

PREVISÃO DE CURTO PRAZO DE NÍVEIS COM REDES NEURAIAS ARTIFICIAIS PARA A CIDADE DE ESTRELA (RS): RESULTADOS PRELIMINARES

Olavo Correa Pedrollo^{1}*

Resumo – O tempo disponível para providências, em um sistema de monitoramento de cheias fluviais, pode ser incrementado com o uso de modelos de previsão de curto prazo, cujo alcance varia desde algumas horas até alguns dias. Neste trabalho, redes neurais artificiais do tipo perceptron de múltiplas camadas são utilizadas para compor os modelos de previsão de curto prazo, uma vez que a capacidade destes de adaptação às diferentes situações resultantes da degradação do sistema de monitoramento, durante eventos, pode ser obtida pela combinação de redes neurais com as alternativas possíveis de disponibilidade de dados de entrada. Portanto, cada modelo proposto é uma combinação de redes neurais artificiais. O posto de Estrela, que faz parte do sistema de monitoramento telemétrico da bacia do rio Taquari (CPRM), foi selecionado por possuir dados suficientes para a aplicação e pela importância local da previsão. Comprovou-se que é possível, com redes neurais artificiais, efetuar previsões de boa qualidade para Estrela, com alcances de 05 e de 11 horas, utilizando-se diferentes grupos de postos telemétricos remanescentes a possíveis panes em períodos emergenciais. Os níveis previstos revelam-se instrumentos potencialmente úteis para orientar ações preventivas.

Palavras-Chave – Sistemas de alerta, degradação do sistema, bacia do rio Taquari.

SHORT-TERM RIVER LEVEL FORECASTING WITH ARTIFICIAL NEURAL NETWORKS FOR THE CITY OF ESTRELA (RS): PRELIMINARY RESULTS

Abstract – The time available for action on a river flood monitoring system can be increased by using short-term prediction models, whose range can be from a few hours to a few days. In this work, artificial neural networks of the multilayer perceptron type are used to compose the short-term prediction models, since their capacity to adapt to the different situations resulting from the degradation of the monitoring system during events can be obtained by combination of neural networks with the possible alternatives of input data availability. Therefore, each proposed model is a combination of artificial neural networks. The Estrela river gauge, which is part of the telemetric monitoring system of the Taquari River basin (CPRM) was selected because it has enough data to the application and by the local importance of the forecast. It was shown that it is possible, with artificial neural networks, to make good quality forecasts for Estrela, with ranges of 05 and 11 hours, using different groups of remaining telemetric stations to possible breakdowns in emergency periods. The expected levels turn out to be potentially useful tools to guide preventive actions.

Keywords – Flood warning, System degradation, Taquari river basin.

¹ Prof. do PPGRHSA/Instituto de Pesquisas Hidráulicas (IPH-UFRGS), e-mail olavopedrollo@gmail.com.

INTRODUÇÃO

O monitoramento das situações de cheias fluviais, associadas a medidas complementares, como planos para a evacuação emergencial, podem fazer muita diferença para a população atingida por uma enchente. A efetividade das providências depende do tempo disponível, uma vez detectada a situação. Para incrementar este tempo, podem-se utilizar modelos de previsão de curto prazo, com alcances de algumas horas ou dias, dependendo do tamanho da bacia.

Previsões confiáveis de níveis fluviais de inundação são importantes, na fase de ascensão, para orientação de ações preventivas, como a remoção de populações, e na fase de recessão, para auxiliar na orientação de decisões relativas à continuidade das ações para a redução de danos provenientes do prolongamento da inundação. Além disso, em uma situação prática, não se sabe “*a priori*”, se um evento está realmente para ocorrer. Portanto, é importante que o modelo de previsão seja capaz de identificar as alterações dos níveis fluviais antes do evento estar ocorrendo, ou seja, o modelo deve ser capaz de operar com séries contínuas, e não apenas com eventos.

