SENSIBILIDADE DA PREVISÃO HIDROLÓGICA EM RELAÇÃO À PREVISÃO DE PRECIPITAÇÃO: modelo baseado em rede neural para representação da estrutura de erros

Eduardo Alvim Leite; José Eduardo Gonçalves; Ângelo Breda; Lívia Souza Freire[1] *& Auder Machado Vieira Lisboa*[2]

RESUMO --- O impacto da utilização de previsões de precipitação sobre a qualidade das previsões hidrológicas é bastante variável, dependendo tanto da estrutura de erros dessas primeiras previsões, quanto do domínio de aplicação e modelo hidrológico utilizado. Múltiplas situações de impactos vinculadas à introdução desse tipo de preditor vêm sendo investigadas pelos autores, sendo comum a ocorrência de perdas de qualidade quando o horizonte de previsão aumenta ou o modelo não possui mecanismos de tratamento das incertezas sempre presentes nessas informações. O trabalho apresenta uma abordagem de análise da sensibilidade da previsão hidrológica em relação à previsão de precipitação, considerando uma disponibilidade limitada dessas informações. O método é baseado no treinamento de redes neurais artificiais, do tipo LVQ (*Learning Vector Quantization*), para a representação e simulação da estrutura de erros das previsões. Um comparativo entre essa abordagem e o tradicional método de "Monte Carlo" também foi realizado. A metodologia proposta foi aplicada na bacia do Rio Iguaçu, contemplando ambiente hidrológico sensível à ocorrência de precipitação, que conjuga problemas de gestão de reservatório hidroelétrico e controle de cheias.

ABSTRACT --- The impact of rainfall forecast over the hydrological forecasts quality is quite variable, depending on both the structure of these first forecast errors, as application domain and hydrologic model used. The advantages of forcing hydrological models with precipitation forecast have been investigated by the authors. Losses of quality are common when the forecasting lead time increases or the model don't have mechanisms for dealing with uncertainties present in this kind of information. The paper presents an approach to analyzing the sensibility of hydrological forecast concerning on the rainfall forecast, when the sample size is confined. The method is based on training LVQ artificial neural networks (Learning Vector Quantization) to represent and simulate the structure of the forecasts errors. A comparison between this approach and the traditional "Monte Carlo" method was also performed. The proposed methodology was applied in the Iguaçu river basin, covering hydrological environment sensitive to the occurrence of precipitation, combining problems of management of hydroelectric reservoir and flood control.

Palavras-chave: Previsão hidrológica, previsão de precipitação, redes neurais artificiais.

1) Pesquisadores do Instituto Tecnológico SIMEPAR, Caixa Postal 19100, CEP 81531-990, Curitiba, PR, Brasil, alvim@simepar.br, jgongalv@simepar.br, angelo@simepar.br, livia@simpear.br.

2) Engenheiro de ITAIPU Binacional Av. Tancredo Neves, 6731, CEP 85856-970, Foz do Iguaçu, PR, Brasil, auder@itaipu.gov.br.

1 – INTRODUÇÃO

Em um cenário de perturbações climáticas, expansão da demanda e pressões por competitividade empresarial, o setor elétrico brasileiro enfrenta o desafio de melhoria nos modelos hidrológicos de previsão de vazão, necessários à segurança e otimização da gestão dos reservatórios hidroelétricos, submetidos às exigências regulatórias do setor e ao uso múltiplo das águas. Ao mesmo tempo em que se tornam disponíveis dados horários de nível e precipitação oriundos de sistemas de monitoramento telemétrico, percebe-se, em muitos casos, a importância de incorporação, nos modelos hidrológicos operacionais de previsão de vazão, não só desses dados monitorados, mas também da previsão de precipitação, que pode ser gerada e processada a partir de diferentes esquemas operacionais, em múltiplos horizontes e períodos de acumulação.

Dentro desse contexto, o presente trabalho apresenta uma abordagem de análise da sensibilidade da previsão hidrológica em relação à previsão de precipitação, considerando a disponibilidade real, mas limitada, dessas informações em relação ao histórico de calibração, a partir de métodos de representação e simulação da estrutura de erros dessas previsões. Os impactos potenciais da incorporação de previsões de precipitação na modelagem hidrológica têm sido investigados pelos autores nos últimos anos. Em um primeiro trabalho (Leite *et al*., 2006), os autores investigaram os impactos da telemetria hidrológica horária e de esquemas discretos de previsão de precipitação por categoria na previsão operacional de vazões, realizada através de modelos estatísticos do tipo ARIMA e filtro de Kalman. Em um segundo trabalho (Leite e Rotunno Filho, 2006) aprofundou-se a investigação da sensibilidade dos modelos baseados em filtro de Kalman aos erros de previsão da precipitação, mantendo-se o esquema da previsão por categoria, mas gerando estruturas de erros ordenadas em relação a sua utilidade, baseadas em um conceito estatístico denominado de "informatividade". Em um terceiro trabalho (Leite *et al*., 2007), a investigação da sensibilidade da previsão hidrológica à informatividade da previsão de precipitação é expandida para modelos baseados em diferentes abordagens – regressão linear múltipla; filtro de Kalman e conceitual chuva-vazão, sendo realizadas análises comparativas intra e inter-modelos dentro dos contextos de sub-bacia de cabeceira e sub-bacia interna. Os estudos têm demonstrado a existência de situações críticas, nas quais a incorporação dessas previsões afeta negativamente a qualidade das previsões hidrológicas em relação ao caso de não utilização desse preditor (alimentação do modelo com previsão de precipitação sempre nula). O presente trabalho incorpora dados reais de previsão de precipitação, que foram gerados e processados com o intuito de aprimorar a qualidade da previsão hidrológica. Como comumente ocorre, esses dados estão disponíveis para um período de tempo limitado, o que restringe a análise estatística do impacto de

sua incorporação sobre a qualidade da previsão de vazão. Para superar essa limitação de tamanho da amostra dos dados de previsão de precipitação, o presente trabalho apresenta abordagem metodológica, baseada em Redes Neurais Artificiais, para a representação da estrutura de erro das previsões de precipitação e sua simulação em qualquer período de análise. Um comparativo entre essa abordagem e o tradicional método de "Monte Carlo" é realizado e a análise conjunta dos resultados expande nossa capacidade de reconhecimento dos potenciais impactos esperados. A metodologia proposta foi aplicada na bacia do Rio Iguaçu, sobre a área de contribuição para União da Vitória, contemplando ambiente hidrológico sensível à ocorrência de precipitação, que conjuga problemas de gestão de reservatório hidroelétrico e controle de cheias.

2 - METODOLOGIA

2.1 - Local de estudo

A região de estudo escolhida foi a bacia do rio Iguaçu, no estado do Paraná. O sistema de previsão hidrológica operacional na bacia, denominado SISPSHI, foi estruturado de forma a contemplar vinte sub-bacias ao longo do rio Iguaçu, indo desde a sua nascente nas proximidades de Curitiba até a sua foz, na afluência com o rio Paraná. No âmbito deste estudo, somente a região à montante de União da Vitória foi analisada, limitando a área de estudo a nove sub-bacias, em uma região denominada de Alto Iguaçu, conforme apresentada na Figura 1. A bacia do Alto Iguaçu possui área de drenagem total de 23.993 km^2 e vazão média da ordem de 528 m^3/s. O Instituto Tecnológico SIMEPAR realiza o monitoramento de variáveis hidro-meteorológicas na região, através de uma rede telemétrica composta por 21 estações. Dentre os registros efetuados no posto de União da Vitória, desde 1998 a maior vazão medida foi de 2.735 m^3/s. Porém, com base em uma série histórica mais extensa mantida pela Agência Nacional de Águas (ANA), observam-se vazões mais extremas, próximas a 5.000 m^3/s. Essa região fica próxima e a montante do reservatório hidroelétrico de Foz do Areia, o primeiro de uma cascata de reservatórios da bacia do Iguaçu, com responsabilidade pela regularização dos mesmos. Esse reservatório possui capacidade instalada de 1676 MW de potência, o maior da bacia. Em períodos de cheia, os seus níveis de operação afetam a severidade das enchentes em União da Vitória, cujo controle se constitui em desafio permanente para a gestão do reservatório. Nesse contexto, a previsão operacional de vazões é ferramenta essencial na otimização da gestão desse aproveitamento hidroenergético.

