

Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais

Marcus Felipe Matos Cruz, Lucas Daniel Rodrigues e Bruno Rabelo Versiani

Centro de Pesquisas Hidráulicas e Recursos Hídricos – UFMG

marcus.felipe@terra.com.br, lucasdr.ufmg@gmail.com, versiani@ehr.ufmg.br

Recebido: 15/09/09 - revisado: 09/02/10 - aceito: 05/03/10

RESUMO

Neste artigo apresenta-se a comparação de duas metodologias de previsão de cheias, utilizando-se modelos com poucos parâmetros a calibrar. Na metodologia DPFT (Diferenças Primeiras da Função de Transferência) usa-se uma amostra de observações de eventos precipitação-vazão e um algoritmo iterativo para a identificação simultânea do Hidrograma Unitário (Função de Transferência) médio da bacia e de uma série de precipitações efetivas associadas a cada evento. Esta última particularidade permite a calibração e comparação de diferentes modelos de Função de Produção, representando a transformação precipitação observada – precipitação efetiva. No caso em questão, foi utilizado um modelo simples de Função de Produção, o modelo GR3. A metodologia DPFT é comparada com um modelo simples de Redes Neurais Artificiais, onde as não-linearidades inerentes ao processo de transformação precipitação-vazão são representadas por uma estrutura de rede MLP com 4 neurônios representativos das vazões e precipitações. Os resultados de aplicação e comparação dos métodos em duas bacias hidrográficas de médio porte são apresentados e analisados. Nos estudos de caso analisados, a metodologia DPFT apresentou um desempenho ligeiramente superior ao modelo de redes neurais artificiais, mostrando, entretanto, menor regularidade nos resultados.

Palavras-chave: modelagem precipitação-vazão, metodologia DPFT, redes neurais artificiais.

INTRODUÇÃO

A grande maioria da rede brasileira de estações de monitoramento hidrológico dispõe somente de dados de precipitação e de vazão, com dados de observação diários. Esta carência de dados hidrológicos sempre dificulta a adoção de metodologias de previsão de cheias que utilizam modelos mais sofisticados, onde em geral há necessidade de calibração de grande número de parâmetros, relacionados, por exemplo, à caracterização de perdas por evapotranspiração e interceptação vegetal, umidade do solo, separação dos escoamentos superficial e subterrâneo, tempo de esvaziamento dos reservatórios superficial e subterrâneo, capacidade de infiltração e tempo de concentração da bacia. Além do mais, o processo de calibração de parâmetros, quando manual, pode ser uma tarefa tediosa para usuários pouco experientes e, quando automática, é dependente da eficácia e eficiência de um algoritmo de calibração automática (Collischonn e Tucci, 2003).

Portanto, tratando-se de simulação hidrológica, métodos globais mais simples, que usam modelos concentrados empíricos, podem ser usados em

estudos e aplicações tecnológicas. Dentre os métodos mais simples, baseado apenas em dados de precipitação e de vazão, destaca-se o método do Hidrograma Unitário, extensivamente analisado e utilizado ao longo de décadas, em simulação e previsão de cheias. O uso da metodologia DPFT (Diferenças Primeiras da Função de Transferência), Duband et al (1993), para identificação do Hidrograma Unitário médio de uma bacia hidrográfica e das precipitações efetivas, através de amostras de precipitações e vazões observadas, torna possível a escolha da melhor Função de Produção relativa à bacia hidrográfica em estudo.

Estudos realizados por Cruz (2007) e Cruz et al (2006) permitiram a análise de vários modelos de Função de Produção em bacias do Estado de Minas Gerais, pela metodologia DPFT, e um modelo simples, com 1 parâmetro calibrável, o modelo GR3 (Edijatno e Michel, 1989), que apresentou um melhor desempenho. Assim sendo, neste estudo de caso apresentado, adotou-se o modelo GR3, cujos parâmetros foram calibrados, evento por evento, tendo-se como paradigma as precipitações efetivas geradas pelo método DPFT.

Por outro lado, Redes Neurais Artificiais (RNA) tem sido atualmente apresentadas como uma alternativa aos métodos tradicionais na solução de problemas de previsão de séries temporais, como é o caso das vazões. No caso em questão, o uso desta técnica é interessante, na medida em que não é necessário ter-se um conhecimento físico-matemático prévio das complexas relações não-lineares que descrevem a transformação precipitação-vazão na bacia hidrográfica, pois não se dispõe de dados hidrológicos mais detalhados, tais como fisiografia, estado e constituição do solo e umidade antecedente. Neste trabalho, este tipo de modelo caixa-preta é usado na comparação com a metodologia DPFT, em estudo para 2 bacias de médio porte no Estado de Minas Gerais.

MODELOS DE SIMULAÇÃO PRECIPITAÇÃO-VAZÃO

Uma classificação completa de modelos hidrológicos ou sistemas é dada por Tucci (2005), que caracteriza modelos contínuos ou discretos, concentrados ou distribuídos, estocásticos ou determinísticos, conceituais ou empíricos.