A experiência com sistemas de monitoramento e previsão de curto prazo (Pedrollo *et al.*, 2014) recomenda três características a serem contempladas nos modelos de previsão: 1. Que estes possam funcionar mesmo em presença de degradação do sistema de aquisição (pois os equipamentos podem sofrer panes ou avarias, justamente durante eventos), devendo a redução do grau de confiabilidade resultante, nestes casos, ser conhecida; 2. Que as previsões sejam associadas à incerteza, na forma de intervalos de confiança ou risco de sobrepasseamento de níveis de inundação; 3. Que os modelos sejam capazes de adaptar-se, não só a possíveis alterações físicas, como também a modificações no sistema de aquisição (pelo incremento da cobertura de postos, ou pela possível modificação da localização devido a imposições técnicas, como perda de sinal).

Apresenta-se, nesta etapa, uma investigação preliminar de como poderiam ser os modelos de previsão de curto prazo, baseados em combinações de redes neurais artificiais generalizadas (Pedrollo *et al.*, 2013), contemplando diversos graus de degradação do sistema. Estes modelos são dependentes da disponibilidade de grande quantidade de registros de dados, os quais ainda precisam ser representativos do domínio das variáveis envolvidas, pois não servem para a extrapolação fora do domínio para o qual foram ajustados. Portanto, devem existir séries históricas relevantes, de todos os dados a serem utilizados, tanto das variáveis de entrada como das variáveis de saída.

Foram experimentadas as previsões na seção fluvial de Estrela (RS), a qual possui leituras suficientes para a aplicação pretendida, e cujas previsões podem ser, futuramente, associadas a mapas de inundação para as regiões próximas. Segundo a Companhia de Pesquisas de Recursos Minerais – CPRM (Pedrollo *et al.*, 2014), que opera esta rede telemétrica, os níveis de atenção, de alerta e de inundação desta seção são de 14m, 15m e 18m, respectivamente.

AS REDES NEURAI ARTIFICIAIS GENERALIZADAS

Redes neurais artificiais são modelos empíricos, com uma estrutura interna formada por funções de transferência não lineares interconectadas, cada uma das quais supostamente reproduz o funcionamento esquemático de um neurônio biológico, sendo capazes de aprendizado quando submetidos a treinamento, e de resposta a estímulos de acordo com este treinamento.

O elemento fundamental destes modelos é o neurônio artificial, o qual é uma evolução do modelo de McCulloch e Pitts (1943), formulado a partir de observações do neurônio natural. Constitui-se de uma função de soma ponderada das entradas seguida de uma função de ativação, geralmente não linear, cuja resposta depende do ajuste (chamado de treinamento) dos parâmetros de ponderação (chamados pesos sinápticos, em analogia aos neurônios biológicos).

A rede neural artificial (RNA) é geralmente estruturada em camadas sucessivas, sendo a primeira correspondente aos nós de entrada, seguida de uma ou mais camadas intermediárias e uma camada de saída. Tradicionalmente, é representada graficamente, com as ligações entre os nós, onde estão as funções de ativação, representadas por setas, sendo cada ligação correspondente a um peso sináptico (figura 1).

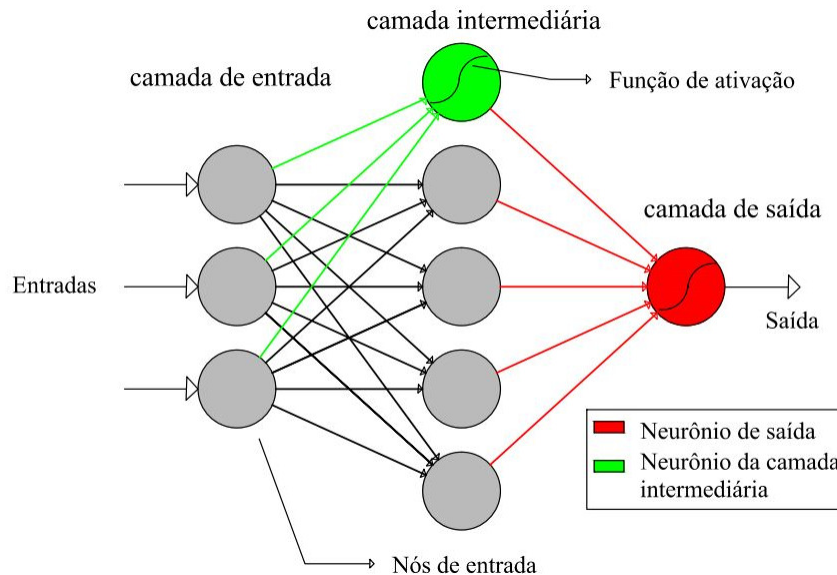


Figura 1 – Redes Neurais Artificiais. Fonte: Matos *et al.* (2014).