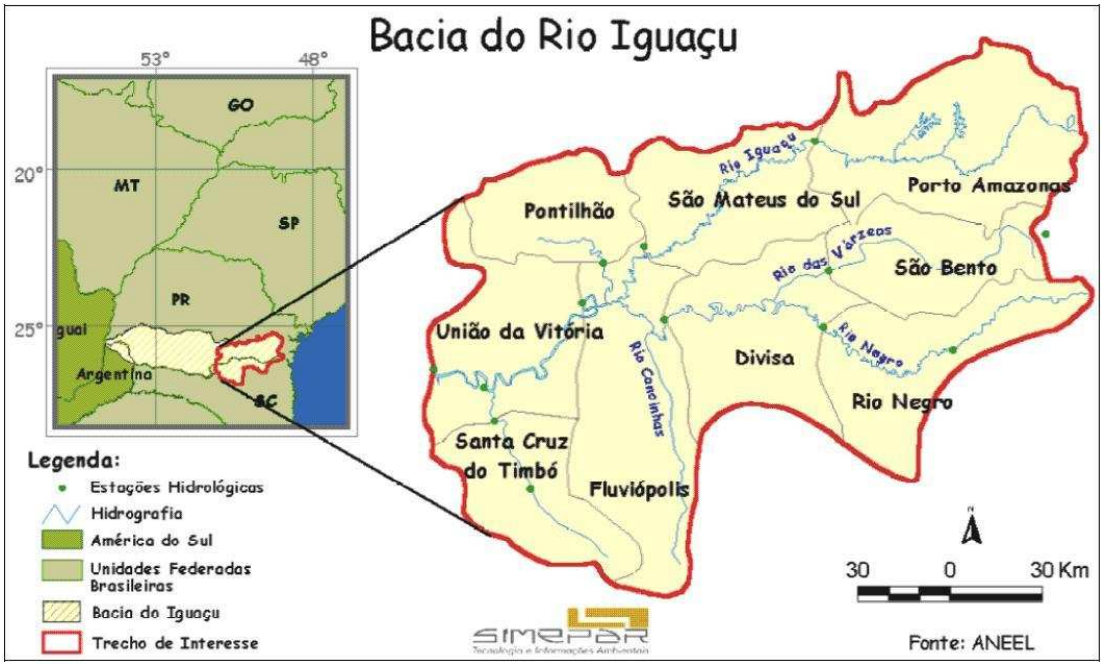

Figura 1 - Mapa das sub-bacias da área de estudo e hidrografia principal

2.2 - Modelo hidrológico utilizado

O sistema de previsão hidrológica operacional da bacia do Iguaçu, SISPSHI, incorpora um modelo conceitual, do tipo chuva-vazão. Esse modelo é baseado no algoritmo de Sacramento modificado, apresentado por Georgakakos *et al*. (1988), uma versão do modelo original desenvolvido por Burnash *et al*. (1973) para o *National Weather Service* de Sacramento. Trata-se de um modelo hidrológico espacialmente semi-distribuído de balanço de água no solo. A versão original foi idealizada para simulações em bacias de cabeceira e, posteriormente, o código foi estendido para incluir bacias internas, passando a ser considerado um modelo semi-distribuído. Nessa versão modificada, o modelo de Sacramento simula a física das variáveis hidrológicas em duas fases distintas: (1) a fase bacia e (2) a fase canal. Na fase bacia, os principais fluxos considerados abrangem a precipitação, o escoamento superficial, a percolação, o escoamento sub-superficial e a evapotranspiração. Na fase canal, a vazão gerada em cada sub-bacia é distribuída por um canal que simula o processo de propagação da onda no espaço e no tempo. Isso é feito através de um modelo cinemático proposto por Mein *et al*. (1974), o qual considera uma cascata de reservatórios conceituais não lineares. Uma descrição mais detalhada deste modelo hidrológico foi apresentada em Breda (2008).

Esse modelo foi calibrado e implementado para um intervalo de integração horária, abrange rotinas de atualização de estado, e encontra-se operacional para previsões de vazão na bacia do Iguaçu desde 2000.

2.3 - Previsões de precipitação utilizadas

Uma versão do modelo hidrológico utilizado operacionalmente foi adaptada para geração de previsões de vazão a cada 6 horas, alimentada com dados observados de vazão e precipitação, bem como com a previsão de precipitação por categorias, para quatro períodos futuros de 6 horas, totalizando o horizonte de 24 horas.

A previsão de precipitação utilizada foi realizada pela equipe de meteorologistas do SIMEPAR, de forma subjetiva, baseado na análise de múltiplos modelos meteorológicos e avaliação dos profissionais da área. A previsão consistia na definição de uma classe de intensidade de chuva acumulada em 6 horas (categoria), para cada sub-bacia, em um horizonte de até 24 horas. As previsões foram realizadas a cada 6 horas, conforme as classes apresentadas na Tabela 1.

Tabela 1 – Classes de intensidade de chuva prevista pelos meteorologistas do SIMEPAR

Classe	Intervalo (mm/6h)	Valor médio representativo (mm/6h)
Sem Chuva	0,0 – 0,2	0
Chuvisco	0,2 – 2,5	0,9
Chuva Fraca	2,5 – 10,0	5,3
Chuva Moderada	10,0 – 25,0	15,5
Chuva Forte	25,0 – 50,0	32,2
Chuva Extrema	+ de 50,0	58,4

A simulação do modelo hidrológico contemplou o cenário de previsão de chuva dos meteorologistas (*met 0*), no qual a chuva prevista foi utilizada nas primeiras 24 horas e as restantes 48 horas foram simuladas com previsão nula de chuva. Foi também simulado um cenário, denominado previsão perfeita por categoria até 24 horas, onde foi gerada uma série de previsão de chuva (*met 1*) na qual o acerto da classe de precipitação foi de 100% nas primeiras 24 horas e previsão nula de chuva nas horas restantes. Complementarmente, também foram simulados os cenários sem previsão de chuva (*prec 0*), e com a chuva ocorrida substituindo a previsão (*prec 1*), o qual representa a melhor previsão de precipitação disponível.

A análise, envolvendo os quatro cenários de previsão de chuva, foi realizada no período de um ano (03/10/2007 a 02/10/2008). Esse período curto de análise não contemplava número representativo de variações do estado hidrológico, com múltiplas recessões e cheias relevantes, restringindo a significância dos resultados. Para o período integral de dez anos (03/10/1998 a 02/10/2008), em relação ao qual se disponha de dados monitorados de vazão e precipitação, mas

não de previsão de precipitação, se desenvolveu e utilizou métodos específicos de geração de previsões de precipitação sintéticas, envolvendo as abordagens de redes neurais artificiais e método de Monte Carlo. A análise do período integral poderia revelar impactos potenciais da previsão de precipitação que estariam subtendidos, devido ao tamanho e não significância da amostra do ano mais recente.

2.4 - Geração de previsões de precipitação sintéticas

2.4.1 *Método estatístico de Monte Carlo*

O método estatístico de Monte Carlo consiste em utilizar a natureza probabilística de certo problema para gerar artificialmente, através de experimentos repetitivos, resultados estatisticamente consistentes para um dado cenário. Ele se torna particularmente útil em situações que envolvem funções complexas entre as variáveis discretas de um problema, como o caso das previsões de precipitação dos meteorologistas em função do estado meteorológico do momento (neste caso, o valor da precipitação observada). A amostragem sintética da variável definida pela função de probabilidade é realizada através da seleção de uma série de números aleatórios uniformemente distribuídos, que representam uma probabilidade diretamente ligada a um valor da variável de interesse (Benjamin e Cornell, 1970).