O processo da relação precipitação-vazão em uma bacia hidrográfica é conhecido como fortemente não-linear, variável no tempo, espacialmente distribuído e, em geral, não pode ser descrito por modelos matemáticos simples (Singh, 1964; Pilgrim, 1976). Duas abordagens para modelagem do processo precipitação-vazão tem sido exploradas na literatura: modelagem conceitual (física) e modelagem sistêmica, por vezes designadas, respectivamente 'caixa-branca' e 'caixa-preta' (Sorooshian, 1983; O'Connell e Clarke, 1981; Young e Wallis, 1985).

Os modelos conceituais geralmente incorporam formas simplificadas de leis físicas, com parâmetros que são representativos das características das bacias hidrográficas. Por razões práticas (disponibilidade de dados, problemas de calibração, etc.) alguns modelos assumem representações globais para os parâmetros. São exemplos largamente conhecidos o modelo de Sacramento (Burnash et al., 1973), o modelo de Stanford (Crawford e Linsley, 1966) e os modelos IPH (Tucci, 2005).

O método do Hidrograma Unitário introduzido por Sherman (1932), reformulado por Nash (1957) e Dooge (1959,1973), inaugurou uma classe de modelos empíricos globais, e sofreu várias atualizações e adaptações que são adotadas hoje em pes-

quisas ou aplicações tecnológicas, tais como projetos de obras hidráulicas e sistemas de previsão de cheias. Exemplos recentes mostram ainda o interesse de pesquisadores por este método: Yang e Han (2006) propõem uma nova estrutura para o modelo, através da transformada em Z, que reduz a instabilidade numérica e é parcimoniosa na identificação das ordenadas discretizadas do Hidrograma Unitário. Bárdossy et al (2006), considerando o número de incertezas relacionadas à própria concepção do modelo e à aquisição de dados, propõem uma nova abordagem para identificação do Hidrograma Unitário, onde as precipitações efetivas são consideradas uma série difusa (*fuzzy*) aplicada à integral de convolução, obtendo-se faixas de vazões difusas.

A metodologia denominada DPFT (Duband et al, 1993) é um método de identificação conjunta do Hidrograma Unitário (ou Função de Transferência) e das precipitações efetivas, cuja principal vantagem é fornecer como sub-produto uma série de precipitações efetivas que podem ser usadas na calibração a *posteriori* de modelos não-lineares de transformação de precipitações totais em precipitações efetivas, ou Funções de Produção.

Na abordagem sistêmica em hidrologia, modelos de equações de diferenças ou de equações diferenciais são usados para identificar uma relação entre entradas e saídas (ou precipitações e vazões), sem considerações detalhadas sobre a estrutura interna dos processos físicos que ocorrem na bacia hidrográfica. O modelo de série temporal linear ARMAX (Box et al, 1994) é um exemplo muito utilizado, porque é relativamente fácil de desenvolver e implementar. Mais recentemente, a modelagem sistêmica por redes neurais tem sido adotada com sucesso, comparando-se com a formulação ARMAX e outros modelos estocásticos lineares (Hsu *et al.*, 1995; Shamseldin, A. Y., 1997; Valença, M., 2005; Valença, M. e Ludermit, T., 2005).

O HIDROGRAMA UNITÁRIO E A METODOLOGIA DPFT

Esquemáticamente, o método do Hidrograma Unitário, aqui designado HU, propõe que, para uma dada bacia hidrográfica, a vazão é resultado de (figura 1):

1. Uma Função de Produção (FP) fortemente não-linear, que transforma a precipitação

total medida, média aritmética ou ponderada, (P), em precipitação efetiva (Pe), a qual produz o escoamento superficial. Esta transformação depende do tipo e uso do solo e das suas condições de umidade, antes do evento chuvoso.

2. Uma Função de Transferência linear, aqui designada FT, que é o próprio Hidrograma Unitário (H), que propaga ao longo do tempo a chuva efetiva Pe, para se obter a vazão superficial. A FT é apresentada aqui por suas ordenadas discretizadas H_i , conforme a equação (1).

$$Q_j = \sum_{i=1}^k H_i \cdot Pe_{j-i+1} \quad (1)$$

onde:

Q_j = vazão superficial no tempo j

H_i = ordenada discretizada da FT no tempo i

Pe_j = chuva efetiva no tempo j

k = número de ordenadas da FT ("memória" do sistema "bacia hidrográfica", em número de intervalos de tempo unitário)




Figura 1 – Transformação precipitação-vazão

O método do Hidrograma Unitário clássico exige que se conheçam previamente as precipitações efetivas, ou seja, uma regra de transformação da precipitação total em precipitação efetiva (Função de Produção). Conforme descrito em Duband et al (1993), Maia et al (2006) e Cruz (2007), ao contrário dessa abordagem clássica, a metodologia DPFT (Diferenças Primeiras da Função de Transferência), através de um processo iterativo, estima o Hidrograma Unitário e as precipitações efetivas, a partir de uma amostra de pares de observações de vazões e de precipitações totais (eventos precipitação-vazão).

Na metodologia DPFT trabalha-se com diferenças de vazão, ou seja:

$$q_j = Q_j - Q_{j-1} \quad (2)$$

e

$$h_i = H_i - H_{i-1} \quad (3)$$

onde q_j representa a variação da vazão no instante j e h_i são os coeficientes da DPFT.