O número de neurônios internos depende da aplicação, podendo ser determinado pela experimentação. A função de ativação típica é a função sigmoide unipolar, com saídas no intervalo $[0,1]$, e cuja derivada (importante nos procedimentos de treinamento tipo gradiente descendente) pode ser calculada unicamente em função da saída, sendo representadas pelas equações 1 e 2.

$$a = f(n) = \frac{1}{1+e^{-n}} \quad (1)$$

$$f'(n) = a(1 - a) \quad (2)$$

onde: a = saída da função de ativação; n = entrada líquida ($n = WP + b$).

Uma vez que as entradas devem ser escalonadas, e as saídas também, pois estas são limitadas pela imagem das funções de ativação, no intervalo $[0,1]$, a rede neural com duas camadas pode ser representada pela equação 3:

$$RNA \left(\frac{x_{et} - p_e}{s_e} \right) = f_s \left(\sum_h w_s f_h \left(\sum_i w_h \left(\frac{x_{et} - p_e}{s_e} \right) + b_h \right) + b_s \right) + e_s \quad (3)$$

sendo: x_{et} = matriz com as entradas do modelo, para cada entrada e e para cada registro t ; w_h , b_h , w_s , b_s = pesos sinápticos e tendências das camadas interna (h) e de saída (s), respectivamente; f_h e f_s = funções de ativação, respectivamente, das camadas interna e de saída; e_s = erro esperado na camada de saída; p_e , s_e = parâmetros de posição e de escala, respectivamente, para o escalonamento de cada variável e de entrada.

O modelo generalizado com redes neurais artificiais resulta da combinação da RNA com as funções de escalonamento, de entrada e de saída, podendo ser representado, no caso de funções de escalonamento lineares, por:

$$\frac{(y_t - p_s)}{s_s} = \text{RNA} \left(\frac{(x_{et} - p_e)}{s_e} \right) \quad (4)$$

onde: y_t = variável de saída, para cada registro t ; p_s , s_s = parâmetros de posição e de escala, respectivamente, para o escalonamento da variável s de saída.

O método de treinamento utilizado neste trabalho é o retropropagativo (Rumelhart *et al.*, 1986), o qual consiste na minimização dos erros, com o uso da chamada regra delta (Widrow e Hoff, 1960), que foi formulada inicialmente para redes neurais de uma camada (equação 5):

$$W_{k+1} = W_k + (\tau e_k \delta_k P_k) \quad (5)$$

onde: W_k = pesos sinápticos atuais; τ = taxa de aprendizado; e_k = erros das saídas da camada; δ_k = derivada das funções ativação; e P_k = entradas na própria camada, no ciclo k , sendo cada ciclo uma aplicação do algoritmo para o conjunto de registros utilizado.

Taxas de aprendizado muito grandes resultam treinamentos não convergentes, enquanto que taxas de aprendizado muito pequenas resultam treinamentos muito lentos, podendo-se obter o valor ideal por tentativas. O uso desta regra para o treinamento das camadas internas requer o conhecimento dos erros nesta camada, os quais são calculados pela equação 6 (Rumelhart *et al.*, 1986), de acordo com a qual os erros das camadas anteriores (h) dependem somente dos erros e das propriedades das camadas posteriores (s):

$$e_h = \sum (W_s e_s \delta_s) \quad (6)$$

onde: e_h = erro na camada interna; W_s = pesos sinápticos na camada posterior; e_s = erros na camada posterior; e δ_s = derivadas da função de ativação na camada posterior.

O algoritmo tem início com pesos sinápticos gerados aleatoriamente, e o uso de aplicações sucessivas do modelo, seguidas do cálculo dos erros nas camadas, e da atualização dos pesos sinápticos, segundo as equações anteriores, podendo ser necessários milhares de ciclos, até ser obtida a precisão desejada.

