

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO UNIVERSITÁRIO DE ESTUDOS E PESQUISAS SOBRE DESASTRES

PRODUTO 4.1.2. SISTEMAS DE PREVISÃO DE CURTO PRAZO

**RF**  
RELATÓRIO FINAL

Porto Alegre  
Fevereiro/2017

## SUMÁRIO

PRODUTO 4.1.2. SISTEMAS DE PREVISÃO DE CURTO PRAZO.....	1
1. INTRODUÇÃO .....	1
2. OS MODELOS GENERALIZADOS COM REDES NEURAIAS ARTIFICIAIS .....	2
3. DESCRIÇÃO DA APLICAÇÃO E IDEALIZAÇÃO DOS MODELOS .....	7
4. PRODUTOS FINALIZADOS .....	11
4.1. Construção dos modelos .....	11
4.2. O Modelo Estrela_11h .....	16
5. CONSIDERAÇÕES FINAIS.....	19
REFERÊNCIAS.....	21

## LISTA DE FIGURAS

Figura 1 - Redes neurais artificiais. ....	3
Figura 2 - Localização dos postos telemétricos da bacia do Taquari.....	8
Figura 3 - Previsões com alcance de 05 horas, com tempo atual acima do nível de alerta. ....	16
Figura 4 - Previsões com alcance de 11 horas, com tempo atual acima do nível de alerta. ....	19

## LISTA DE TABELAS

Tabela 1 - Postos telemétricos do Sistema de Alerta da Bacia do Rio Taquari.....	7
Tabela 2 - Configuração dos dados de entrada e das saídas dos modelos de previsão para as 12:00 horas e para as 18:00 horas.....	11
Tabela 3 - Combinação de postos utilizados para a composição dos modelos para as diferentes situações contempladas.....	12

## PRODUTO 4.1.2. SISTEMAS DE PREVISÃO DE CURTO PRAZO

### 1. INTRODUÇÃO

O monitoramento das situações de cheias fluviais, associadas a medidas complementares, como informação e educação pública, bem como planos para evacuação emergencial, podem fazer muita diferença para uma população atingida por uma enchente.

A efetividade das providências necessárias, porém, depende do tempo disponível, uma vez detectada a situação de emergência. Para incrementar este tempo, podem-se utilizar modelos de previsão hidrológica, obtendo-se com antecedência um panorama da situação no futuro próximo (que podem ser algumas horas ou mesmo dias, dependendo do tamanho da bacia), que constitui a previsão de curto prazo. O panorama desejado constitui-se de uma descrição espacial da inundação prevista, que inclua também as probabilidades associadas a esta previsão.

A espacialização das previsões obtidas para uma seção fluvial, ou um conjunto de seções, é, em geral (Oliveira et al., 2012), obtida por interpolação em mapas digitais do terreno, sendo uma etapa posterior às previsões pontuais, para seções fluviais monitoradas.

Previsões confiáveis de níveis fluviais de inundação são importantes, primeiramente, na fase de ascensão, para orientação de ações preventivas, como a remoção de populações. Na fase de recessão, porém, o conhecimento do rebaixamento esperado dos níveis fluviais pode também ser importante, 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 ao certo, “a priori”, se uma situação de emergência (um evento) está realmente para ocorrer. Portanto, é importante que o modelo de previsão seja capaz de identificar as alterações previstas dos níveis fluviais antes do evento estar estabelecido, ou seja, o modelo deve ser capaz de operar com séries contínuas, e não apenas com situações (eventos) já configurados.

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 as previsões sejam associadas à incerteza, na forma de intervalos de confiança ou risco de sobrepasseamento de níveis de inundação; 2. Que os modelos sejam capazes de adaptar-se, não só a possíveis alterações físicas, como também a modificações no sistema de aquisição (sujeito à evolução pelo incremento da cobertura de postos, ou pela possível modificação da localização devido a imposições técnicas, como perda de sinal); 3. Que estes possam funcionar mesmo em presença de degradação do sistema de aquisição (possível,

pois os equipamentos podem sofrer panes ou avarias, justamente durante eventos), devendo a redução do grau de confiabilidade resultante, nestes casos, ser conhecida.

As previsões hidrológicas de curto prazo, também chamadas de previsões em tempo atual, dependem do conhecimento do estado do sistema e dos volumes afluentes (observados a montante do rio, ou procedentes das precipitações recentes). O estado atual é representado principalmente pelos níveis observados e pelas condições de umidade dos solos da bacia.

Apresenta-se, nesta etapa, uma investigação preliminar de como poderiam ser os modelos de previsão de curto prazo, baseados em redes neurais artificiais, com respostas pontuais e probabilísticas (Pedrollo et al., 2013), e 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 são recomendados 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 pontuais, em uma única seção fluvial, correspondente à régua limnimétrica de Estrela, 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), que opera esta rede telemétrica, os níveis de atenção, de alerta e de inundação desta seção são de 14m, 15m e 18m, respectivamente.