O mecanismo da metodologia divide-se em 2 etapas (Cruz,2007):

1. Identificação do Hidrograma Unitário médio da bacia (ordenadas H_i) e das precipitações efetivas (Pe_j) para todos os eventos, utilizando-se a formulação ARMAX (equações 4 e 5) e a equação de deconvolução (equação 6) abaixo discriminadas.

$$q_t = -\sum_{i=1}^v c_i q_{t-i} + b_0 Pe_t + \sum_{i=1}^w b_i Pe_{t-i} \quad (4)$$

$$H(z^{-1}) = \frac{B(z^{-1})}{C(z^{-1})} \quad (5)$$

e

$$[Pe] = \left\{ [H^*]^T [H^*] \right\}^{-1} [H^*]^T [q] \quad (6)$$

onde q_t é a variação de vazão entre os intervalos de tempo t-1 e t; Pe_t é a chuva efetiva no tempo t; c_i , b_0 e b_i são os coeficientes de regressão múltipla da relação multilinear entre q_t e Pe_t ; z^{-1} é o operador "retardo"; B e C são polinômios formados pelos v coeficientes c_i e w coeficientes b_i e $[H^*]$ é uma matriz formada pelos coeficientes h_i da DPFT.

2. A etapa 2 da metodologia DPFT consiste na calibração de modelos de Função de Produção a partir dos pares precipitação total-precipitação efetiva calculada. As precipitações efetivas calculadas são aquelas obtidas na última iteração do algoritmo iterativo da metodologia, de acordo com a etapa 1. A calibração dos parâmetros dos modelos de Função de Produção é realizada, evento por evento, através da minimização do erro quadrático médio entre as precipitações totais (observadas) e as precipitações efetivas calculadas (Cruz,2007).

O MODELO DE FUNÇÃO DE PRODUÇÃO GR3

Estudos realizados por Cruz *et al* (2006) em bacias do Estado de Minas Gerais mostraram que um modelo simples de Função de Produção, tal como o modelo GR3, pode representar bem a transformação precipitação total-precipitação efetiva, motivo pelo qual esse modelo foi aqui adotado.

O modelo GR3 é um modelo empírico global desenvolvido por Edijatno e Michel (1989), com 2 parâmetros e intervalo de tempo diário. Foi desenvolvido com o objetivo de obter uma representação mais simples possível do processo precipitação-vazão. A figura 2 mostra o diagrama do modelo, adaptada de Nascimento (1995).

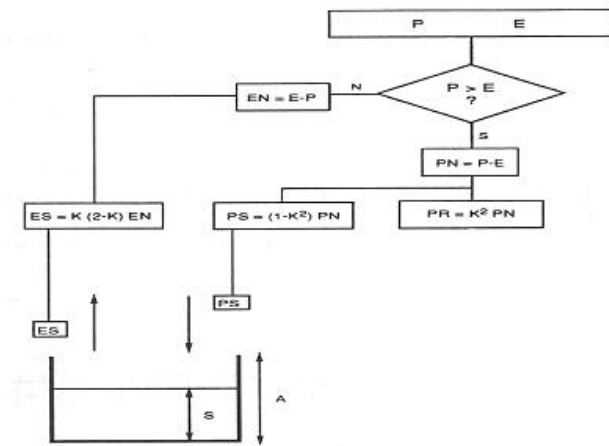


Figura 2 – Diagrama do modelo GR3 adaptado de Nascimento(1995).

O diagrama do modelo simboliza a condição de um reservatório onde é previsto o efeito de abatimento entre a precipitação P e a evapotranspiração E diárias, de modo que, com esta condição, haverá no modelo somente 1 entrada. Se $P \geq E$, a entrada será $P_n = P - E$; se $E > P$, a entrada será $E_n = E - P$, negativa e $P_n = 0$, onde P_n é a precipitação efetiva.

Os parâmetros a serem calibrados são A , que caracteriza a capacidade máxima do reservatório e S_1 , que simula a condição inicial de umidade média da bacia, para cada episódio considerado. O nível inicial do reservatório, S_1 , muda para o valor genérico S , conforme as ações de P_n ou de E_n , originando o valor $K = S/A$.

Na prática, os dois parâmetros calibráveis (S_1 e A) originam um único parâmetro $K = S_1/A$,

equivalente ao estado de umidade do solo, no início de cada evento precipitação-vazão.

A sequência de programas necessários para desenvolvimento e aplicação da metodologia DPFT foi desenvolvida pelos autores em códigos FORTRAN e MATLAB.

MODELOS DE REDES NEURAIS ARTIFICIAIS PARA A RELAÇÃO PRECIPITAÇÃO-VAZÃO

O modelo de neurônio artificial mais simples é o modelo MCP (McCulloch e Pitts, 1943, *apud* Braga *et al*, 2006), que é uma simplificação do que se conhece sobre o neurônio biológico. O modelo consta de n terminais de entrada, que recebem os valores x_1, x_2, \dots, x_n e somente um terminal de saída y_1 . Um arquitetura de rede mais aperfeiçoada pode apresentar m terminais de saída y_1, y_2, \dots, y_m como mostra figura 3. Para representar o comportamento das sinapses, os terminais de entrada do neurônio tem os respectivos pesos sinápticos w_1, w_2, \dots, w_n . A ativação do neurônio é obtida pela aplicação de uma função de ativação, que pode ativar ou não a saída, dependendo do valor da soma $x_i w_i$, comparada com um limiar de ativação do neurônio. Uma rede neural artificial (RNA) de uma camada tem a limitação de resolver apenas problemas lineares.