Um recurso conhecido de procedimento automático para a o controle do superajustamento (quando o treinamento consegue reproduzir inclusive a aleatoriedade das amostras de treinamento) é a técnica da validação cruzada. Esta técnica utiliza, para o treinamento, além da série na qual será aplicado o algoritmo retropropagativo, 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. Verifica-se que os erros do treinamento vão sempre diminuindo (indicando desempenho melhor), enquanto os erros da série de validação, a partir de determinado ciclo, tornam a subir, indicando que a capacidade de generalização ficou comprometida, devendo-se interromper o treinamento neste ciclo (Hecht-Nielsen, 1990). Não se deve confundir a amostragem de validação, utilizada neste procedimento, com a amostragem de verificação final da capacidade de generalização, que não deve ter participado de nenhum procedimento anterior.

Tanto a avaliação do treinamento quanto a verificação da capacidade de generalização devem ser efetuadas com o uso de estatísticas dos erros do modelo. Estatísticas válidas são os erros característicos, como o erro absoluto mediano (Eamd), o quantil 0,95 (Ea95) do erro absoluto, e índices de desempenho, como o erro absoluto médio (Eam) e o coeficiente de Nash-Sutcliffe (NS), o qual representa a proporção da variância da variável calculada que é explicada pelo modelo, correspondentes às equações 7 e 8:

$$\text{Eam} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (7)$$

$$NS = 1 - \frac{\sum_t (y_t - \hat{y}_t)^2}{\sum_t (y_t - \bar{y})^2} \quad (8)$$

onde: y_t = variável observada do registro t ; \hat{y}_t = variável calculada do registro t ; \bar{y} = média da variável observada.

DESCRIÇÃO DA APLICAÇÃO

A rede de monitoramento automático, operada pela Companhia de Pesquisa de Recursos Minerais – CPRM, para atendimento do Sistema De Alerta Hidrológico Da Bacia Do Rio Taquari, compõe-se das estações telemétricas apresentadas e localizadas na figura 2.

