nestas vazões, como precipitação, evapotranspiração e umidade do solo, e que podem estar relacionadas com os processos semelhantes no restante da bacia.

6. CONCLUSÕES E RECOMENDAÇÕES

6.1. Conclusões referentes à pesquisa

A aplicação das redes neurais artificiais para a previsão de curto prazo, com um dia à frente no exutório da bacia da Ponte Mística, permitiu a elaboração das seguintes conclusões:

- A utilização das redes neurais artificiais na previsão de vazão com uso de bacias embutidas mostrou-se bastante eficiente, se levarmos em conta as estatísticas de desempenho da rede, com coeficientes NS variando entre 0,89 e 0,97;

- Na aplicação do modelo com a utilização de componentes antecedentes, os resultados apresentaram uma melhora em cinco das oito alternativas de controle de montante (alternativas 1, 3, 4, 5 e 8), com a utilização das vazões com 24 h de antecedência (t-1), enquanto que, para as demais, os resultados se mantiveram os mesmos. A introdução de informações de vazão média diária com 48 h de antecedência produziu melhora apenas para a alternativa 6 (de 0,91 para 0,94).

- Os resultados comprovam que, ao contrário do esperado, a utilização de dados com um maior detalhamento temporal (dados horários) não melhoraram o modelo, visto que, para o modelo no qual foram utilizadas vazões horárias do posto fluviométrico do Turcato o coeficiente de NS sofreu uma pequena redução, de 0,91 para 0,89, quando comparado com a alternativa de controle que utiliza apenas dados diários. Isto pode ser devido ao fato de que as vazões médias diárias, neste caso, sendo resultantes da integração de vazões com intervalo de 15 minutos, contém mais informações que as séries horárias, pois estas últimas são valores obtidos a cada hora, não tendo em conta as flutuações ocorridas no intervalo;

- Para todas as alternativas de controle, as vazões atuais do próprio posto fluviométrico de Ponte Mística se mostraram como a variável de entrada mais importante, com relação à análise de sensibilidade, com a sua influência variando entre 0,447 e 0,901. Verificou-se que algumas variáveis possuem valores de influência muito baixos, indicando que, em princípio, para aquela situação específica estas variáveis não seriam tão importantes. Porém, a presença destas variáveis, muitas vezes, modifica as

relações de influência das demais, afetando o desempenho do modelo, que pode apresentar incremento significativo.

- A análise de sensibilidade permite a extração de conclusões sobre o comportamento do sistema, sendo estas coerentes com o conhecimento hidrológico e com os resultados obtidos, e capazes de complementar as análises tradicionais, acrescentando maior profundidade a estas, com a interpretação, inclusive, do funcionamento do sistema, tendo em conta as distâncias das bacias contribuintes e as áreas de drenagem.

- As séries de vazões das contribuições de montante revelaram-se sempre mais influentes do que as séries de precipitações diárias sobre toda a bacia, inclusive para bacias de montante muito pequenas, como a do Turcato, revelando a importância que podem ter as bacias embutidas para as previsões. Portanto, as contribuições de bacias muito pequenas podem ainda ser melhores do que a sua proporção, em relação à bacia total (no exutório) sugere. Isto ocorre porque as saídas da sub-bacia (ex., bacia experimental) são o resultado da integração dos diversos processos hidrológicos que ocorrem no interior desta, sendo estas transformações, que ocorrem nos volumes originais das chuvas, análogas às que ocorrem no restante da bacia. Isto será tanto mais verdadeiro quanto mais a sub-bacia for representativa da bacia maior, em suas características físicas, responsáveis pelas transformações.

- A técnica de análise de sensibilidade revelou-se também com potencial para auxiliar na identificação das defasagens temporais.