As não-linearidades são incorporadas em modelos neurais por intermédio de funções de ativação não-lineares para cada neurônio da rede e por uma composição estrutural em camadas sucessivas (Braga *et al*, 2006). À RNA de múltiplas camadas, composta por neurônios com funções de ativação sigmoidais nas camadas intermediárias dá-se o nome de *Multilayer Perceptron* (MLP's).

O treinamento de uma rede MLP é feito com exemplos (amostras de calibração dos pesos sinápticos) usando-se um algoritmo de retropropagação do erro (*backpropagation*) (Braga *et al*, 2006).

A figura 3 ilustra uma rede MLP típica, com uma camada intermediária (camada escondida).

A estrutura da rede mostrada na figura 3 mostra uma similaridade com o diagrama de transformação precipitação-vazão da figura 1. Na figura 3, as entradas x_i e as saídas y_i do sistema não-linear correspondem, respectivamente, às precipitações totais P_i e às vazões Q_i na bacia hidrográfica. Ao invés de se verificar primeiramente qual o melhor modelo não-linear de Função de Produção e depois

Tabela 1- Eventos de calibração e de validação

Rio das Velhas				Rio Abaeté			
Calibração	data	Validação	data	Calibração	data	Validação	data
1_HB	09/01/78	12_HB	19/12/89	1_A	17/02/70	11_A	09/03/73
2_HB	12/02/78	13_HB	09/01/92	2_A	31/01/79	12_A	04/12/74
4_HB	11/12/80	14_HB	19/01/92	3_A	14/02/79	13_A	11/01/78
6_HB	19/11/83	16_HB	22/12/94	4_A	13/02/80	14_A	09/02/83
7_HB	06/12/83	17_HB	12/12/95	5_A	10/01/81	15_A	13/02/86
9_HB	06/03/87	18_HB	23/12/95	6_A	20/01/82	16_A	19/03/91
10_HB	09/02/88	19_HB	07/01/96	7_A	29/02/92	17_A	05/03/94
11_HB	10/12/89			8_A	08/01/98	18_A	30/03/97
				9_A	07/03/99	19_A	17/12/00
				10_A	17/01/02	20_A	25/02/05

identificar-se o Hidrograma Unitário (linear) da bacia, a modelagem do processo precipitação-vazão por redes neurais artificiais considera a transformação direta (não-linear) entre as precipitações e as vazões observadas.




Figura 3 – Rede Neural MLP com uma camada escondida

O modelo estocástico ARMAX dado pela equação 4 é capaz de bem representar o comportamento de um sistema cujas características são aproximadamente lineares. Este comportamento pode ser simulado por uma versão simplificada de uma RNA com uma função de ativação linear sem uma camada escondida. No caso em estudo neste traba-

lho é de se esperar que uma rede MLP com uma camada escondida e função de ativação não-linear represente efetivamente as não-linearidades do processo estocástico precipitação-vazão.

Neste trabalho, o programa usado para aplicação das RNA foi o NeuroHidro (Valença,2005). A arquitetura de rede usada neste software é similar a de uma MLP, composta por blocos (NSRBN – *Non-linear Sigmoidal Regression Blocks Network*). É usado um algoritmo de retropropagação, que ajusta os pesos sinápticos entre a camada de entrada e a camada escondida, assim como entre a camada escondida e a de saída, através do método do gradiente descendente (Valença,2005).

O índice utilizado para comparação entre as metodologias foi o coeficiente de eficiência de Nash (Nash e Sutcliffe, 1970) dado pela equação 7.

$$F = 1 - \frac{\sum_{i=1}^n (Q_{calc} - Q_{obs})^2}{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}})^2} \quad (7)$$

Onde Q_{obs} é a vazão observada, Q_{calc} a vazão calculada pelo modelo e n o número de observações.

Área de Estudo e Calibração de Parâmetros dos Modelos

A figura 4 mostra a área de estudo, localizada no Estado de Minas Gerais. Dados de descarga média diária e de precipitação diária, para eventos precipitação-vazão intensos, isolados, foram usados

para calibração do Hidrograma Unitário médio das bacias e das precipitações efetivas. A precipitação média, para a bacia hidrográfica do rio das Velhas, foi estimada pelo método de Thiessen, usando-se dados de 4 estações, relativamente à estação fluviométrica de Honório Bicalho, onde a área da bacia é de 1.655 km², correspondente às nascentes do rio das Velhas, a montante da cidade de Belo Horizonte.

A segunda região estudada corresponde à bacia hidrográfica do rio Abaeté, afluente da margem esquerda do rio São Francisco, a jusante da represa de Três Marias, na estação fluviométrica Ponte BR-040, onde a área da bacia é de 5.320 km². A precipitação foi estimada por médias aritméticas de 7 estações pluviométricas. Neste caso, o método de estimativa por médias aritméticas foi usado por questão de disponibilidade de arquivos de dados já consistidos.