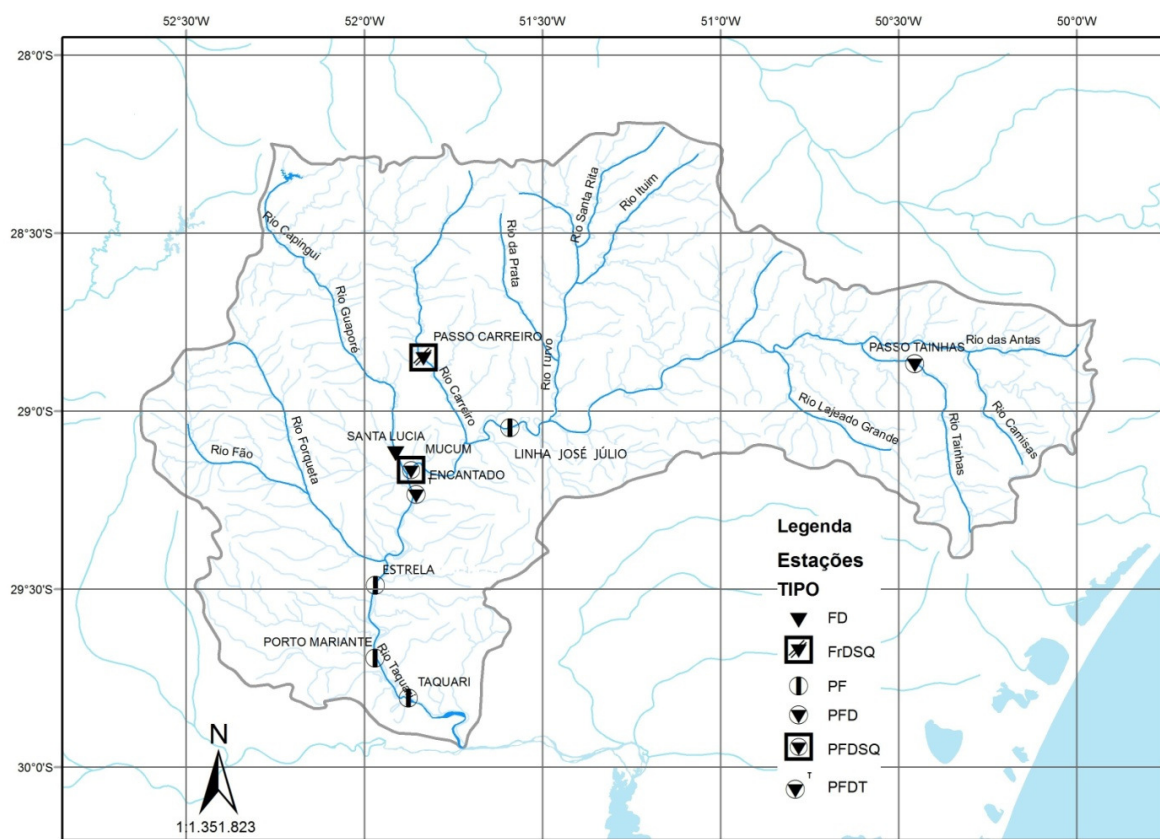


Figura 2 – Postos telemétricos da bacia do rio Taquari. Fonte: Pedrollo *et al.* (2011).

Uma vez que o treinamento das redes neurais que irão compor o modelo de previsão depende da disponibilidade de séries históricas, tanto de chuvas acumuladas diárias quanto de leituras de cotas, e não se pode contar ainda com séries extensas da rede, recentemente implantada, foram utilizadas como entradas dos modelos, principalmente, os dados da Rede Hidrometeorológica Nacional correspondentes a estes postos, com leituras pluviométricas às 07 horas, e limimétricas às 07 e às 17 horas. Considerando-se a disponibilidade de dados na série histórica e o efetivo aproveitamento na rede telemétrica atual, foram selecionados, para esta aplicação preliminar, os postos de Passo Tainhas, Encantado, Muçum, Santa Lúcia e Estrela, sendo aproveitados nos dois primeiros apenas os dados pluviométricos, e no de Estrela, monitorado pela Administração de Hidrovias do Sul (AHSUL), as leituras das 06, 12, 18 e 24 horas.

Após a formatação dos registros, e exclusão dos registros com falhas, tanto para alcance de 05 horas quanto para alcance de 11 horas, resultam 5458 registros. Inicialmente, selecionou-se 2660 registros para o treinamento (entre os quais foram incluídos os extremos do domínio de cada

variável), e 1300 registros para a validação, ficando os restantes para a verificação da capacidade de generalização dos modelos resultantes. O treinamento e os testes das redes neurais foram, neste trabalho, efetuados com base sempre no tempo atual das 07:00 horas da manhã, porém, aplicações práticas podem ser efetuadas em qualquer hora do dia, bastando utilizar as demais entradas do modelo com as defasagens temporais relativas correspondentes.

Cada modelo resulta da combinação de diversas redes neurais generalizadas, cada uma constituindo um Modelo Parcial, e contemplando uma situação diferente de possível degradação do sistema (com possível falha de coleta ou de transmissão de dados de um ou mais postos), de forma que a condição de robustez do modelo seja atendida. A operação de um modelo começa pela identificação da situação representada pelo conjunto de dados disponibilizados, concluindo pela apresentação de uma previsão, após a aplicação do Modelo Parcial correspondente. Desta forma, é possível lidar com diversas possibilidades de pane em sensores e equipamentos de transmissão de dados, sem perder a capacidade de fornecer uma resposta.

OS MODELOS E OS RESULTADOS OBTIDOS

O número de componentes antecedentes de cada variável (níveis ou precipitações), bem como o número de neurônios da camada interna, foi pesquisado, por tentativas, no modelo para a disponibilidade de todos os dados, até se chegar a uma configuração considerada mais eficiente, a qual foi repetida, para efeito de obtenção de resultados preliminares, nos Modelos Parciais. Tanto no primeiro modelo (alcance de 05 horas) como no segundo (alcance de 11 horas), concluiu-se por uma camada interna de 10 neurônios, após a aplicação de um procedimento automático de pesquisa. A configuração das componentes antecedentes, utilizada para cada modelo, é descrita na tabela 1.