Para a utilização do método, necessitou-se da identificação da função de probabilidade empírica que representa a previsão dos meteorologistas num certo horizonte, dada uma classe de chuva observada. Para isso, foi gerada uma matriz que identifica as ocorrências das classes da precipitação prevista em relação às classes da precipitação observada. Após a normalização de cada coluna, ela passa a ser uma matriz de verossimilhança, representando a probabilidade de ocorrência de cada classe de previsão dada a ocorrência de uma classe de precipitação. Acumulando os valores de cada coluna, obtemos a função de probabilidade acumulada (FPA) das previsões para cada estado (classe de precipitação observada). A produção das previsões é realizada a partir da geração de um número aleatório, uniformemente distribuído, de 0 a 1, e da utilização da função inversa de probabilidade acumulada relativa à classe de precipitação observada. Essa função aplicada sobre esse número aleatório reproduz a classe de precipitação prevista para aquele instante.

Dessa forma, foram geradas dez séries sintéticas de previsão de precipitação (*sintMMC*) para os horizontes de previsão dos meteorologistas (6, 12, 18 e 24 horas), no período de 03/10/1998 até 02/10/2008, de seis em seis horas. Essas previsões sintéticas seguem a mesma distribuição de probabilidade que as previsões reais, ou seja, apresentam a mesma estrutura unitária de erro, considerando-se cada classe e período de tempo individualmente. Nesse caso são desprezadas as

interdependências espaciais e temporais que influenciam o desempenho da previsão. A análise de qualidade considerou a média de desempenho das dez séries simuladas.

2.4.2 *Rede neural do tipo LVQ (Learning Vector Quantization)*

Redes neurais são modelos computacionais que visam simular o funcionamento do cérebro humano, e que podem ser definidos como um sistema constituído por elementos de processamentos interconectados, chamados neurônios, os quais são responsáveis pela não-linearidade e memória da rede. São poderosas ferramentas na aproximação das mais diversas funções, uma vez que, para sua utilização, não se faz necessário o conhecimento prévio das relações matemáticas entre as variáveis do problema (Valença, 2005).

A rede do tipo LVQ (*Learning Vector Quantization*) pertence ao grupo das redes conhecidas por redes de Kohonen, e é formada por algoritmos estatísticos aplicáveis ao reconhecimento de padrões, que por sua vez são definidos por classes e representados por vetores chamados *codebooks* (Kohonen, 1995). Os *codebooks* que irão representar cada classe do problema são os neurônios da rede, e o treinamento é supervisionado, fornecendo exemplos de vetores com sua respectiva classe como entrada do modelo. A aprendizagem da rede é feita de maneira competitiva, ou seja, ao se apresentar uma entrada à rede, os neurônios competem entre si através da distância euclidiana em relação ao vetor de entrada, e o vencedor, bem como seus vizinhos topológicos, tem seus pesos ajustados para melhor representar as características do histórico (Montgomery e Ludwig Jr., 2007).

Para a geração de previsão de precipitação sintética através da rede LVQ, foi definido um conjunto de preditores que influenciam na classe de precipitação prevista para cada um dos quatro horizontes (6, 12, 18 e 24 horas), que inclui a chuva prevista e observada anteriormente, além da chuva observada no período de previsão. O treinamento da rede foi realizado com o período em que há previsão dos meteorologistas, sendo gerado um conjunto de duzentos preditores (padrões) para cada classe de chuva prevista, em cada horizonte de previsão. A partir dos preditores do período de geração sintética, foi encontrado a cada 6 horas o padrão que os representa, utilizando a menor distância euclidiana, e então a classe da previsão de precipitação para aquele momento foi definida.

No período em que existe previsão dos meteorologistas, foi realizada a previsão a partir da rede e os resultados foram comparados com as previsões reais, formando uma matriz de erro. Essa matriz foi utilizada para obter funções de probabilidade acumulada, que representam as probabilidades, dada uma previsão sintética, de a previsão real ser igual a ela ou pertencer à outra classe. A partir do sorteio de um número aleatório uniforme entre 0 e 1, que representa uma probabilidade, a previsão feita pela rede pode se manter a mesma ou ser alterada para uma outra classe. Assim, foram obtidas dez séries de previsões sintéticas distintas (*sintLVQ*) a cada seis horas

no período de 03/10/1998 até 02/10/2008. De forma similar ao método de Monte Carlo, a análise de qualidade considerou a média de desempenho das dez séries simuladas.

2.5 - Medidas de qualidade utilizadas

Para medir a acurácia de cada previsão hidrológica ($Q_{prev,i}$) em relação à vazão observada ($Q_{obs,i}$), foi utilizada uma medida clássica, o erro médio quadrático (*EMQ*), conforme apresentado na equação (1). Essa medida penaliza os erros maiores em relação aos menores, sendo particularmente sensível aos grandes desvios.

$$EMQ = \frac{\sum_{i=1}^{N} (Q_{prev,i} - Q_{obs,i})^2}{N} \quad (1)$$

De acordo com sugestões de Katz e Murphy (1997), também foi avaliado um índice de melhoria (*SS – Skill Score*) da acurácia da previsão em relação a uma referência, calculado conforme a equação (2). Esse índice expressa, em porcentagem, a melhoria do erro médio quadrático da previsão (*EMQ*) em relação ao erro médio quadrático de referência (EMQ_{ref}), que nesse caso foi considerada como sendo a previsão de vazão feita sem previsão de chuva.

$$SSEMQ = (1 - EMQ / EMQ_{ref}) * 100 \quad (2)$$

3 - RESULTADOS

3.1 – Análise no período de um ano com dados reais de previsão de precipitação

A Figura 2 apresenta os resultados do *EMQ* obtidos para cada tipo de previsão na sub-bacia de União da Vitória, com base no período de um ano, de 03/10/2007 a 02/10/2008, que contempla dados reais de previsão de precipitação. A previsão hidrológica utilizando a precipitação observada como previsão (*prec1*) apresenta a melhor acurácia (EMQ menor) em todos os horizontes de previsão, demonstrando melhoria significativa em relação à previsão de precipitação nula (*prec0*). Isto reflete a importância relativa desse preditor na produção de previsões hidrológicas nessa bacia. A utilização da previsão de precipitação dos meteorologistas (*met0*) reduziu significativamente os erros em relação à utilização de previsão de precipitação nula, principalmente em horizontes maiores que 20 horas. Se a previsão de precipitação dos meteorologistas fosse sempre correta (*met1*), o erro seria próximo ao obtido na simulação com precipitação observada (*prec1*) nos primeiros horizontes de previsão, ficando significativamente maior somente a partir de 36 horas. O

esquema de previsões por categoria, para o horizonte de 24 horas, mostrou-se adequado e suficiente para previsões até esse horizonte de 36 horas.