Para ambas as bacias estudadas, 2 amostras de eventos precipitação-vazão foram selecionadas: uma para calibração e outra para validação dos modelos analisados. A tabela 1 mostra a relação desses eventos, com as respectivas datas, para as bacias do rio das Velhas e do rio Abaeté. O critério de seleção de eventos chuva-vazão para as duas bacias baseou-se na escolha dos eventos de maior pico de vazão, presentes no histórico disponível, fornecido pela CEMIG (Companhia Energética de Minas Gerais), independentemente da data de ocorrência. Supõe-se que as amostras de calibração e de validação sejam representativas de eventos de vazão máxima.

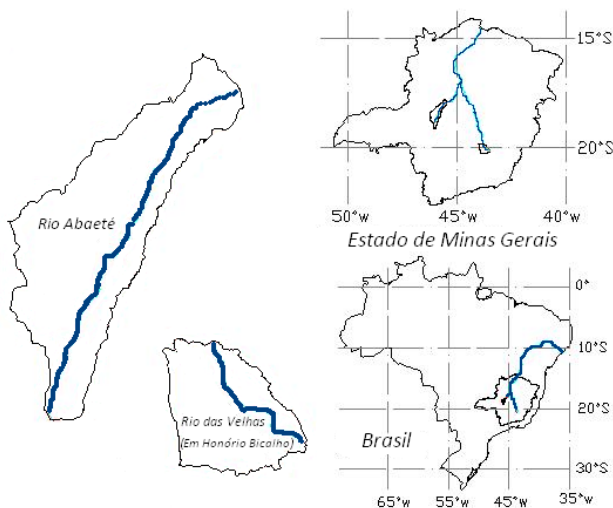


Figura 4 – Localização das bacias no estado de Minas Gerais

Por questão de convergência na calibração e validação do método DPFT, principalmente na bacia do rio das Velhas, onde se dispunham inicialmente de duas amostras de 10 eventos chuva-vazão, foi necessária a eliminação de alguns eventos, originando-se 8 eventos de calibração e 7 de validação, como mostra a tabela 1.

Hidrograma Unitário

De acordo com a etapa 1 da metodologia DPFT, foram calibrados os Hidrogramas Unitários (adimensionais) para as 2 bacias analisadas, que são apresentados nas figuras 5 e 6.




Figura 5-Hidrograma Unitário adimensional do Rio das Velhas




Figura 6-Hidrograma Unitário adimensional do Rio Abaeté

Função de Produção

Na ausência de dados de evapotranspiração para os eventos respectivos do histórico de vazões disponível para as duas bacias, adotou-se um valor de evapotranspiração diária de 5 mm para todos os eventos.

De acordo com a etapa 2 da metodologia DPFT, os resultados encontrados na calibração dos parâmetros $k=S_1/A$ do modelo GR3, para os eventos precipitação-vazão nas duas bacias são dados na tabela 2.

Tabela 2- Parâmetros S_1/A calibrados

Evento	Rio das Velhas	Evento	Rio Abaeté
	S_1/A		S_1/A
1_HB	0.33	1_A	0.01
2_HB	0.29	2_A	0.51
4_HB	0.24	3_A	0.42
6_HB	0.38	4_A	0.52
7_HB	0.41	5_A	0.36
9_HB	0.19	6_A	0.59
10_HB	0.40	7_A	0.46
11_HB	0.17	8_A	0.27
-	-	9_A	0.01
-	-	10_A	0.17

Os valores médios dos parâmetros obtidos para o modelo GR3, que serão usados posteriormente para validação dos modelos são: $S_1=298$ mm, $A=946$ mm, ($S_1/A = 0.32$), e $S_1=364$ mm, $A=794$ mm, ($S_1/A = 0.46$), respectivamente para as bacias do rio das Velhas e do rio Abaeté.

Validação metodologia DPFT e dos modelos de Redes Neurais Artificiais e comparação dos métodos

Dispondo-se dos Hidrogramas Unitários respectivos das duas bacias, obtidos pela metodologia DPFT, para os eventos de calibração (tabela 1) e dos valores médios de S_1/A da tabela 2, foi possível portanto calcular as respectivas chuvas efetivas, a partir das chuvas totais, para cada evento de validação, e, através da equação (1) de convolução, obte-

rem-se as vazões calculadas de previsão, para a amostra de validação.

Analogamente à equação 4 (modelos AR-MAX), em termos de redes neurais, a vazão no instante t (Q_t) corresponde aos neurônios da camada de saída (y_t), enquanto as vazões e precipitações concomitantes e anteriores correspondem aos neurônios da camada de entrada da rede neural artificial ($x_t, x_{t-1}, x_{t-2}, \dots$), como mostrado na figura 3.

Para os eventos precipitação-vazão das amostras de validação, referentes respectivamente às bacias do rio das Velhas e Abaeté, foram previstas as vazões, utilizando-se os melhores modelos de redes neurais das amostras de calibração, do ponto de vista do coeficiente de Nash.