Tabela 1 – Configuração das entradas e das saídas dos Modelos Completos (MC) de previsão

Postos	dia t-1					dia t (atual)			Previsão para:	
	06:00	07:00	12:00	17:00	18:00	00:00	06:00	07:00	12:00	18:00
Ch Passo Tainhas		x						x		
Ch Muçum		x						x		
Ch Encantado		x						x		
Santa Lúcia		x		x				x		
Muçum		x		x				x		
Estrela	x		x		x	x	x		x	x

Os Modelos Parciais, para compor os dois modelos, tanto para o modelo com alcance de 05 horas como para o modelo com alcance de 11 horas, utilizam como dados de entrada, além dos níveis atuais e antecedentes em Estrela, as alturas pluviométricas e os níveis, quando existentes, dos postos, segundo a tabela 2, para o Modelo Completo (MC) e os Modelos Parciais (MPi).

Na tabela 3 são apresentadas as estatísticas de avaliação (da verificação da capacidade de generalização) dos modelos completos e parciais que compõe cada um dos dois modelos propostos, para previsões, respectivamente, com alcances de 05 horas e de 11 horas.

Para ilustração da utilização do modelo, em situações com o nível atual em Estrela igual ou acima do nível de alerta (15m) da amostragem de verificação, são apresentados, na figura 3, os resultados das previsões com o modelo completo correspondente ao alcance de 11 horas.

Tabela 2 – Combinação de postos utilizados para a composição dos modelos

Modelos	Postos incluídos	Postos excluídos
MC	Muçum, Santa Lúcia, Encantado e Passo Tainhas.	-
MP1	Muçum, Santa Lúcia, e Passo Tainhas.	Encantado
MP2	Muçum, Santa Lúcia e Encantado.	Passo Tainhas
MP3	Muçum e Santa Lúcia.	Encantado e Passo Tainhas
MP4	Muçum, Encantado e Passo Tainhas.	Santa Lúcia
MP5	Santa Lúcia, Encantado e Passo Tainhas.	Muçum
MP6	-	Muçum, Santa Lúcia, Encantado e Passo

Tabela 3 – Desempenho dos modelos na Verificação

Modelos\Desempenho		Eamd (m)	Ea95 (m)	Eam (m)	NS
Alcance 05 horas	MC	0,04	0,32	0,09	0,97
	MP1	0,04	0,31	0,08	0,98
	MP2	0,05	0,32	0,09	0,97
	MP3	0,04	0,31	0,08	0,98
	MP4	0,06	0,31	0,10	0,96
	MP5	0,02	0,30	0,08	0,97
	MP6	0,08	0,32	0,12	0,95
Alcance 11 horas	MC	0,07	0,53	0,14	0,93
	MP1	0,08	0,49	0,15	0,93
	MP2	0,08	0,50	0,15	0,92
	MP3	0,06	0,52	0,14	0,92
	MP4	0,14	0,53	0,19	0,87
	MP5	0,08	0,50	0,15	0,92
	MP6	0,24	0,54	0,29	0,80