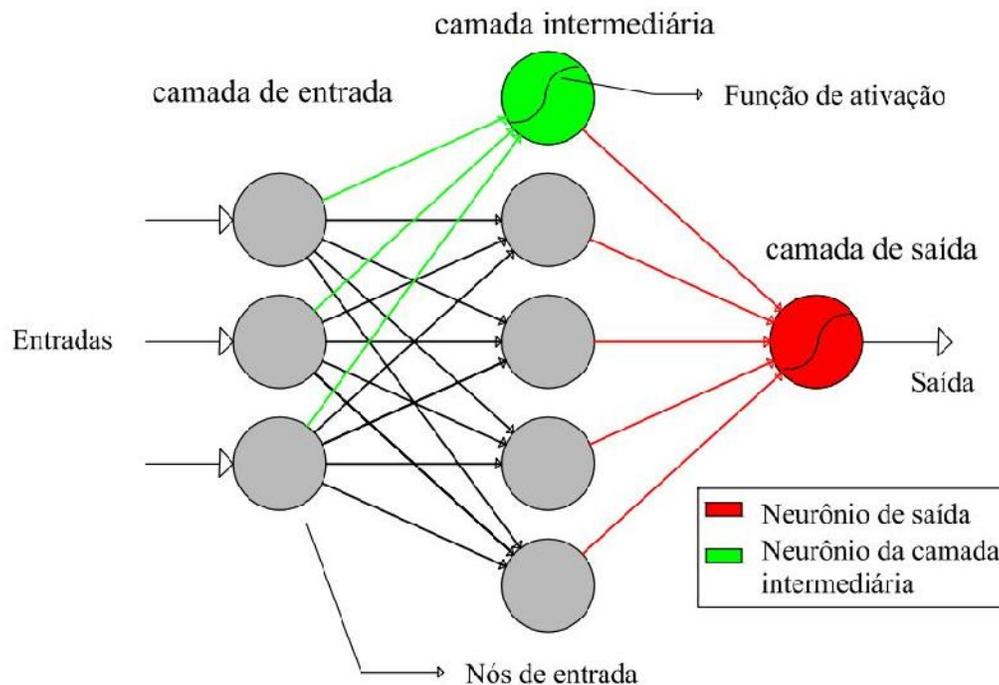
## **2. OS MODELOS GENERALIZADOS COM REDES NEURAIAS ARTIFICIAIS**

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 de um modelo proposto por McCulloch e Pitts (1943), formulado a partir de observações do neurônio natural. Constitui-se de uma função de soma ponderada das entradas e uma função, geralmente não linear, de ativação, a qual modifica o resultado anterior, resultando uma resposta que depende do ajuste (chamado de treinamento) dos parâmetros de ponderação (chamados pesos sinápticos, em analogia aos neurônios biológicos).

A rede neural artificial 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 apresentada como um grafo, com as ligações entre os nós, onde estão as funções de ativação, representadas por setas, sendo cada ligação correspondente a um peso sináptico (**Erro! Fonte de referência não encontrada.**).

**Figura 1 - Redes neurais artificiais.**



Fonte: Matos et al., 2014.

As saídas dos neurônios das camadas anteriores correspondem, sucessivamente, às entradas dos neurônios das camadas posteriores. Um termo de tendência é adotado, para cada neurônio, para proporcionar maior liberdade, permitindo que a saída possa assumir valores diferentes de zero, mesmo para entradas líquidas nulas.

Hecht-Nielsen (1987), apresentou um teorema da existência, adaptado de um teorema de Kolmogorov para funções contínuas arbitrárias: "Dada uma relação contínua  $r: [0,1]^n \rightarrow \mathbb{R}^m$ , existe uma rede neural com uma única camada interna e com  $2n + 1$  neurônios artificiais nesta camada, a qual pode aproximá-la exatamente".

Estimulados por este teorema, diversos autores enunciaram simultaneamente teoremas da aproximação universal com redes neurais, para relações de interesse prático, entre os quais o de Hornik et. al. (1989), cujo enunciado pode ser interpretado como:

“Dada uma relação mensurável  $r:R^n \rightarrow R^m$ , existe uma rede neural com uma única camada interna, a qual pode, desde que adequadamente treinada e com um número compatível de neurônios artificiais nesta camada, aproximá-la com qualquer precisão desejada”.

O número de neurônios na camada interna, na prática, depende da aplicação e da quantidade de amostras a ser utilizada no treinamento, podendo ser determinado pela experimentação.

Embora seja possível outras funções de ativação, a mais utilizada 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: é a saída da função de ativação;

n: é a 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:

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

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 rede neural com as funções de escalonamento, de entrada e de saída, podendo ser representado, no caso de funções de escalonamento lineares, por:

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

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 em um método de procura dos pesos sinápticos para a 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:

$W_k$  são os pesos sinápticos atuais;  $\tau$  é a taxa de aprendizado;  $e_k$  são os erros das saídas da camada;  $\delta_k$  é a derivada das funções ativação; e  $P_k$  são as entradas na própria camada, na iteração  $k$ .

Taxas de aprendizado muito grandes resultam treinamentos não convergentes, enquanto que taxas de aprendizado muito pequenas resultam treinamentos muito lentos, sendo o valor ideal de difícil determinação, para problemas complexos, podendo ser ajustado por tentativas.