Foi feita uma comparação de 3 tipos de modelos de redes neurais (respectivamente com 10, 6 e 4 neurônios) e o melhor resultado foi obtido usando-se o modelo de 4 neurônios, que corresponde à rede com camada de saída com 1 neurônio (Q_t) e camada de entrada com 3 neurônios (Q_{t-1}, P_t, P_{t-1}).

Conforme Valença (2005), alguns aspectos relacionados ao treinamento das redes neurais, usando-se o software NeuroHidro, são: (i) cada evento chuva-vazão é dividido em 3 sub-conjuntos: um sub-conjunto que é responsável pelo ajuste dos pesos sinápticos da rede neural (treinamento), um sub-conjunto para validação cruzada, cuja função é determinar o ponto de parada do treinamento da rede, para que essa não perca a sua capacidade de generalização, e o sub-conjunto de verificação (para a rede já treinada), que serve para avaliar o desempenho do modelo empregado; (ii) alguns parâmetros importantes nos processos de treinamento são: taxa de aprendizagem, que está diretamente relacionada com o incremento dos pesos sinápticos durante o processo de aprendizagem (treinamento) e o fator momentum, que tem por objetivo minimizar a possibilidade de o algoritmo ficar preso a mínimos locais; (iii) a função de ativação usada na calibração dos pesos sinápticos é a sigmoideal.

Em seguida foram comparadas as duas metodologias, ou seja, a metodologia DPFT (Hidrograma Unitário com modelo de Função de Produção GR3), com o modelo de Redes Neurais Artificiais com 4 neurônios. A tabela 3 mostra os valores do coeficiente de Nash referentes às amostras de previsão para as duas bacias estudadas.

As figuras 7 e 8 mostram, respectivamente para as bacias dos rios das Velhas e Abaeté, as vazões observadas e previstas, usando-se a metodologia DPFT, com modelo GR3, e o modelo de RNA com 4 neurônios.

Tabela 3-Comparação entre os coeficientes de Nash (F) do modelo de RNA e metodologia DPFT, com o modelo de função de produção GR3 – Previsão.

Eventos	Rio das Velhas		Eventos	Rio Abaeté	
	RNA	DPFT		RNA	DPFT
13_HB	0.7228	0.6108	11_A	0.4518	0.7259
14_HB	0.7479	0.8104	12_A	0.2954	0.7678
16_HB	0.3425	-1.8113	13_A	0.6012	0.8321
17_HB	0.7967	0.7989	14_A	0.6691	0.7105
18_HB	0.1414	0.4782	15_A	0.6639	0.7379
19_HB	0.4890	0.2415	16_A	0.6524	-2.7528
-	-	-	17_A	0.2287	0.0530
-	-	-	18_A	0.4248	-0.7360
-	-	-	19_A	0.7827	0.8826
-	-	-	20_A	0.3273	-0.6265

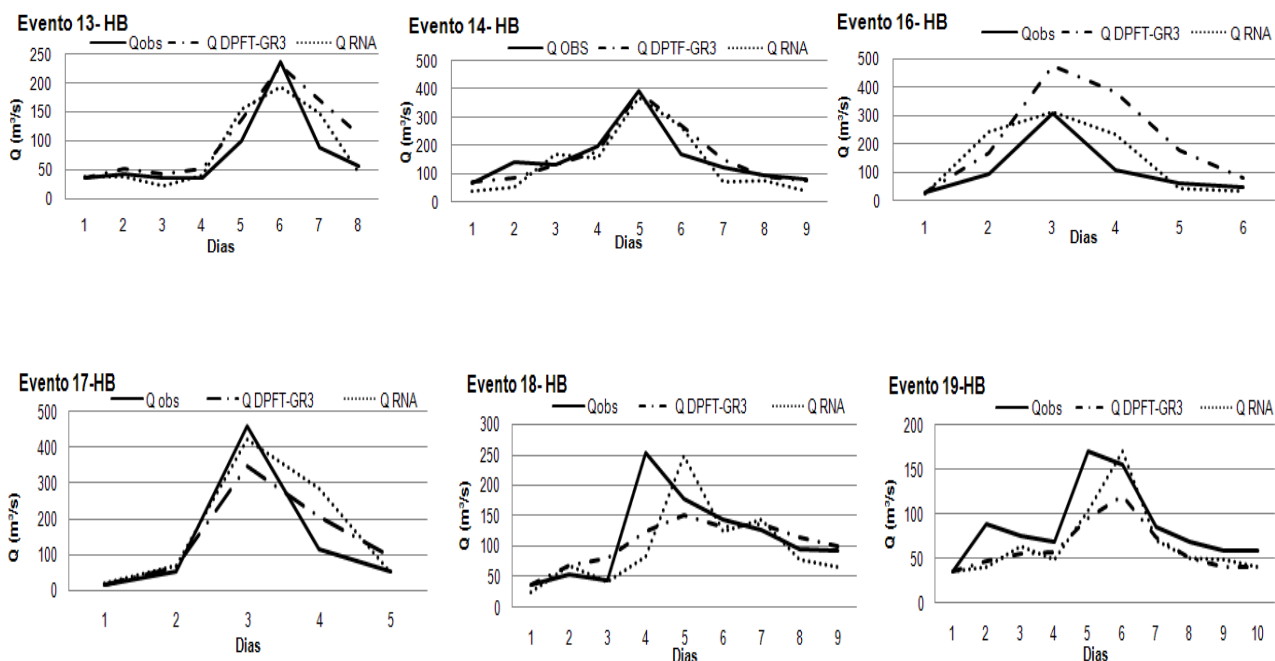


Figura 7 – Vazões observadas e previstas utilizando o método DPFT (com a função de Produção GR3) e o modelo de Redes Neurais Artificiais - Rio das Velhas.