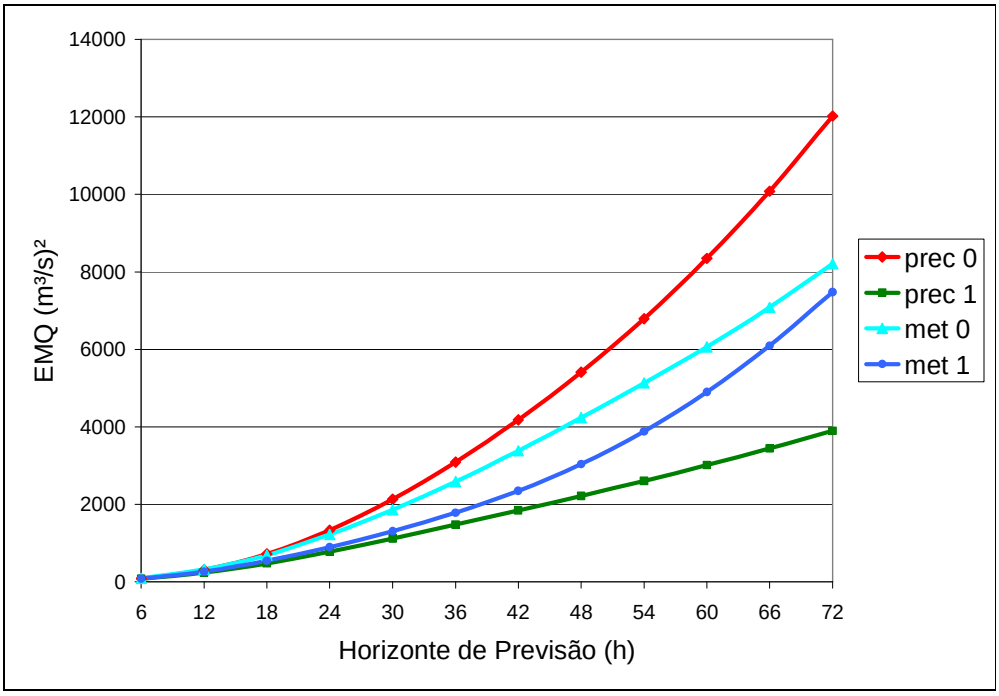

Figura 2 - EMQ da vazão prevista no período de um ano

As Figuras 3, 4 e 5 apresentam o índice de melhoria (ou perda) do *EMQ*, por classe de vazão observada, das previsões hidrológicas associadas aos diversos cenários de previsão de precipitação em relação aquele que considera as previsões sempre nulas (*prec0*). Essa desagregação do índice de melhoria foi realizada visando examinar o impacto das previsões de precipitação em situações de maiores vazões, considerando a relevância do problema de controle de cheias na região de estudo.

Conforme se pode observar nas Figuras abaixo, apenas a previsão *met0* (Fig. 3) apresentou perdas em baixas vazões e em baixos horizontes, enquanto que *met1* (Fig. 4) apresentou apenas ganhos, chegando a 80% em altas vazões. As previsões com precipitação perfeita (*prec1*, Fig. 5) apresentaram os maiores ganhos, chegando a mais de 40% na maior parte dos horizontes e classes de vazão, atingindo de 80 a 100 %, em vazões próximas a 1250 m³/s e horizontes acima de 64 horas.

Com o objetivo de avaliar os resultados das previsões de precipitação sintéticas, foram analisados os seus impactos na acurácia das previsões hidrológicas nesse período de um ano, podendo-se assim comparar os seus resultados com os obtidos no cenário realizado com as previsões reais dos meteorologistas.

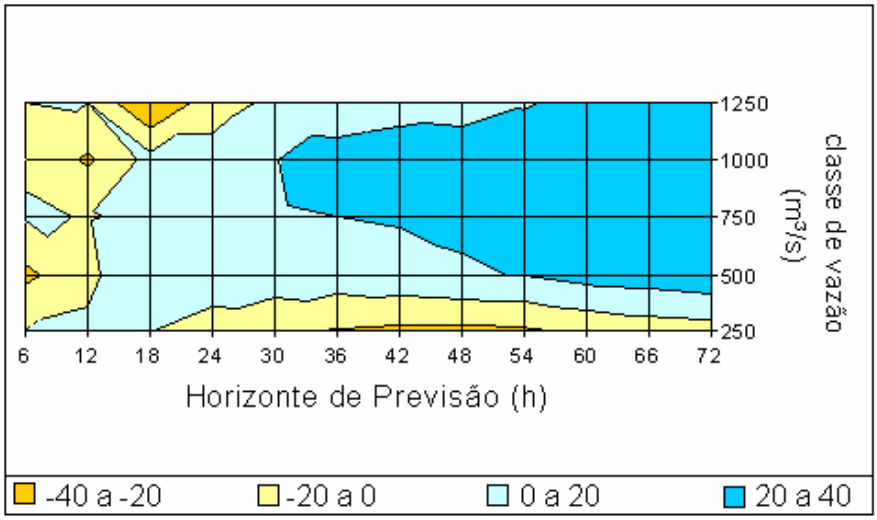

Figura 3 - Índices de melhoria de acurácia (%) da previsão *met0* em relação à *prec0* (1 ano)

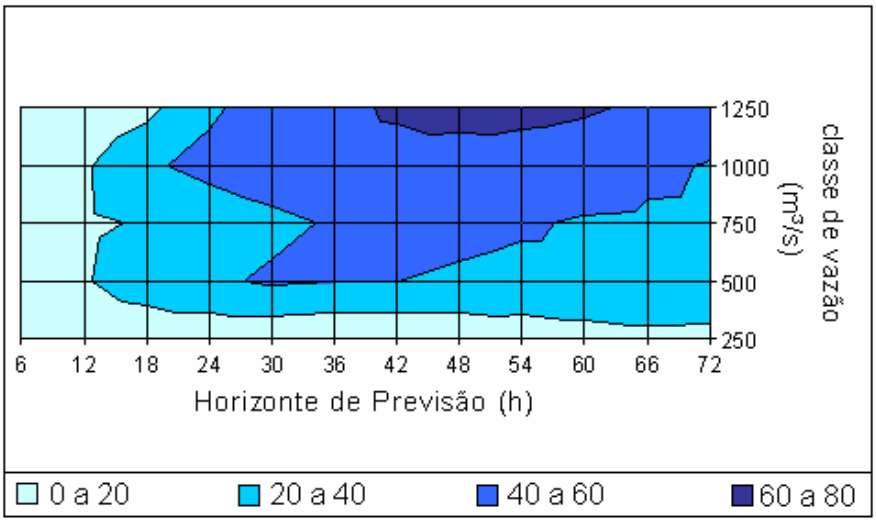

Figura 4 - Índices de melhoria de acurácia (%) da previsão *met1* em relação à *prec0* (1 ano)

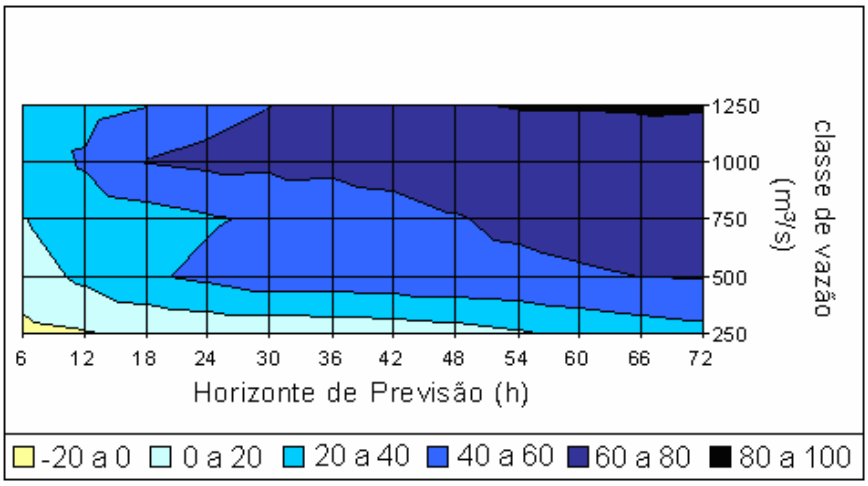

Figura 5 - Índices de melhoria de acurácia (%) da previsão *prec1* em relação à *prec0* (1 ano)

3.1.1 Previsões sintéticas geradas pelo método de Monte Carlo

A Figura 6 mostra os resultados obtidos, para o período de um ano, considerando a previsão real de precipitação dos meteorologistas (*met0*) e a média das dez simulações de previsão sintética realizadas pelo método de Monte Carlo, do índice de melhoria (ou perda) do EMQ por classe de vazão observada em relação à *prec0*. As previsões sintéticas, em média, apresentaram ganhos onde havia perdas nas previsões reais, em baixas vazões e em pequenos horizontes de previsão, porém apresentaram ganhos menores que os reais em altas vazões e horizontes de previsão de mais de 30h.