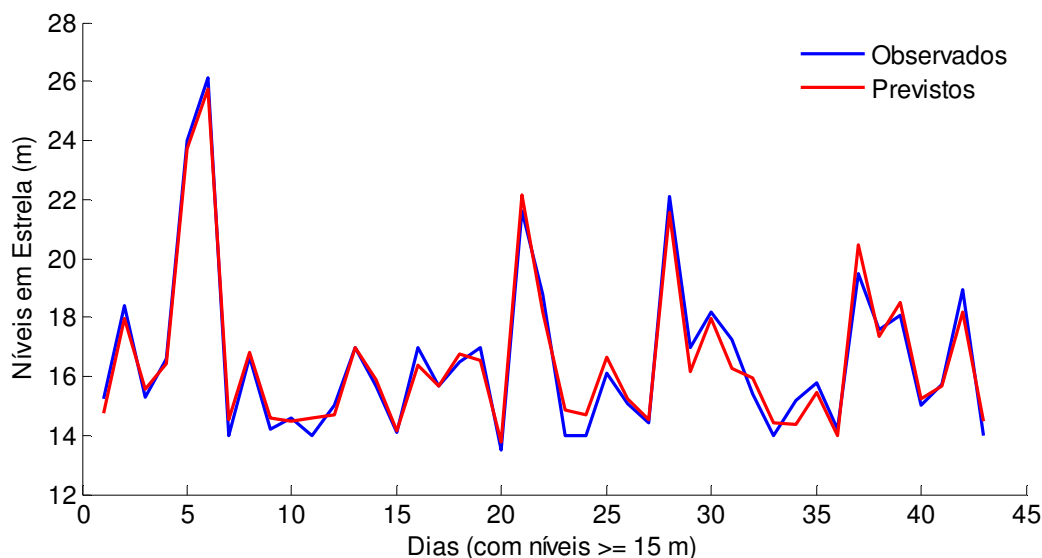


Figura 3 – Níveis previstos pelo modelo completo, com alcance de 11 horas.

CONCLUSÕES

Comprovou-se que é possível, com redes neurais artificiais, efetuar previsões de boa qualidade para Estrela, com alcances de 05 e de 11 horas, utilizando-se diferentes grupos de postos telemétricos remanescentes a possíveis panes em períodos emergenciais. O desenvolvimento de recursos para o uso integrado de modelos de combinações de redes neurais, bem como a associação de probabilidades às previsões são passos subsequentes recomendados.

AGRADECIMENTOS

O presente estudo integra o projeto “Desenvolvimento e apoio à implantação de uma estratégia integrada de prevenção de riscos associados a regimes hidrológicos na bacia do Taquari-Antas-RS, desenvolvido pelo Centro Universitário de Estudos e Pesquisas sobre Desastres (CEPED/RS) da UFRGS, com financiamento e apoio da Secretaria Nacional de Defesa Civil (SEDEC) do Ministério da Integração Nacional (MI) e apoio da Coordenadoria Estadual de Defesa Civil do Estado (CEDEC/RS). Os participantes do projeto agradecem ao CNPq pelas bolsas de Mestrado e de Produtividade em Pesquisa.

REFERÊNCIAS

- HECHT-NIELSEN, R. 1990. Neurocomputing. Addison-Wesley, 1990. pp. 433.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H.. 1989. Multilayer feedforward networks are universal approximators. Neural networks, v. 2, n. 5, p. 359-366.
- MATOS, A. B., PEDROLLO, O. C., CASTRO, N. M. R. Efeito do controle de montante de sub-bacias embutidas na previsão hidrológica de curto prazo com redes neurais. RBRH Revista Brasileira de Recursos Hídricos. , v.19, p.87-99, 2014.
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics., Vol. 5, pp. 115-133, 1943.
- PEDROLLO, M. C. R.; GERMANO, A.; SOTÉRIO, P.; RODRIGUES, E.; MADUELL, J. C.. 2011. Alerta hidrológico da bacia do rio Caí: Concepção e implantação do sistema. In: XIX Simpósio Brasileiro de Recursos Hídricos, 2011, Maceió. Anais.
- PEDROLLO, O. C., PEDROLLO, M. C. R. Sistema de alerta de cheias da bacia do rio Caí: previsão de níveis com redes neurais artificiais In: Eventos Extremos no Rio Grande do Sul: Inundações e Movimentos de Massa. 1 ed. Porto Alegre: Evangraf, 2013, v.1, p. 102-120.
- PEDROLLO, M. C. R., SOTÉRIO, P. W., PEDROLLO, O. C. Operation of the hydrological warning system in the Caí river basin - Preliminary studies In: 6th International Conference on Flood Management - ICFM6, 2014, São Paulo. PROCEEDING OF THE ICFM6. , 2014.
- RUMELHART D. E., HINTON G. E., WILLIAMS, R.J. 1986. Learning internal representation by error propagation. In: The PDP Research Group: Parallel distributed processing, vol 1, chap 8. MIT Press, Cambridge.
- WIDROW, B.; HOFF, M. E. 1960. Adaptive switching circuits. IRE WESCON Convention Record, New York: IRE Part 4, pp. 96-104.