- Quanto à variação da área controlada, os resultados mostram que, conforme aumenta essa área, a eficiência do modelo tende a melhorar. Os melhores resultados foram encontrados nas alternativas 2 (Santo Ângelo) e 7 (Santo Ângelo e Colônia Mousquer), com NS de 0,97;

6.2. Recomendações e sugestões

Este trabalho nos permitiu sugerir as seguintes recomendações para futuros trabalhos:

- Realizar a previsão de vazão proposta neste estudo para um objetivo diferente, como por exemplo, em vez de vazões médias, utilizar os dados de vazão das 7 hs para prever a vazão às 17 hs;

- Utilizar o método proposto por Maier e Dandy (1997) para estudar as componentes antecedentes. No trabalho destes autores, são propostos, inicialmente, modelos univariados, a partir dos quais é feita a análise das componentes antecedentes válidas, para cada série de entrada, antes do treinamento do modelo completo, com todas as variáveis explicativas;
- Utilizar uma quantidade maior de bacias embutidas para a previsão de vazão;
- Realizar este estudo para um período diferente, após a mudança do uso do solo na bacia (1994).

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALFIERI, L.; SALAMON, P.; PAPPENBERGER, F.; WETTERHALL, F. Operational Early Warning Systems for Water-Related Hazards in Europe. *Environmental Science & policy*, v.21, p.35-49. 2012.

ANDREOLLI, I. Previsão de Vazão em Tempo Real no Rio Uruguai com Base na Previsão Meteorológica. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2003.

ANEEL. Contrato de Concessão N° 006/2006 – MME – UHE São José. http://www.aneel.gov.br/aplicacoes/Contrato/Documentos_Aplicacao/CG06006SaoJose.pdf. 2012.

BATISTA, A. L. F. Modelos de Séries Temporais e Redes Neurais Artificiais na Previsão de Vazão. Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia de Sistemas da UFLA, Lavras/MG, 79p. 2009.

BENEDITO, C. S.; COLLISCHONN, W.; TUCCI, C. E. M.; CLARKE, R. T.; CORBO, M. D. Previsão Hidroclimática de Vazão de Curto Prazo na Bacia do Rio São Francisco. *Revista Brasileira de Recursos Hídricos*, v.12, n.3, p.31-41. 2007.

BOWDEN, G. J.; DANDY, G. C.; MAYER, H. R. Input Determination for Neural Network Models in Water resources Applications: Part 1 – Background and Methodology. *Journal of Hydrology*, v.301, p.75-92. 2005.

BRAVO, J. M.; UVO, C. B.; PEDROLLO, O. C.; COLLISCHONN, W.; PAZ, A. R. Previsões de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais. *Revista Brasileira de Recursos Hídricos*, v.13, n.2, p.77-88. 2008a.

BRAVO, J. M.; COLLISCHONN, W.; TUCCI, C. E. M.; PILAR, J. V.; SILVA, B. C. Avaliação dos Benefícios de Previsão de Vazão na Operação de Reservatórios. *Revista Brasileira de Recursos Hídricos*, v.13, n.1, p.197-213. 2008b.

BRUN, G. W.; TUCCI, C. E. M. Previsão em Tempo Real do Volume Afluente ao Reservatório de Ernestina. *Revista Brasileira de Recursos Hídricos*, Porto Alegre, v.6, n.2, p.73-80. 2001.

CASTANHARO, G.; MINE, M. R. M. Operação de reservatórios baseada em previsão de afluência de curto prazo em tempo real. In: XIV Simpósio Brasileiro de

Recursos Hídricos e V Simpósio de Hidráulica dos países de língua oficial portuguesa, Aracaju. Livro de resumos. Porto Alegre : ABRH. v.1. p.284-284. 2001.

CASTRO, N. M.; CHEVALLIER, P.; AUZET, A. V.; LEPRUN, J. C. Land Use Change Effects on Runoff and Erosion from Plot to Catchment Scale on the Basaltic Plateau of Southern Brazil. *Hydrological Processes*, v.13, p.1621-1628. 1999.

CASTRO, N. M.; CHEVALLIER, P.; GOLDENFUM, J. Projeto Potiribu, Atualização 1989-1998 – Dados Básicos de Fluviometria e Pluviometria (com anexos). Instituto de Pesquisas Hidráulicas da UFRGS, *Revista de Recursos Hídricos*, v.35. 2000.