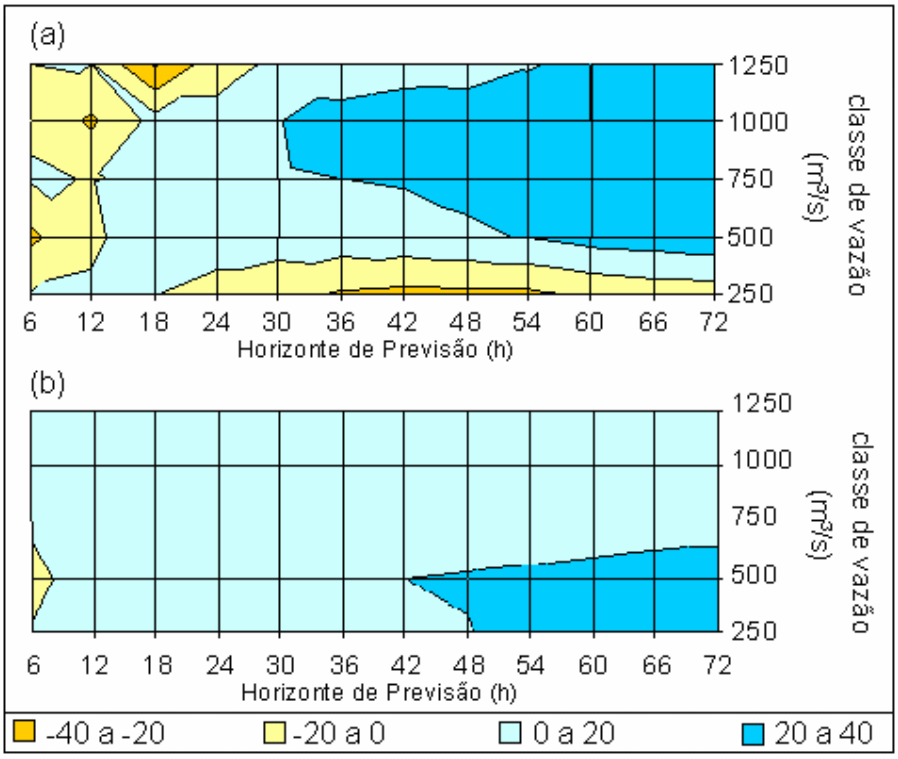

Figura 6 – Índice de melhoria da acurácia (%) em relação à *prec0* (a) do cenário da previsão real dos meteorologistas (*met0*) e (b) da média das previsões sintéticas (*sintMMC*) geradas por Monte Carlo

3.1.2 Previsões sintéticas geradas por rede neural do tipo LVQ

A comparação dos índices de melhoria das previsões sintéticas realizadas com rede neural (*sintLVQ*) em relação às previsões sempre nulas (*prec0*), para o período de um ano, mostrou comportamento semelhante com esse mesmo índice associado à previsão real dos meteorologistas (*met0*), conforme pode ser observado na Figura 7. As perdas e ganhos observados são de mesma ordem de grandeza e ocorrem nas mesmas classes de vazão, em praticamente todos os horizontes de previsão. Essa capacidade da rede neural em reproduzir os impactos da previsão de precipitação na

qualidade da previsão hidrológica estimula o seu uso em um período alternativo de análise, que contemple maior variabilidade dos estados hidrológicos. Isto foi realizado considerando o período integral de dez anos, que contempla a totalidade dos dados horários monitorados disponíveis no SIMEPAR.

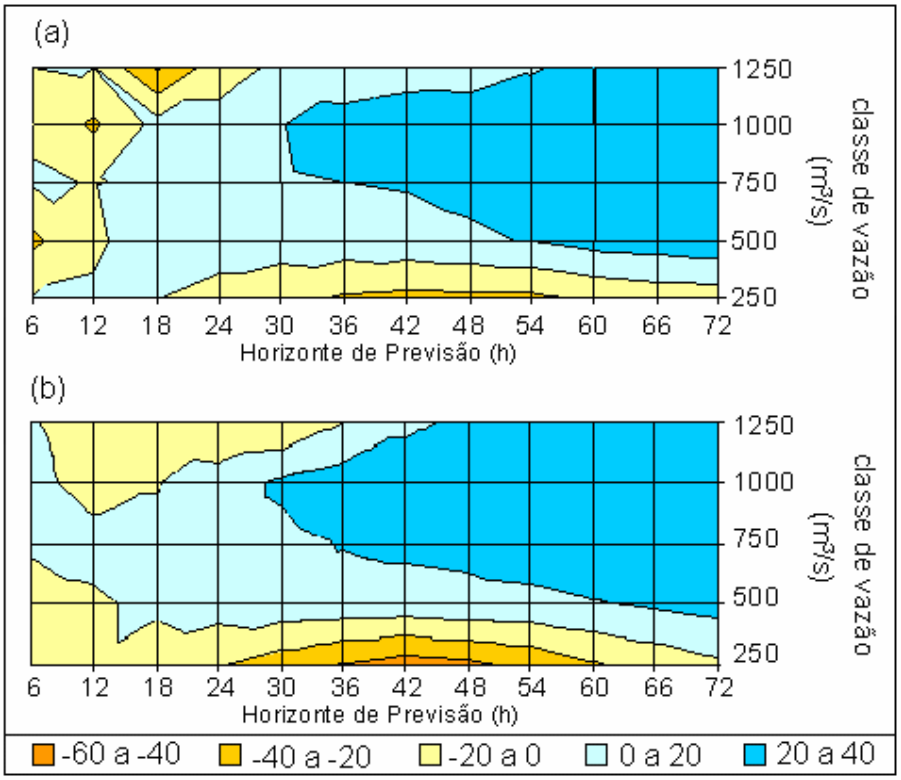

Figura 7 – Índice de melhoria da acurácia (%) em relação à *prec0* (a) do cenário da previsão real dos meteorologistas (*met0*) e (b) da média das previsões sintéticas (*sintLVQ*) geradas por LVQ

3.2 – Análise no período integral de dez anos, com dados sintéticos de previsão de precipitação

As Figuras 8 e 9 apresentam os índices de melhoria da acurácia das previsões hidrológicas correspondentes aos cenários de previsão de precipitação perfeita por categoria até 24 h (*met1*) e de previsão sempre perfeita (*prec1*), em relação ao cenário de previsão de precipitação sempre nula (*prec0*). Os índices, expressos por classe de vazão observada, foram calculados considerando-se o período integral de dez anos de dados (03/10/1998 a 02/10/2008).

O cenário de previsão perfeita por categoria *met1* (Fig. 8) apresentou pequenas perdas em horizontes de até 12 horas em classes de vazão de 1000 a 1750 m³/s, porém contemplou ganhos de até 60 % em horizontes e classes de vazão intermediárias. Nas outras situações, apresentou ganhos consideráveis, que vão de 0 a 40 %.

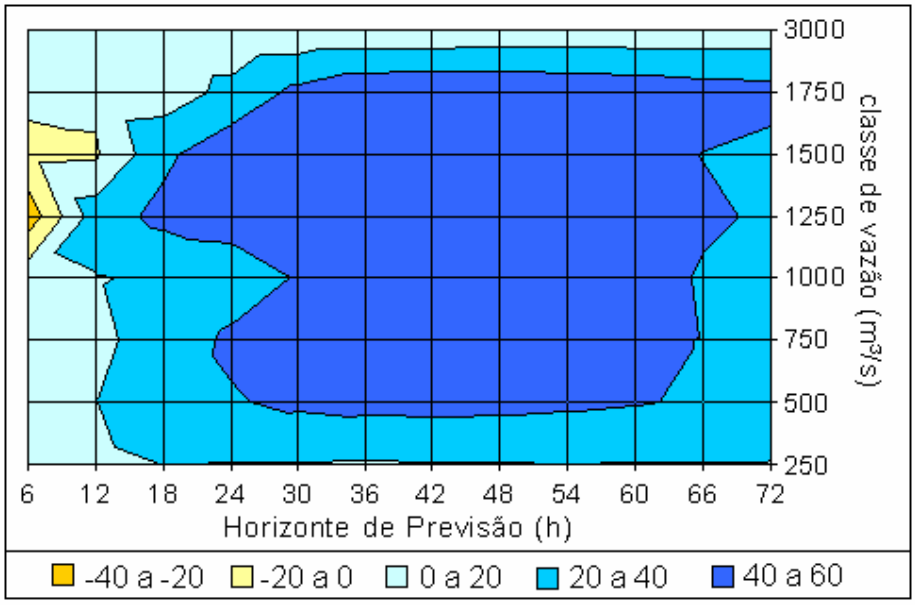

Figura 8 - Índices de melhoria de acurácia (%) da previsão *met1* em relação à *prec0* (10 anos)