O uso desta regra para o treinamento das camadas internas da rede requer o conhecimento dos erros nesta camada, os quais são calculados pela equação 6 (Rumelhart et. al, 1986). De acordo com esta equação, os erros das camadas anteriores ( $h$ ) dependem somente dos erros e das propriedades das camadas posteriores ( $s$ ), sendo, para camadas internas:

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

onde:

$e_h$  é o erro na camada interna;  $W_s$  são os pesos sinápticos na camada posterior;  $e_s$  são os erros na camada posterior; e  $\delta_s$  são as derivadas da função de ativação na camada posterior.

$e_s$  são as derivadas da função de ativação na camada posterior.

O algoritmo tem início com a aplicação da rede com pesos sinápticos gerados aleatoriamente, e o uso do algoritmo, composto de aplicações sucessivas, seguidas do cálculo dos erros nas camadas, e da atualização dos pesos sinápticos, segundo as equações anteriores. Cada aplicação do algoritmo, para o conjunto de registros disponibilizados para o treinamento, é um ciclo de treinamento, podendo ser necessários milhares de ciclos, dependendo da complexidade do problema.

O principal critério de parada do treinamento é o da precisão desejada. É necessário, porém, um critério adicional, representado pelo número máximo de ciclos, para a interrupção dos processos que não convergem.

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 (aplicação a uma série de dados diferente da série utilizada no treinamento, e representativa para os usos pretendidos) 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.

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. 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 a estatística de erros do treinamento vai sempre diminuindo (indicando desempenho melhor), enquanto que a estatística de erros 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 fica comprometida, havendo a interrupção do treinamento (Hecht-Nielsen, 1990).

O método de treinamento é dependente das condições iniciais, a partir das quais existe o risco de estacionamento em mínimos locais. Este fenômeno é tanto mais frequente quanto mais complexa é a superfície de desempenho, a qual depende das complexidades da rede e dos fenômenos aproximados por esta. Para contornar este problema, executa-se o treinamento com diversas inicializações aleatórias dos pesos sinápticos, adotando-se o modelo de melhor desempenho.

Dornelles et al. (2013) apresentam 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 de desempenho subsequentes são irrelevantes.

Tanto a avaliação do treinamento quanto a verificação da generalização devem ser efetuadas com o uso de estatísticas dos erros do modelo. Estatísticas válidas são os erros característicos (o erro absoluto máximo, o quantil 0,95 do erro e o erro mediano), e índices de desempenho, como o erro médio absoluto (EMA), a raiz da média do quadrado dos erros (RMQE) e o coeficiente de Nash-Sutcliffe (NS), o qual

representa a proporção da variância da variável calculada que é explicada pelo modelo. Estes índices são representados, respectivamente, pelas equações 7, 8 e 9, a seguir:

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

$$RMQE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (8)$$

$$NS = 1 - \frac{\sum_t (y_t - \hat{y}_t)^2}{\sum_t (y_t - \bar{y})^2} \quad (9)$$

onde:

$y_t$  = variável observada do registro t.

$\hat{y}_t$  = variável calculada do registro t.

$\bar{y}$  = média da variável observada.

### 3. DESCRIÇÃO DA APLICAÇÃO E IDEALIZAÇÃO DOS MODELOS

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 na **Erro! Fonte de referência não encontrada.**

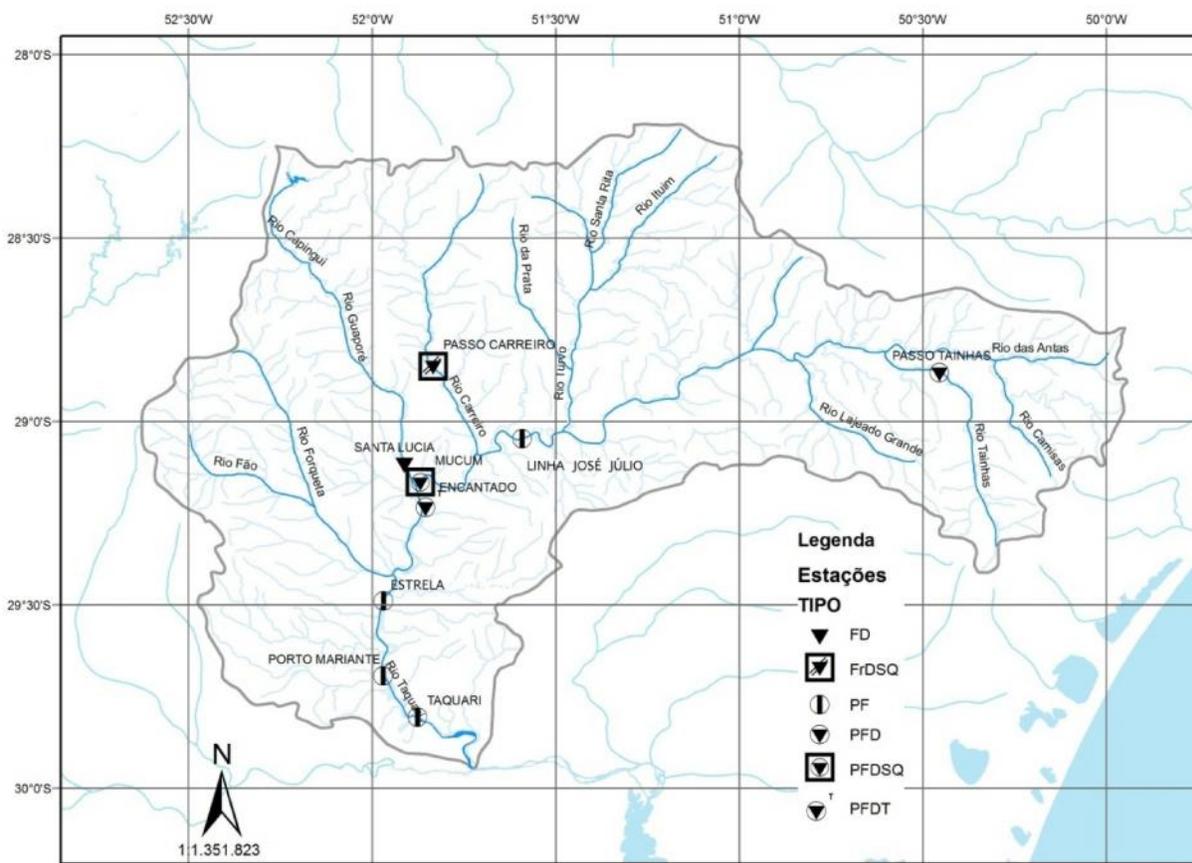
**Tabela 1 - Postos telemétricos do Sistema de Alerta da Bacia do Rio Taquari.**