CASTRO, N. M.; PINHEIRO, A.; FERNANDES, C.; PAIVA, E.; MERTEN, G.; MINELLA, J.; PAIVA, J.; GOLDENFUM, J.; SILVA, M.; GASTALDINI, M.; BRAGA, S. Rede de Pesquisa em Bacias Representativas e Experimentais no Bioma da Mata Atlântica, na Região Sul do Brasil: Relatório Final das Atividades Desenvolvidas de Março de 2007 à Maio de 2010. Universidade Federal do Rio Grande do Sul, 316p. 2010.

CERILUZ. Geração de Energia. <http://www.ceriluz.com.br/site/geracao-energia.php>. 2012.

CHEVALLIER, P.; CASTRO, N. M. R. As Precipitações na Região de Cruz Alta e Ijuí (RS-Brasil). *Simpósio Brasileiro de Recursos Hídricos 10*, Rio de Janeiro. ABRH/APRH, p.183-192. 1991.

CHOW, V. T. *Handbook of applied hydrology: a compendium of water resources technology*. New York: MacGraw-Hill. 1468p. 1964.

CLARKE, R. T. *Mathematical Models in Hydrology*. FAO Irrigation and Drainage Paper, n.19, 282p. 1973.

COULIBALY, P; ANCTIL, F; BOBÉE, B. Daily Reservoir Inflow Forecasting Using Artificial Neural Networks With Stopped training Approach. *Journal of Hydrology*, v.230, p.244-257. 2000.

CRAWFORD, N. H.; LINDSLEY, R. K. *Digital Simulation in hydrology: Stanford Watershed model IV*. Department of Civil Engineering, Stanford University, Tech. Report, n° 39. 1966.

CRUZ, M. F. M.; RODRIGUES, L. D.; VERSIANI, B. R. Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais. *Revista Brasileira de Recursos Hídricos*. v.5, p.121-132. 2010.

DAWSON, C. W.; WILBY, R. L. Hydrological Modelling Using Artificial Neural Network. *Progress in Physical Geography*, v.25, p.80-108. 2001.

DE BOER, D. Constraints on Spatial Transference of Rainfall-Runoff Relationships in Semiarid Basins Drained by Ephemeral Streams. *Hydrological Sciences Bulletin*, v.37, n.5, p.491-504. 1992.

DOOGE, J. C. I. Linear Theory of Hydrologic Systems. Technical Bulletin: United States Department of Agriculture, n.1468, 326p. 1973.

DORNELLES, F. Previsão Contínua de Níveis Fluviais com Redes Neurais Utilizando Previsão de Precipitação. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2007.

FADIGA, F. M. J.; LOPES, J. E.; MARTINS, J. R.; BARROS, M. T.; SANTOS, R. C. Modelos de Previsão de Vazões para a Bacia Incremental à UHE Itaipu. *Revista Brasileira de Recursos Hídricos*, v.13, n.2, p.65-75. 2008.

FEPAM. Relatório Anual sobre a Situação dos Recursos Hídricos no Estado do Rio Grande do Sul e Inventário Hidrelétrico da Sub-Bacia 75, http://www.fepam.rs.gov.br/qualidade/bacia_uru_ijui.asp. 2012.

FIGUEIREDO, K.; VELLASCO, M.; BARBOSA, C. R. H.; PACHECO, M. A. C.; CRUZ, A. V.; CONTRERAS, R. J.; SOUZA, R. C.; BARROS, M.; MARQUES, V. S. Modelo de Previsão de Vazão com Informação de Precipitação. *Revista Brasileira de Recursos Hídricos*, v.12, n.3, p.69-82. 2007.

FRANCHINI, M.; BERNINI, A.; BARBETTA, S.; MORAMARCO, T. Forecasting Discharges at the Downstream End of a River Reach Through Two Simple Muskingum Based Procedures. *Journal of Hydrology*, v.339, p.335-352. 2011.

GEORGAKAKOS, K. P.; KRZYSZTOFOWICZ, R. Probabilistic and Ensemble Forecasting. *Journal of Hydrology*, v.249, p.1. 2001.