O cenário de previsão perfeita *prec1* (Fig. 9) apresentou pequenas perdas de acurácia para a vazão em torno de 1250 m³/s, em horizonte muito curto (6 horas). Os ganhos aumentaram gradativamente com o aumento do horizonte de previsão, chegando a ser entre 80 e 100 %, para vazões entre 1500 e 1750 m³/s, nos horizontes acima de 54 horas. Conforme se pode notar da simulação desses dois cenários, a previsão de precipitação é critica para a melhoria da acurácia da previsão hidrológica nessa bacia, com impactos potencialmente maiores em classes de vazão mais elevadas.

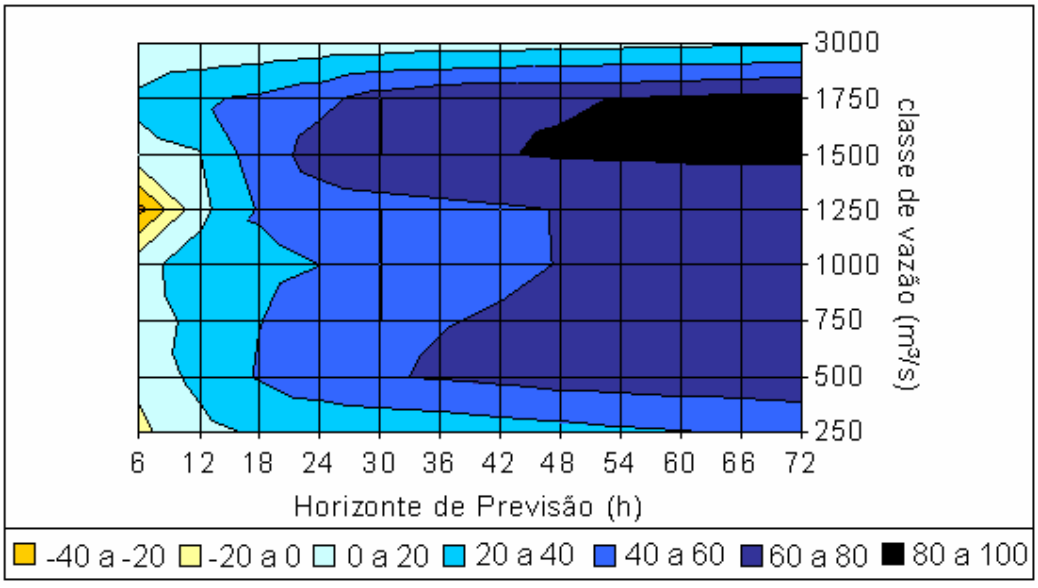

Figura 9 - Índices de melhoria de acurácia (%) da previsão *prec1* em relação à *prec0* (10 anos)

Nesse período de dez anos, as melhorias na acurácia das vazões previstas com a previsão de precipitação sintética, representando os meteorologistas, variaram de acordo com o método utilizado, indicando situações de perdas e ganhos inesperados.

3.2.1 Previsões sintéticas geradas pelo método de Monte Carlo

A Figura 10 mostra o erro médio quadrático correspondente aos quatro cenários de previsão de precipitação utilizados na previsão hidrológica para horizontes de até 72 horas, considerando o período integral de dez anos de dados. Os erros associados às previsões sintéticas de precipitação pelo método de Monte Carlo (*sintMMC*) foram significativamente menores que o gerado pelo cenário de previsão de precipitação sempre nula (*prec0*), se aproximando muito, em até 12 horas, do erro causado por *met1* e *prec1* (cenários perfeitos), e se distanciando com o aumento do horizonte de previsão. Em horizontes maiores, o comportamento é semelhante: quanto maior o horizonte, maior o erro e maior a distância entre a média da previsão *sintMMC*, *met1* e *prec1*. Entretanto, os ganhos em relação à *prec0* persistem em todos os horizontes, guardando uma relação direta com o horizonte de previsão.

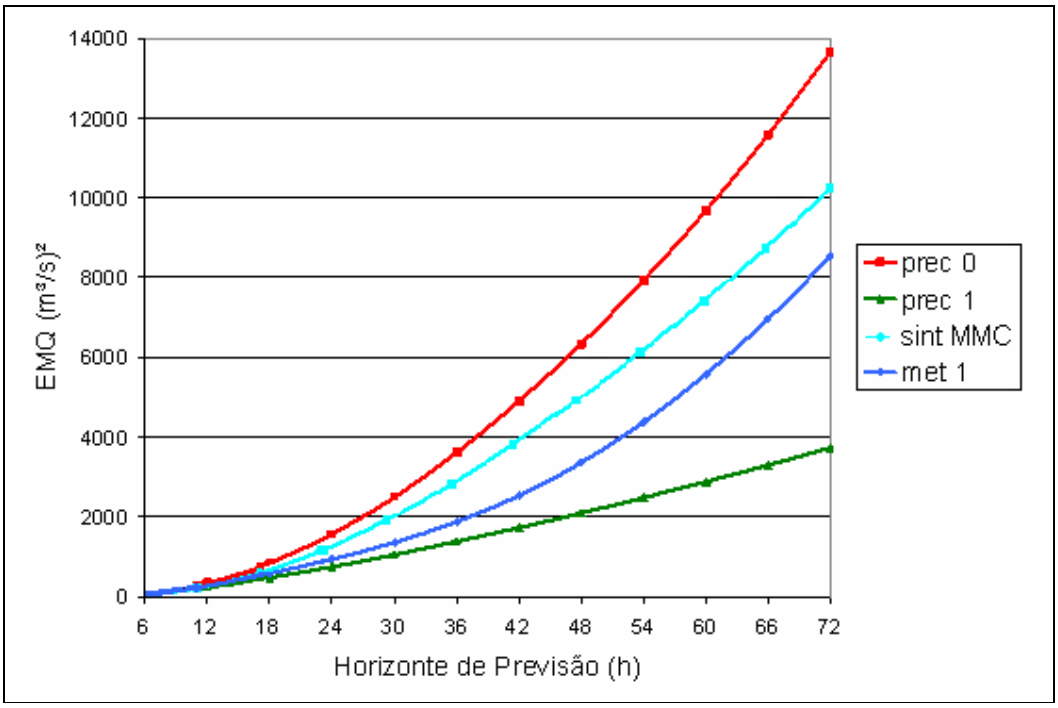

Figura 10 - EMQ previsão de vazão no período de dez anos com previsão sintética gerada por Monte Carlo

A Figura 11 permite a análise da melhoria da acurácia da média das previsões *sintMMC* em relação à *prec0*, por classes de vazão observada. Conforme apresentado, observa-se na análise de 10

anos, que a previsão sintética de precipitação correspondente aos meteorologistas, incorpora ganhos na acurácia da vazão, que ficam entre 20 e 40%, tanto em classes de vazão de 1500 a 1750 m³/s, quanto entre 250 a 750 m³/s. Nas demais situações, os ganhos chegam até 20% e não foram observadas situações de perda de acurácia.