Nº	Estação		Tipo	
	Nome	Código	Existente	Ampliada
1	Passo Tainhas	2850009	P	PT
2	Linha José Júlio	Nova		PFDQT
3	Passo Carreiro	86500000	FrDSQ	PFrDSQ
4	Muçum	02951070/86510000	PFDSQ	PFDSQT
5	Santa Lúcia	86580000	FDQ	PFDQT
6	Encantado	02951010/86720000	PFDQT	PFDQT
7	Estrela	Nova		PFDQT
8	Porto Mariante	86895000	F	PFT
9	Taquari	86950000	F	PFT

Fonte: Companhia de Pesquisa de Recursos Minerais – CPRM

Estas estações estão localizadas segundo a **Erro! Fonte de referência não encontrada.**, e, excetuando-se Passo Carreiro, já estão todas instaladas e em funcionamento.

**Figura 2 - Localização dos postos telemétricos da bacia do Taquari.**



Fonte: Companhia de pesquisa de Recursos Minerais - CPRM.

As estações de Estrela e Linha José Júlio são novas, ou seja, não fazem parte da Rede Hidrometeorológica Nacional, de responsabilidade da ANA (Agência Nacional de Águas) e operadas pela CPRM. O monitoramento do posto de Estrela, porém, é feito diariamente, quatro vezes por dia, às 0, 6, 12 e 18h, pela AHSUL (Administração de Hidrovias do Sul), existindo uma série histórica, disponibilizada desde 1977.

Uma vez que o treinamento das redes neurais que irão compor o modelo de previsão proposto 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, utilizou-se para tanto os dados da Rede Hidrometeorológica Nacional correspondentes a estes postos, excetuando-se as leituras do posto limnimétrico de Encantado, o qual, por sua vez, apresenta grande número de falhas em sua série histórica.

Portanto, uma vez que os postos selecionados para que suas leituras sejam utilizadas como entradas nos modelos são aqueles que, além de serem telemétricos, possuem dados históricos suficientes, são utilizadas as cotas lidas em Santa Lúcia, Muçum, e Estrela, e as chuvas acumuladas de 24 horas em Passo Tainhas, Muçum e Encantado.

As séries de dados existentes nesta rede (de 01/01/1991 a 31/03/2011), por ocasião do início da realização deste trabalho, são suficientes (8126 registros) para o treinamento e a verificação de modelos baseados em redes neurais artificiais, tendo-se em conta, também, a representatividade proporcionada pela grande frequência de ocorrência de eventos extremos nesta bacia.

A coleta de dados de níveis e de chuvas da rede hidrometeorológica nacional, operada pela CPRM no âmbito do convênio com a ANA (Agência Nacional de Águas), consiste em uma leitura diária de chuva às 7 horas (total acumulado em 24 horas) e duas leituras diárias de níveis, às 7 horas e às 17 horas. Conseqüentemente, as alternativas disponíveis para os modelos preliminares, que ainda não contam com séries de dados telemétricos para ajustes, são limitadas.

Optou-se, neste estudo preliminar, pelo treinamento de modelos a partir das 07:00 horas, quando da disponibilização dos dados de chuva de 24 horas, resultando, em função dos níveis disponíveis em Estrela, pela escolha de duas possibilidades para os alcances de previsão em Estrela. Portanto, foram testados dois modelos, um para previsões às 12:00 horas (alcance de 05 horas) e o outro para previsões às 18:00 horas (alcance de 11 horas). O fato do treinamento e dos testes serem, neste trabalho, efetuados com base sempre no tempo atual das 07:00 horas da manhã, porém, não significa que, em situações práticas, o modelo tenha esta restrição, pois, para a aplicação em qualquer hora do dia, basta utilizar as demais entradas do modelo com as defasagens temporais relativas correspondentes .

Cada modelo resulta da combinação de diversos modelos individuais, cada um 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.