GIRARDI, R. V.; CASTRO, N. M. R.; PINHEIRO, A.; GOLDENFUM, J. A.; SILVEIRA, A. L. L. Avaliação do Efeito de Escala em Características de Precipitação e Vazão em Sub-Bacias da Bacia do Potiribu. *Revista Brasileira de Recursos Hídricos*, v.16, p.49-64. 2011.

GOMES, L. F. C.; MONTENEGRO, S. M. G. L.; VALENCA, M. J. S. Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco. *Revista Brasileira de Recursos Hídricos*, v.15, p.5-15. 2010.

GOSWAMI, M.; O'CONNOR, K. M. Real-Time Flow Forecasting in the Absence of Quantitative Precipitation Forecasts: A Multi-Model Approach. *Journal of Hydrology*, v.334, p.125-140. 2007.

GUERRA, A. T. *Dicionário Geológico-Geomorfológico*. Rio de Janeiro: IBGE, 411p. 1966.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. *Neural Network Design*. PWS Publishing. 722p. 1996.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. New York: Macmillan College Publishing Company, 696p. 1994.

HEBB, D. O. *The Organization of Behavior: A Neuropsychological Theory*. New York: John Wiley & Sons, 334p. 1949.

HECHT-NIELSEN, R. *Neurocomputing*. Addison-Wesley Publishing Co., New York, 433p. 1990.

IBGE. *Folha SH.22 Porto Alegre e Parte das Folhas SH.21 e SI.22 Lagoa Mirim*. Rio de Janeiro: IBGE (levantamento de recursos naturais, v.33). 1986.

KASABOV, N. K. *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*. The MIT press, 550p. 1996.

KERH, T.; LEE, C. S. Neural Network Forecasting of Flood Discharge at an Unmeasured Station Using River Upstream Information. *Advances in Engineering Software*. v.37, n.8, p.533-543. 2006.

KOUSSIS, A. D.; LAGOUVARDOS, K.; MAZI, K.; KOTRONI, V.; SITZMANN, D.; LANG, J.; ZAISS, H.; BUZZI, A.; MALGUZZI, P. Flood Forecasts for Urban Basin with Integrated Hydro-Meteorological Model. *Journal of Hydrologic Engineering*, v.8, n.1. 2003.

KUMAR, A. R. S.; SUDHEER, K. P.; JAIN, S. K.; AGARWAL, P. K. Rainfall-Runoff Modelling Using Artificial Neural Networks: Comparison of Network Types. *Hydrological Process*, n.19, p.1277-1291. 2005.

LEK, S.; BELAUD, A.; DIMOPOULOS, I.; DELACOSTE, M. Role of Some Environmental Variables in Trout Abundance Models Using Neural Networks. *Aquatic Living Resources*, v.9, p.23-29. 1996.

LETTENMAIER, D. P.; WOOD, E. F. Hydrologic Forecasting. In: MAIDMENT, D. R. *Handbook of Hydrology*. Ed. McGraw-Hill, p.26.1-26.30. 1993.

LIMA, C. H. R.; LALL, U. Climate Informed Monthly Streamflow Forecasts for the Brazilian Hydropower Network Using a Periodic Ridge Regression Model. *Journal of Hydrology*, v.380, p.438-449. 2010.

MACHADO, F. W. Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais. Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia de Recursos Hídricos e Ambiental da UFPR, Curitiba/PR, 128p. 2005.

MADSEN, H.; SKOTNER, C. Adaptive State Updating in Real-Time River Flow Forecasting – A combined Filtering and Error Forecasting Procedure. *Journal of Hydrology*, v.308, p.302-312. 2005.

MAIER, H. R.; DANDY, G. C. Determining Inputs for Neural Networks Models of Multivariate Time Series. *Microcomputers in Civil Engineering*, v.12, p.353-368. 1997.

MAIER, H. R.; DANDY, G. C. Neural Network for the Prediction and Forecast of Water Resources Variables: A Review of Modelling Issues and Applications. *Environmental Modelling and Software*, v.15, p.101-124. 2000.