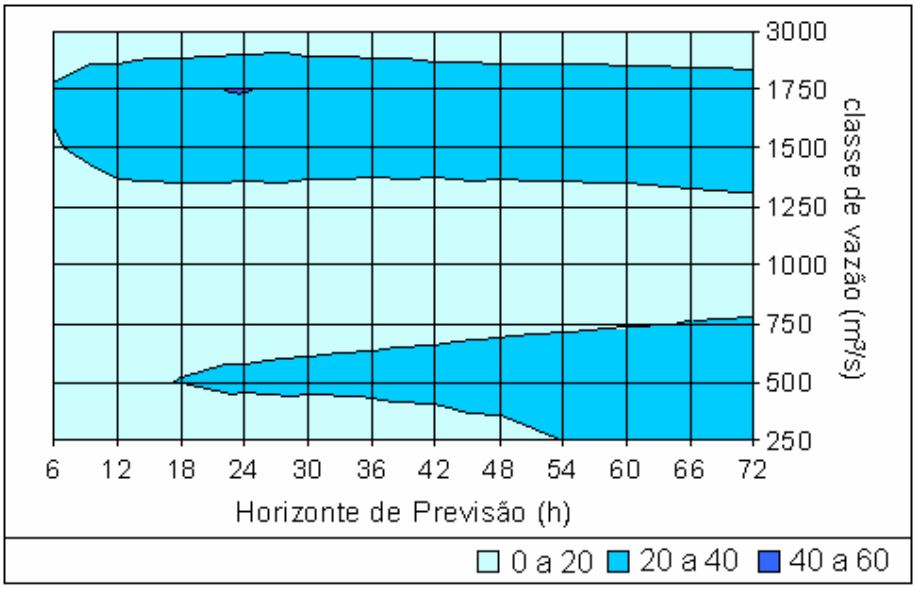

Figura 11 - Média dos índices de melhoria de acurácia (%) das previsões sintéticas geradas por Monte Carlo (*sintMMC*) em relação à *prec0* (10 anos)

3.2.2 Previsões sintéticas geradas por rede neural do tipo LVQ

A Figura 12 mostra o comportamento do erro médio quadrático correspondente aos quatro cenários de previsão de precipitação utilizados na previsão hidrológica para horizontes de até 72 horas, considerando o período integral de dez anos de dados. A previsão gerada por *sintLVQ* apresentou, em média, erros cada vez menores em relação à previsão gerada por *prec0* com o aumento do horizonte de previsão, porém ainda maiores em relação às previsões perfeita *prec1* e *met1*.

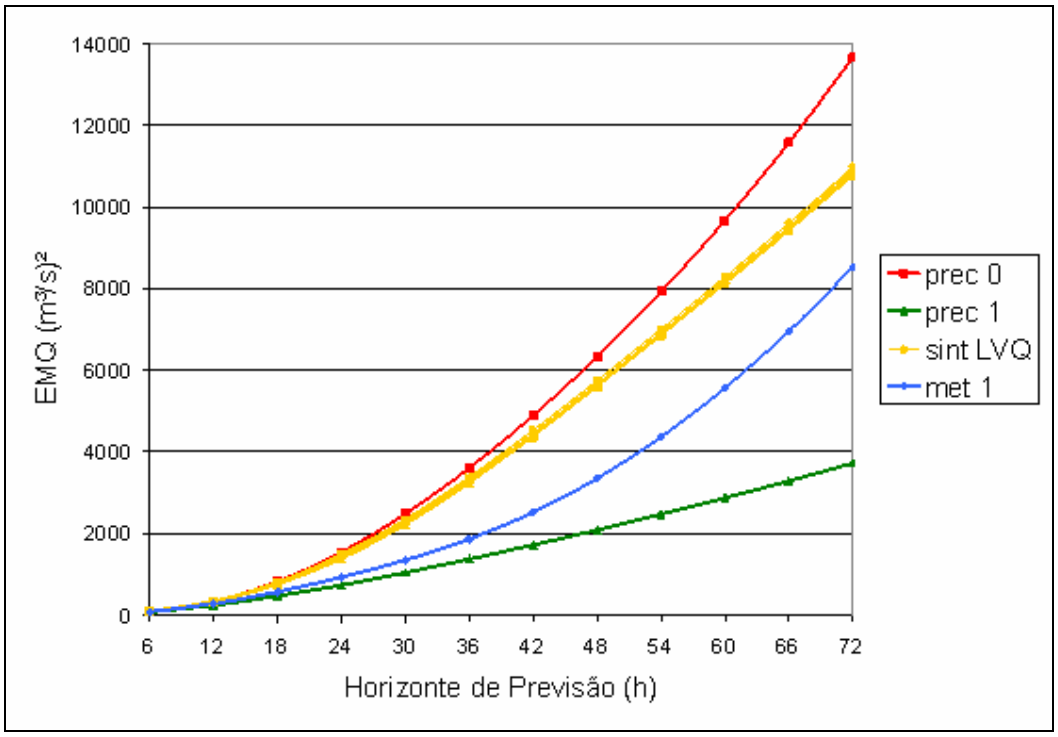

Figura 12 - EMQ da previsão de vazão no período de dez anos com previsão sintética gerada por LVQ

Em relação às classes de vazão observada no período de 10 anos, conforme apresentado na Figura 13, a média do ganho de acurácia das vazões previstas com o cenário de previsões sintéticas de precipitação geradas por rede neural *sintLVQ* em relação à *prec0* ficou entre 40 e 80%, para situações de classes de vazão acima de 1750 m³/s e horizontes de mais de 24h. Entretanto, em situações de classes de vazão abaixo de 500 m³/s, a média de *sintLVQ* apresenta perdas que podem chegar à ordem de 100% em relação à *prec0*. Também podem ser observadas perdas de acurácia que podem chegar a 20% em situações de vazão entre 500 e 750 m³/s e horizontes de até 42h. No restante das situações, as simulações revelam ganhos de acurácia de até 40%.

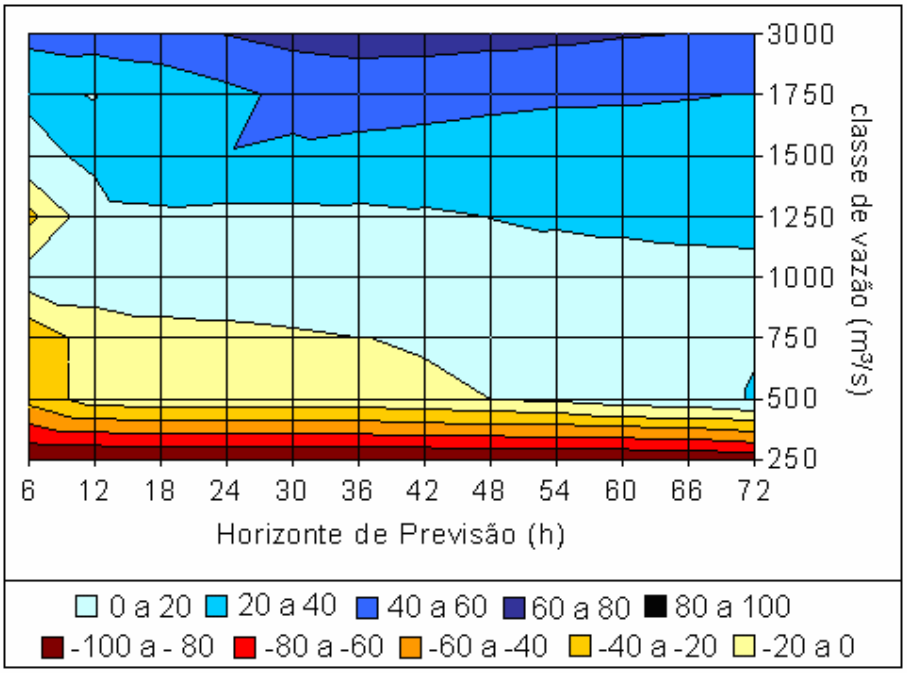

Figura 13 - Média dos índices de melhoria de acurácia (%) das previsões sintéticas geradas por LVQ (*sintLVQ*) em relação à *prec0* (10 anos)

5 – CONCLUSÕES

O trabalho realizado apresentou uma proposta metodológica para a análise de sensibilidade da previsão hidrológica que incorpora dados reais de previsão de precipitação. A abordagem enfrenta o problema do reduzido tamanho da amostra normalmente disponível de dados de previsão de precipitação. Sua reprodução para extensos períodos de tempo no passado é operacionalmente inviável, nos casos de previsão subjetiva, ou computacionalmente custosa, para o caso de previsões objetivas oriunda de modelos numéricos de tempo. A opção metodológica implementada foi a de geração de séries sintéticas de previsões de precipitação a partir de modelos baseados em redes neurais, que busquem capturar a estrutura de erros da previsão real, disponível em algum período de tempo. O modelo de rede neural utilizado, do tipo LVQ (*Learning Vector Quantization*), é especializado em reconhecimento de padrões e sua utilização se mostrou adequada para identificar situações determinantes da seleção de cada categoria de precipitação prevista pelos meteorologistas. O trabalho incluiu também o método normalmente utilizado, conhecido como Monte Carlo, mas discute sua incapacidade de reproduzir adequadamente os impactos na qualidade da previsão hidrológica.