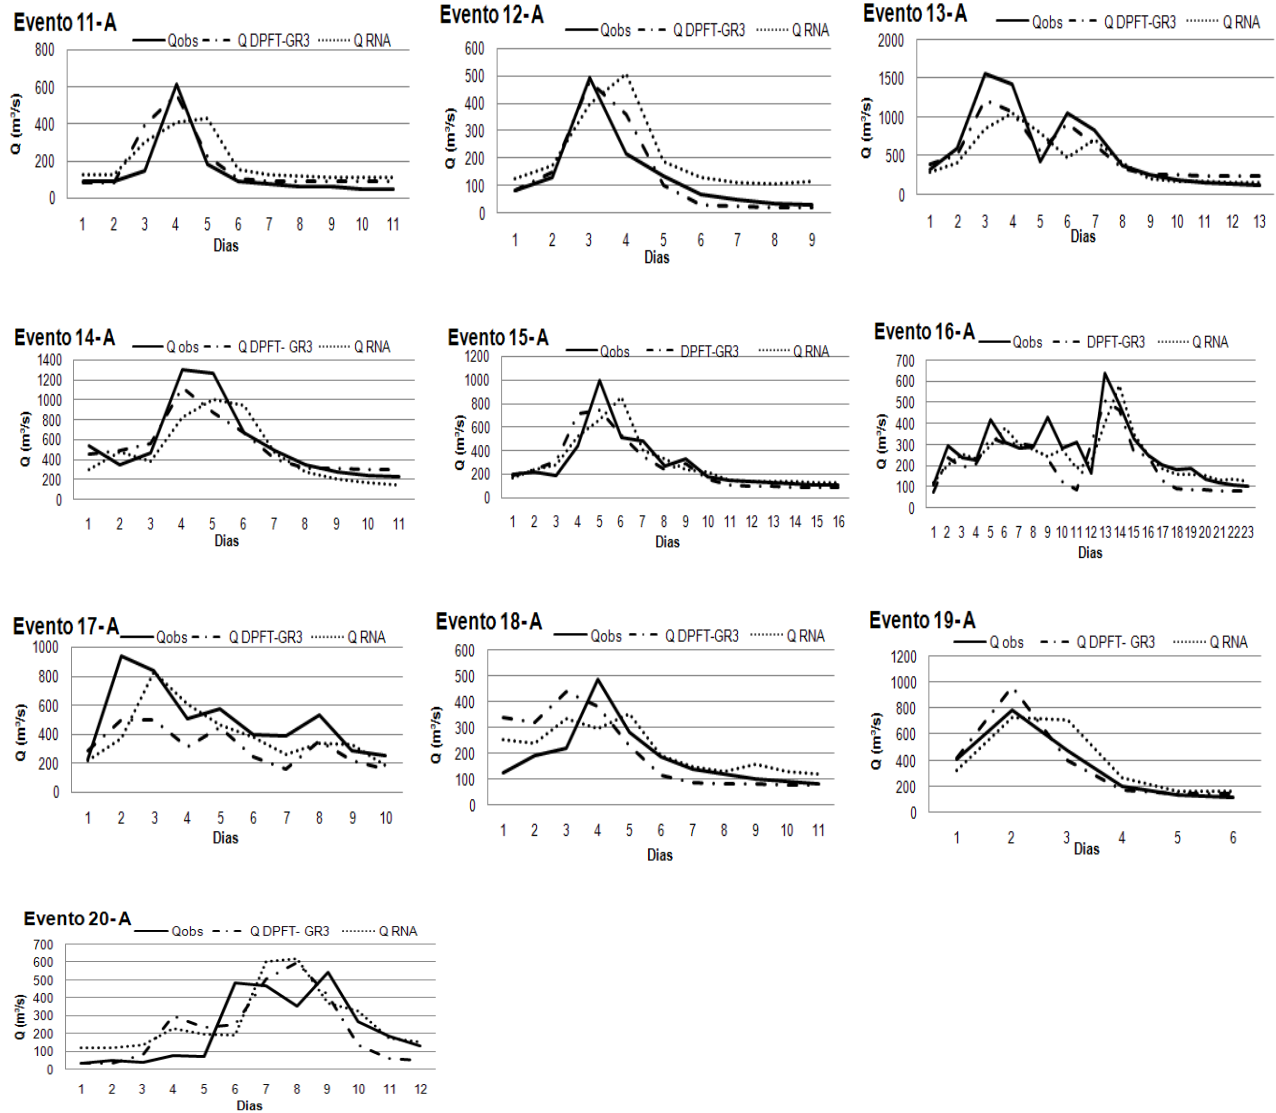


Figura 8 – Vazões observadas e previstas utilizando o método DPFT (com a função de Produção GR3) e o modelo de Redes Neurais Artificiais – Rio Abaeté