MCCULLOCH, W.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, v.5, p.115-133. 1943.

MENDIONDO, E. M. Integração das Escalas Hidrológicas nas Sub-Bacias Embutidas do Rio Potiribu, RS. Dissertação (Mestrado) – Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS, 248p. 1995.

MENDIONDO, M.; TUCCI, C. E. M. Escalas Hidrológicas I: Conceitos. *Revista Brasileira de Recursos Hídricos*, Porto Alegre, v.2, n. 1, p.59-122. 1997.

MINSKY, M.; PAPERT, S. *Perceptrons: An Introduction to Computational Geometry*. MIT Press, Cambridge, MA. 258p. 1969.

NAPOLITANO, G.; SEE, L.; CALVO, B.; SAVI, F.; HEPPENSTALL, A. A Conceptual and Neural Network Model for Real-Time Flood Forecasting of the Tiber River in Rome. *Physics and Chemistry of the Earth*, v.35, p.187-194. 2010.

NIMER, E. *Climatologia do Brasil*. Instituto Brasileiro de Geografia e Estatística. 2.ed, 421p. 1989.

OLDEN, J. D.; JACKSON, D. A. Illuminating the “Black Box”: Understanding Variable Contributions in Artificial Neural Networks. *Ecological Modelling*, v.154, p.135-150. 2002.

OLDEN, J. D.; JOY, M. K.; DEATH, R. G. An Accurate Comparison of Methods for Quantifying Variable Importance in Artificial Neural Networks Using Simulate Data. *Ecological Modelling*, v.178, p.389-397. 2004.

OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M. R. Metodologia de Análise de Sensibilidade e Exclusão de Variáveis de Entrada em Simulação Hidrológica por Redes Neurais Artificiais (RNAs): Resultados Preliminares. XIX Simpósio Brasileiro de recursos Hídricos. 2011.

PAZ, A. R.; BUENO, E. O.; TUCCI, C. E. M. Análise de metodologias de previsão de vazões em tempo real. Estudo de casos: bacia do rio Doce (MG) e do rio Uruguai (RS). In: II Simpósio de Recursos Hídricos do Centro-Oeste, 2002, Campo Grande. Anais do II Simpósio de Recursos Hídricos do Centro-Oeste, v.1. 2002.

PEDROLLO, O. C.; LANNA, A. E. Previsão de Cheias em Tempo Atual em Sistemas Fluviais com Contribuições Laterais Relevantes. *Revista Brasileira de Engenharia*, v.9, n.2, p.25-51. 1991.

PEDROLLO, O. C. Previsão em Tempo Atual de Cheias com Uso de Sistema Especialista Difuso. Tese (Doutorado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2000.

PEDROLLO, O. C. SIRENE I: Sistema de Redes Neurais Progressivas. Relatório de Pesquisa. v.1. 2007.

RABUFFETTI, D.; BARBERO, S. Operational Hydro-Meteorological Warning and Real-Time Flood Forecasting: The Piemonte Region Case Study. *Hydrology and Earth System Sciences*, v.9, n.4, p.457-466. 2005.

ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, v.65, n.6. 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. v.1, p.318-362, MIT press, Cambridge. 1986.

SALAS, J. D. Analysis and Modeling of Hydrologic Time Series. In: MAIDMENT, D. R. *Handbook of Hydrology*. Ed. McGraw-Hill, p.19.1-19.72. 1993.

SALAS, J. D.; DELLEUR, J. W.; YEVJEVICH, V.; LANE, L. J. *Applied Modelling of Hydrologic Time Series*. Water Resources Publications, 498p. 1980.

SANTOS, C. N. El Niño, La Niña e a Erosividade das Chuvas no Estado do Rio Grande do Sul. Tese (Doutorado), Universidade Federal de Pelotas, 138p. 2008.

SATARRI, M. T.; YUREKLI, K.; PAL, M. Performance Evaluation of Artificial Network Approaches in forecasting reservoir inflow. *Applied Mathematical Modelling*, v.36, p.2649-2657. 2012.