Conforme foi possível observar do conjunto da análise realizada, considerando o caso estudado da bacia do Alto Iguaçu, a incorporação de previsões de precipitação no sistema de

previsão hidrológica, atualmente operacional na bacia, impõe perdas e ganhos de acurácia, conforme a situação definida em termos de classe de vazão observada e horizonte de previsão. A análise limitada ao período de um ano, com dados reais de previsão de precipitação, revelou perdas de acurácia no horizonte mais curto e nas classes de vazão mais baixas, e restringiu o ganho a 40% nas classes máximas observadas de até 1250 m³/s e horizontes superiores a 36 horas. O tamanho restrito da amostra de estados hidrológicos reduz a significância e confiabilidade dos resultados observados.

A expansão da análise para o período integral de 10 anos, com a utilização do método de Monte Carlo para a geração das previsões sintéticas de precipitação revelou somente ganhos de acurácia, de até 40%, em todas as situações de classe de vazão e horizonte de previsão. Esses resultados, excessivamente favoráveis à incorporação das previsões de precipitação, se revelam improváveis pela incapacidade do método de reproduzir a estrutura do erro das previsões de precipitação e seus impactos sobre a qualidade da vazão gerada, fato observado na análise de um ano, com as previsões sintéticas produzidas.

A análise para o período integral, com a geração sintética de previsões de precipitação pelo método das redes neurais do tipo LVQ, na medida em que conseguiu reproduzir os impactos na qualidade da vazão para o período de um ano, agrega confiabilidade aos resultados da análise e confirma tendências já presentes na análise com dados reais de previsão de precipitação: perdas, muitas vezes expressivas, nas classes de vazão baixas, e ganhos de acurácia consistentes, de até 80%, nas classes de vazão altas, bem como tendência de ganho crescente com o horizonte de previsão.

A incorporação das previsões de precipitação nos sistemas de previsão hidrológica é certamente um caminho para o incremento da qualidade. Porém, esse processo, para ser exitoso, exige, por um lado, estudos de reconhecimento dos impactos dessas informações no sistema, suas limitações e potencialidades, perdas e ganhos esperados e, por outro, o desenvolvimento de ferramentas capazes de ajustar as estruturas de erros e integrar as incertezas do modelo hidrológico, dos dados monitorados e da previsão de precipitação. Exemplo de instrumento com essa finalidade desenvolvido pelos autores é o pós-processamento estocástico das previsões hidrológicas baseado em filtro de Kalman, apresentado em Leite *et al.* (2008), que se mostrou eficaz no tratamento das incertezas e melhoria da acurácia das previsões hidrológicas geradas a partir de dados monitorados e previsões de precipitação.

BIBLIOGRAFIA

BENJAMIN, J. R.; CORNELL, A. (1970). *Probability, Statistics, and Decision for Civil Engineers*. McGraw-Hill Book Company, 684 p.

BREDA, A. (2008). "*Avaliação de melhorias para um sistema de previsão hidrológica horária*". Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental) – Programa de Pós Graduação em Engenharia de Recursos Hídricos e Ambiental – UFPR, Curitiba, 2008, 142 p.

BREDA, A.; LEITE, E. A.; SILVEIRA, R. B.; GONÇALVES, J. E.; FREIRE, L. S. (2008). "*Avaliação do uso de métodos subjetivo e objetivo de previsão de chuva na simulação hidrológica de curto prazo"* in Anais do II Simpósio de Recursos Hídricos do Sul-Sudeste, Rio de Janeiro, Out. 2008.

BURNASH, R.; FERRAL, R.; MCGUIRE, R. (1973). *A generalized streamflow simulation system: conceptual modeling for digital computers*. Joint Federal and State River Forecast Center Tech. Report, National Weather Service, 204 p.

GEORGAKAKOS, K.P.; RAJARAM, H.; LI, S.G. (1988). *On improved operational hydrologic forecasting of streamflows*. II HR Technical Report n. 326. Iowa Institute of Hydraulic Research, The University of Iowa.

KATZ, R.W.; MURPHY, A.H. (1997). *Economic value of weather and climate forecasts*. Cambridge,UK: Cambridge University Press, 222 p.

KOHONEN, T. (1995). *Kohonen: Self-Organizing Maps*. Springer Series in Information Science, Vol 30, 362 p.

KOHONEN, T.; KANGAS, J.; LAAKSONEN, J.; TORKKOLA, K. (1992). *"LVQ_PAK: A software package for the correct application of Learning Vector Quantization algorithms"* in Proceedings of the International Joint Conference on Neural Networks, Baltimore, MD, USA, Jun. 1992, 1, pp. 725-730.

LEITE, E. A. (2008). "*Gestão do valor da informação hidrometeorológica: o caso dos alertas de inundação para proteção de bens móveis em edificações residenciais de União da Vitória*". Tese (Doutorado em Engenharia Civil) – Programa de Engenharia Civil – PEC/UFRJ, Rio de Janeiro, 2008, 224 p.

LEITE, E. A.; DIAS, N. L.; ROTUNNO FILHO, O. C. (2006). "*The effect of precipitation forecasts and monitoring on hourly hydrological statistical prediction models"* in Proceedings of the 8th International Conference on Southern Hemisphere Meteorology and Oceanography, Foz do Iguaçu, Brasil, Abr. 2006.

LEITE, E. A.; GONÇALVES, J. E.; ROTUNNO FILHO, O. C. (2007). "*Sensibilidade da previsão hidrológica em relação à informatividade da previsão de precipitação: análise comparativa de diferentes modelos"* in Anais do XVII Simpósio Brasileiro de Recursos Hídrico, São Paulo, Nov. 2007.

LEITE, E. A.; GONÇALVES, J. E.; ROTUNNO FILHO, O. C. (2008). "*Pós-processamento estocástico da previsão hidrológica: uma alternativa para o incremento da qualidade"* in Anais do II Simpósio de Recursos Hídricos do Sul-Sudeste, Rio de Janeiro, Out. 2008.

LEITE, E. A.; ROTUNNO FILHO, O. C. (2006). "*Análise de sensibilidade da previsão hidrológica em relação à informatividade da previsão de precipitação"* in Anais do XIV Congresso Brasileiro de Meteorologia, Florianópolis, Nov. 2006.

MONTGOMERY, E.; LUDWIG JR, O. (2007*). Redes Neurais – Fundamentos e Aplicações com Programas em C*. Editora Ciência Moderna Ltda, 136 p.

MEIN, R.G.; LAURENSON, E.M.; MCMAHON, T.A. (1974). "*Simple nonlinear model for flood estimation*". Journal of Hydraulic, ASCE, 100(HY11), pp. 1057-1518.

TUCCI, C. E. M.; VILLANUEVA, A. O. N. (1999). "*Flood control measures in União da Vitória and Porto União: structural vs. non-structural measures"*. Urban Water 1, pp. 177 – 182.

VALENÇA, M. (2005). *Aplicando Redes Neurais – Um Guia Completo*. Editora Livro Rápido – Elógica, 284 p.