Internamente, o modelo começa pela identificação da situação representada pelo conjunto de dados disponibilizados, concluindo pela apresentação de uma previsão, composta, além dos níveis pontuais esperados, de valores associados à probabilidade de serem sobrepassados, e de riscos identificados de ultrapassagem do nível de inundação. O algoritmo interno do modelo de previsão, contemplando seis situações, considerando-se a “Situação 0” sem indisponibilidade de dados, e as situações seguintes, com falhas de uma ou mais estações, constitui-se de:

Conforme os dados disponíveis constituam:

Situação 0, faz

Aplica Modelo Completo (MC)

Níveis associados às probabilidades 0,05; 0,25; 0,50; 0,75 e 0,95

Risco de sobrepasseamento do nível de inundação

Situação 1, faz

Aplica Modelo Parcial 1 (MP1)

Níveis associados às probabilidades 0,05; 0,25; 0,50; 0,75 e 0,95

Risco de sobrepasseamento do nível de inundação

Situação 2, faz

Aplica Modelo Parcial 2 (MP2)

Níveis associados às probabilidades 0,05; 0,25; 0,50; 0,75 e 0,95

Risco de sobrepasseamento do nível de inundação

---

Situação 6, faz

Aplica Modelo Parcial 6 (MP6)

Níveis associados às probabilidades 0,05; 0,25; 0,50; 0,75 e 0,95

Risco de sobrepasseamento do nível de inundação

Fim conforme

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. Como cada modelo de uma situação individual é preparado para responder com sua própria incerteza, representada pelas

probabilidades implícitas, a incerteza, tendo em conta a ausência de uma determinada informação, passa a ser automaticamente fornecida.

Os modelos preconizados nesta etapa contemplam somente a previsão de níveis em um posto limnimétrico. O prosseguimento natural da pesquisa seria a espacialização destas previsões.

Como as transformações níveis-vazões implicam em agregar incertezas, e os modelos pretendidos são de natureza empírica, ou seja, não contemplam transformações objetivas de volumes, decidiu-se que as variáveis de entrada e de saída dos modelos seriam diretamente os níveis lidos nas réguas, sem transformações níveis-vazão. E as entradas de chuvas não sofreriam transformações preliminares para chuvas médias na bacia, ou para chuvas efetivas, ficando estas possíveis transformações consideradas implícitas no próprio modelo.

#### 4. PRODUTOS FINALIZADOS

##### 4.1. Construção dos modelos

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 situação 0 (disponibilidade de todos os dados), até se chegar a uma configuração considerada mais eficiente, a qual foi repetida nos demais 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 com duração de 27,32 horas para o primeiro e de 20,43 horas para o segundo modelo. A configuração das componentes antecedentes, para cada modelo, é descrita na **Erro! Fonte de referência não encontrada..**

Os Modelos Parciais, para compor os dois modelos, tanto para o modelo com alcance de 05 horas (previsão para as 12:00 horas em Estrela) como para o modelo com alcance de 11 horas (previsão para as 18:00 horas em Estrela), 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

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

**Tabela 2 - Configuração dos dados de entrada e das saídas dos modelos de previsão para as 12:00 horas e para as 18:00 horas.**

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

**Tabela 3 - Combinação de postos utilizados para a composição dos modelos para as diferentes situações contempladas.**

Modelos	Postos incluídos	Postos excluídos
MC - Modelo completo	Muçum, Santa Lúcia, Encantado e Passo Tainhas.	-
MP1 - Modelo Parcial 1	Muçum, Santa Lúcia, e Passo Tainhas.	Encantado
MP2 - Modelo Parcial 2	Muçum, Santa Lúcia e Encantado.	Passo Tainhas
MP3 - Modelo Parcial 3	Muçum e Santa Lúcia.	Encantado e Passo Tainhas
MP4 - Modelo Parcial 4	Muçum, Encantado e Passo Tainhas.	Santa Lúcia
MP5 - Modelo Parcial 5	Santa Lúcia, Encantado e Passo Tainhas.	Muçum

MP6 - Modelo  
Parcial 6

Muçum, Santa Lúcia, Encantado e  
Passo Tainhas.

Após a formatação dos registros, e exclusão dos registros com falhas, ocorre uma redução considerável dos registros disponíveis, sendo que, para os modelos completos, tanto para alcance de 05 horas quanto para alcance de 11 horas, resultam 5458 registros. Inicialmente, selecionou-se 2660 registros para o treinamento e 1300 registros para a validação, ficando os restantes para a verificação, para a aplicação da validação cruzada e a verificação da capacidade de generalização dos modelos resultantes. Porém, para garantir a representatividade do treinamento, uma investigação preliminar identificou os registros que possuem valores extremos, nos limites dos domínios de cada uma das variáveis, de entrada ou de saída. Estes registros identificados, diferentes para cada situação, são acrescentados à série de treinamento, e excluídos das demais, para cada Modelo Parcial, modificando ligeiramente as quantidades de registros utilizadas nas três etapas.

O número de iterações do treinamento, a partir de condições iniciais aleatórias, foi fixado em 30, para todos os modelos, e as estatísticas apresentadas referem-se aos resultados do treinamento adotado, para cada rede neural.