SCARDI, M.; HARDING, L. W. Developing an Empirical Model of Phytoplankton Primary Production: A Neural Network Case Study. *Ecological Modelling*, v.120, p.213-223. 1999.

SECRETARIA ESTADUAL DO MEIO AMBIENTE DO RIO GRANDE DO SUL (SEMA-RS). Relatório Anual Sobre a Situação dos Recursos Hídricos no Estado do Rio Grande do Sul. Edição 2007/2008. Porto Alegre/RS. 2008.

SILVA JÚNIOR, O. B. Análise da Escala das Variáveis Hidrológicas e do Uso do Solo na Bacia do Rio Potiribu - RS. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2001.

SILVA JÚNIOR, O. B.; TUCCI, C. E. M.; CASTRO, N. M. R.; BUENO, E. O. Extrapolação Espacial na Regionalização da Vazão. *Revista Brasileira de Recursos Hídricos*, Porto Alegre, v.8, n.1, p.20-30. 2003.

SILVA, V. S. V. Estimativa de Precipitação Pontual em Diferentes Escalas para Uso em Modelo Concentrado Chuva-Vazão. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2011.

SILVEIRA, G. L. Quantificação de Vazão em Pequenas Bacias com Carência de Dados Fluviométricos. Tese (Doutorado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 1997.

SOUSA, W. S.; SOUSA, F. A. S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.14, p.173-180. 2010.

STONE, M. Cross-Validatory Choice of Assessment of Statistical Predictions. *Journal of Royal Statistical Society. Series B*, v.36, p.111-147. 1974.

TIWARI, M. K.; CHATTERJEE, C. Uncertainty Assessment and Ensemble Flood Forecasting Using Bootstrap Based Artificial Neural Network (BANNs). *Journal of Hydrology*, v.382, p.20-33. 2010.

TODINI, E. An Operational Decision Support System for Flood Risk Mapping, Forecasting and Management. *Urban Water*, p.131-143. 1999.

TUCCI, C. E. M. Hidrologia: Ciência e Aplicação. Porto Alegre: Ed. da UFRGS/ABRH: 4 ed. 943p. 2007.

TUCCI, C. E. M. Modelos Hidrológicos. Associação Brasileira de Recursos Hídricos, Editora Universitária UFRGS. Porto Alegre/RS, 669p. 1998.

TUCCI C. E. M.; CLARKE, R. T.; DIAS P. L. S.; COLLISCHONN, W. Previsão de Médio Prazo da Afluência de Reservatórios com Base na Previsão Climática. Projeto BRA/00/029. Relatório Final. Instituto de Pesquisas Hidráulicas. 2002.

TUCCI, C. E. M.; VILANUEVA, A.; BERTONI, J. C. Previsão de vazão para irrigação. VII Simpósio Brasileiro de Recursos Hídricos. São Paulo: ABRH, v.1, p.536-549. 1987.

TURAN, E. M.; YURDUSEV, A. M. River Flow Estimation from Upstream Flow Records by Artificial Intelligence Methods. Journal of Hydrology, v.369, p.71-77. 2009.

VIERO, A. C. Análise da Geologia, Geomorfologia e Solos no Processo de Erosão por Voçorocas: Bacia do Taboão, RS. Dissertação (Mestrado), Instituto de Pesquisas Hidráulicas da UFRGS, Porto Alegre/RS. 2004.

VOGL, T. P.; MANGIS, J. K.; ZIGLER, A. K.; ZINK, W. T.; ALKON, D. L. Accelerating the Convergence of the Back-Propagation Method. Biological Cybernetics. n.59, p.257-263. 1988.

VON ZUBEN, F. J. Uma Caricatura Funcional de Redes Neurais Artificiais. Learning and Nonlinear Models. Revista da Sociedade Brasileira de Redes Neurais, v.1, n.2, p.77-87. 2003.

WIDROW, B.; HOFF, M. E. Adaptive Switching Circuits. In: 1960 IRE WESCON Convention Record, New York: IRE: Part 4, p.96-104. 1960.