Apresentam-se, nos itens seguintes, as ilustrações dos resultados, bem como as estatísticas de avaliação (do treinamento e da verificação da 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. São usadas as seguintes definições:

**Tempo decorrido:** Tempo, em minutos, investido no treinamento.

**Ea(0,5) :** Erro absoluto mediano (corresponde ao quantil 0,5), em m.

**Ea(0,95):** Quantil 0,95 dos erros absolutos, em cm. Portanto, erro que não foi ultrapassado com a frequência de 0,95, em m.

**Eamax:** Erro absoluto máximo, em m.

**Média(Ea):** Média dos erros absolutos, em m.

**RMQE:** Raiz da média do quadrado dos erros, em m.

**NS:** Coeficiente de eficiência de Nash-Suitcliffe.

4.2. O Modelo Estrela\_05h

### **MC: Modelo Completo**

Tempo decorrido = 1.639,4minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,12    Ea(0,95) = 0,54    Ea max = 2,00  
Media(Ea) = 0,17    RMQE = 0,27    NS = 0,988

Estatísticas de Verificação:

Ea(0,5) = 0,04    Ea(0,95) = 0,32    Ea max = 1,48  
Media(Ea) = 0,09    RMQE = 0,17    NS = 0,970

### **MP1: Modelo Parcial 1**

Tempo decorrido = 72,0minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,12    Ea(0,95) = 0,58    Ea max = 1,94  
Media(Ea) = 0,18    RMQE = 0,28    NS = 0,986

Estatísticas de Verificação:

Ea(0,5) = 0,04    Ea(0,95) = 0,31    Ea max = 1,93  
Media(Ea) = 0,08    RMQE = 0,16    NS = 0,975

### **MP2: Modelo Parcial 2**

Tempo decorrido = 65,1minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,11    Ea(0,95) = 0,56    Ea max = 1,85  
Media(Ea) = 0,17    RMQE = 0,28    NS = 0,986

Estatísticas de Verificação:

Ea(0,5) = 0,05    Ea(0,95) = 0,32    Ea max = 1,53  
Media(Ea) = 0,09    RMQE = 0,16    NS = 0,973

### **MP3: Modelo Parcial 3**

Tempo decorrido = 64,9minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,11$     $Ea(0,95) = 0,60$     $Ea \text{ max} = 1,93$   
 $Media(Ea) = 0,18$     $RMQE = 0,29$     $NS = 0,985$

Estatísticas de Verificação:

$Ea(0,5) = 0,04$     $Ea(0,95) = 0,31$     $Ea \text{ max} = 1,64$   
 $Media(Ea) = 0,08$     $RMQE = 0,16$     $NS = 0,977$

**MP4: Modelo Parcial 4**

Tempo decorrido = 65,0 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,12$     $Ea(0,95) = 0,59$     $Ea \text{ max} = 1,82$   
 $Media(Ea) = 0,20$     $RMQE = 0,29$     $NS = 0,986$

Estatísticas de Verificação:

$Ea(0,5) = 0,06$     $Ea(0,95) = 0,31$     $Ea \text{ max} = 3,05$   
 $Media(Ea) = 0,10$     $RMQE = 0,18$     $NS = 0,957$

**MP5: Modelo Parcial 5**

Tempo decorrido = 60,3 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,12$     $Ea(0,95) = 0,64$     $Ea \text{ max} = 1,99$   
 $Media(Ea) = 0,20$     $RMQE = 0,31$     $NS = 0,979$

Estatísticas de Verificação:

$Ea(0,5) = 0,02$     $Ea(0,95) = 0,30$     $Ea \text{ max} = 1,97$   
 $Media(Ea) = 0,08$     $RMQE = 0,16$     $NS = 0,969$

**MP6: Modelo Parcial 6**

Tempo decorrido = 53,2 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,18$     $Ea(0,95) = 0,94$     $Ea \text{ max} = 1,65$   
 $Media(Ea) = 0,30$     $RMQE = 0,44$     $NS = 0,962$

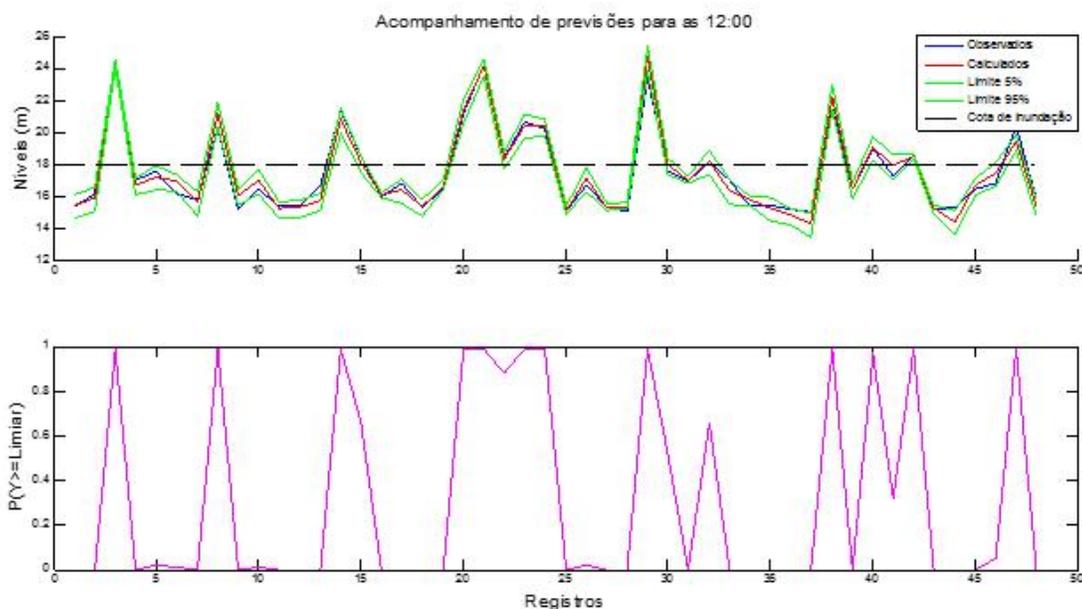
Estatísticas de Verificação:

$Ea(0,5) = 0,08$     $Ea(0,95) = 0,32$     $Ea \text{ max} = 2,91$   
 $Media(Ea) = 0,12$     $RMQE = 0,20$     $NS = 0,953$

Para efeito de ilustração da utilização do modelo, em situações críticas (com o nível atual em Estrela igual ou acima do nível de alerta - 15m), são apresentados, na **Erro! Fonte de referência não encontrada.**, os resultados das previsões, nas formas pontual e probabilística.

A previsão probabilística é apresentada na forma de limites de confiança para os resultados e da probabilidade, a cada previsão, do limiar de 18m (onde tem início a ocorrência de inundações), de sobrepassamento deste limiar no intervalo de tempo correspondente ao alcance da previsão.

**Figura 3 - Previsões com alcance de 05 horas, com tempo atual acima do nível de alerta.**



## 4.2. O Modelo Estrela\_11h

### MC: Modelo Completo

Tempo decorrido = 1.226,1 minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,20    Ea(0,95) = 0,87    Ea max = 5,44  
Media(Ea) = 0,30    RMQE = 0,50    NS = 0,950

Estatísticas de Verificação:

Ea(0,5) = 0,07    Ea(0,95) = 0,53    Ea max = 2,95  
Media(Ea) = 0,14    RMQE = 0,26    NS = 0,933

### MP1: Modelo Parcial 1

Tempo decorrido = 55,3 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,18$     $Ea(0,95) = 0,76$     $Ea \text{ max} = 5,56$   
 $Media(Ea) = 0,28$     $RMQE = 0,51$     $NS = 0,950$

Estatísticas de Verificação:

$Ea(0,5) = 0,08$     $Ea(0,95) = 0,49$     $Ea \text{ max} = 3,50$   
 $Media(Ea) = 0,15$     $RMQE = 0,29$     $NS = 0,933$

**MP2: Modelo Parcial 2**

Tempo decorrido = 55,5 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,18$     $Ea(0,95) = 0,89$     $Ea \text{ max} = 5,48$   
 $Media(Ea) = 0,29$     $RMQE = 0,53$     $NS = 0,946$

Estatísticas de Verificação:

$Ea(0,5) = 0,08$     $Ea(0,95) = 0,50$     $Ea \text{ max} = 3,57$   
 $Media(Ea) = 0,15$     $RMQE = 0,29$     $NS = 0,917$

**MP3: Modelo Parcial 3**

Tempo decorrido = 54,6 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,19$     $Ea(0,95) = 0,82$     $Ea \text{ max} = 5,58$   
 $Media(Ea) = 0,30$     $RMQE = 0,53$     $NS = 0,944$

Estatísticas de Verificação:

$Ea(0,5) = 0,06$     $Ea(0,95) = 0,52$     $Ea \text{ max} = 3,62$   
 $Media(Ea) = 0,14$     $RMQE = 0,31$     $NS = 0,924$

**MP4: Modelo Parcial 4**

Tempo decorrido = 54,5 minutos

Estatísticas de Treinamento:

$Ea(0,5) = 0,21$     $Ea(0,95) = 1,12$     $Ea \text{ max} = 5,27$   
 $Media(Ea) = 0,35$     $RMQE = 0,57$     $NS = 0,936$

Estatísticas de Verificação:

$Ea(0,5) = 0,14$     $Ea(0,95) = 0,53$     $Ea \text{ max} = 4,50$   
 $Media(Ea) = 0,19$     $RMQE = 0,32$     $NS = 0,873$

**MP5: Modelo Parcial 5**

Tempo decorrido = 60,6 minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,18    Ea(0,95) = 0,91    Ea max = 5,53  
Media(Ea) = 0,29    RMQE = 0,51    NS = 0,933

Estatísticas de Verificação:

Ea(0,5) = 0,08    Ea(0,95) = 0,50    Ea max = 3,60  
Media(Ea) = 0,15    RMQE = 0,27    NS = 0,921

### **MP6: Modelo Parcial 6**

Tempo decorrido = 53,4 minutos

Estatísticas de Treinamento:

Ea(0,5) = 0,34    Ea(0,95) = 1,59    Ea max = 2,84  
Media(Ea) = 0,52    RMQE = 0,71    NS = 0,888

Estatísticas de Verificação:

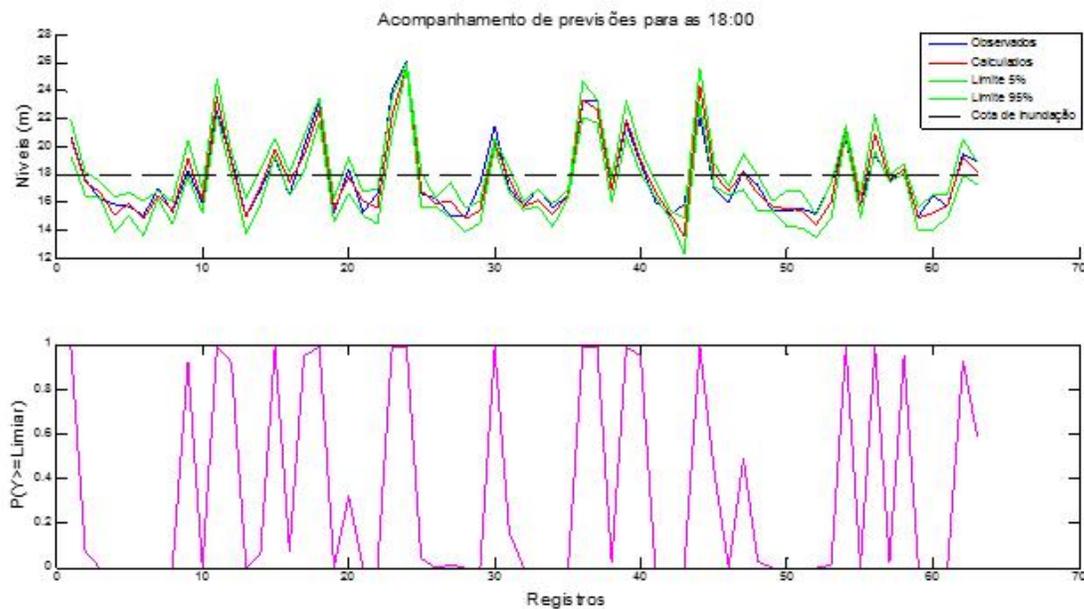
Ea(0,5) = 0,24    Ea(0,95) = 0,54    Ea max = 5,20  
Media(Ea) = 0,29    RMQE = 0,41    NS = 0,803

Para efeito de ilustração da utilização do modelo, em situações críticas (com o nível atual em Estrela igual ou acima do nível de alerta - 15m), são apresentados, na

, os resultados das previsões, nas formas pontual e probabilística.

A previsão probabilística é apresentada na forma de limites de confiança para os resultados e da probabilidade, a cada previsão, do limiar de 18m (onde tem início a ocorrência de inundações), de sobrepassamento deste limiar no intervalo de tempo correspondente ao alcance da previsão.

**Figura 4 - Previsões com alcance de 11 horas, com tempo atual acima do nível de alerta.**



## 5. CONSIDERAÇÕES FINAIS

Embora a necessidade de efetivar o treinamento dos modelos com os dados convencionais da rede nacional tenha limitado as possibilidades para esta tarefa, em uma situação prática de aplicação, qualquer momento em que se deseje realizar uma previsão, será, desde que a rede telemétrica esteja funcionando, um tempo atual viável.

Para os dois alcances considerados, observou-se que, excetuando-se o Modelo Parcial 4 (excluindo-se o posto de Santa Lúcia) para alcance de 11 horas, as diferentes configurações de disponibilidade de dados são bastante aceitáveis, em comparação ao Modelo Completo de cada alternativa (alcance pesquisado). Em alguns casos, para o alcance de 05 horas, modelos parciais foram até, aparentemente, um pouco mais eficientes do que o modelo completo. Por outro lado, o uso apenas de dados de níveis atuais e antecedentes do próprio posto de Estrela não resultou em modelos igualmente eficientes.

Ou seja, é possível efetuar previsões com a mesma qualidade, utilizando-se postos telemétricos com informações diferentes. Esta é uma observação importante, tendo-se em conta que é justamente isso que pode ocorrer durante eventos extremos, razão pela qual o modelo desejado deve ser suficientemente robusto para ser utilizado nestes casos.

Os níveis observados, em geral (com proporção de cerca de 90%), ocorrem dentro dos intervalos de previsão estimados. Esta informação, bem como a estimativa do risco de sobre passamento do limiar de inundação ( $PY \geq \text{Limiar}$ ), quando elevada, apresentam-se como fortes indicativos que podem ser úteis para orientar as ações preventivas.

## REFERÊNCIAS

- DORNELLES, F.; GOLDENFUM, J. A.; PEDROLLO, O. C. Artificial neural network methods applied to forecasting river levels. In: RBRH: revista brasileira de recursos Hídricos. Porto Alegre, RS. Vol. 18, n. 4 (out./dez. 2013), p. 45-54: il.; gráfs.; tabs.
- HECHT-NIELSEN, R., 1987. Kolmogorov's mapping neural network existence theorem. Proceedings of the First IEEE International Joint Conference on Neural Networks, San Diego, California, pp. 11–14, IEEE, New York.
- 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.

OLIVEIRA, G. G.; GUASSELLI, L. A.; SALDANHA, D. L.. Modelos de previsão e espacialização das áreas inundáveis em Montenegro, Rio Grande do Sul, Brasil.. Revista Brasileira de Geomorfologia, v. 13, p. 355-378, 2012.

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.