Para estes resultados do estudo de caso, destacam-se os seguintes comentários:

- De acordo com as figuras 5 e 6, verifica-se que, para ambas bacias, o tempo de resposta às precipitações é bastante rápido, pois os picos dos respectivos Hidrogramas Unitários ocorrem no primeiro dia ($t=1$), para tempos de base entre 3 e 4 dias.
- Os valores médios dos parâmetros calibrados do modelo GR3 ($S_1/A = 0.32$ e $S_1/A = 0.46$), respectivamente para as bacias dos rios das Velhas e Abaeté correspondem a estados de umidade inicial dos solos relativamente baixa; estes valores usados na previsão forneceram bons ajustes aos valores iniciais das vazões, exceto para o evento 18_A, onde as vazões iniciais foram superestimadas (figuras 7 e 8).

- Alguns autores (Coulibaly *et al*, 2000) recomendam o valor limite inferior do coeficiente de Nash igual a 0,70 para estabelecimento da qualidade do ajuste de modelos. De acordo com a tabela 3 e as figuras 7 e 8, para o rio das Velhas, comparando-se os resultados em previsão, do total de 6 eventos, $F > 0,70$ para 3 eventos (RNA) e para 2 eventos (método DPFT); para o rio Abaeté, do total de 10 eventos, $F > 0,70$ para 6 eventos (método DPFT) e 1 evento (RNA). Pode-se observar que os resultados são similares no caso da bacia do rio das Velhas, mas os resultados obtidos com a metodologia DPFT são melhores do que os obtidos com o modelo de redes neurais, no caso do rio Abaeté. Entretanto, em termos de valores médios do coeficiente de Nash, verifica-se que, para os 10 eventos da bacia do Abaeté, temos, respectivamente para os modelos de RNA e DPFT, 0,51 e 0,06; e para os 6 eventos da bacia do rio das Velhas, temos respectivamente para os modelos de RNA e DPFT, 0,54 e 0,19. Em termos de valores de *desvio padrão*, respectivamente para os rios das Velhas e Abaeté, temos 0,26 e 0,19 para RNA, contra 1,00 e 1,16 para DPFT. Estes resultados relativos à média e desvio padrão mostram uma maior dispersão de resultados para a metodologia DPFT, sendo que a RNA obteve uma maior regularidade de resultados, o que por vezes é mais importante na ótica da confiabilidade do modelo.
- No caso do modelo de RNA, principalmente para o rio Abaeté, as previsões apresentam defasagem de um dia, apesar dos valores dos picos de vazão observada e calculada serem, em alguns casos, aproximadamente os mesmos.
- Para o rio das Velhas, os melhores ajustes foram para os eventos 14_HB (DPFT, com $F=0,81$) e 17_HB (RNA, com $F=0,80$); para o rio Abaeté, os melhores ajustes foram para o evento 19_A (DPFT, com $F=0,88$ e RNA, com $F=0,78$).

CONCLUSÕES

Este trabalho apresentou a comparação de dois métodos globais de previsão de vazões, aplicados a 2 bacias hidrográficas de médio porte, locali-

zadas no Estado de Minas Gerais, onde somente dados diários de precipitação e de vazão, relativos a eventos intensos, são disponíveis.

O primeiro procedimento utilizado é baseado no método do Hidrograma Unitário, mas aqui apresentado através de uma abordagem alternativa, a metodologia DPFT, proposta nos anos 1980. A principal vantagem desta metodologia é que ela permite o estudo de modelos de Função de Produção, sem se impor *a priori* a transformação não-linear entre a precipitação total e a precipitação efetiva na bacia hidrográfica. Adotou-se como Função de Produção um modelo mais simples possível, com um parâmetro calibrável. Os resultados alcançados na fase de validação (previsão das vazões), para as duas bacias analisadas mostram desempenho bastante satisfatório, considerando-se as hipóteses básicas de aplicação do método do Hidrograma Unitário. Estas hipóteses referem-se à uniformidade espacial da precipitação sobre toda a bacia, ou que, a precipitação média seja uniformemente distribuída sobre a região. Esta é a principal limitação dos modelos concentrados globais, pois é evidente que, para grandes bacias, esta hipótese não é mais válida. Destaque-se também que o Hidrograma Unitário determinado pelo método DPFT é um hidrograma unitário *médio*, pois foi estimado a partir de uma amostra de eventos precipitação-vazão isolados. Se, por acaso, nesta amostra de calibração houver algum evento de precipitação não uniformemente distribuído sobre a bacia, ou muito heterogêneo, as respectivas precipitações efetivas estimadas pelo método (pela equação 6, de deconvolução) não serão representativas, comprometendo-se assim a segunda etapa do método, ou seja, a calibração do modelo de Função de Produção.

O segundo procedimento utilizado, com o objetivo de comparação com a metodologia DPFT, é baseado numa classe de modelos caixa-preta, empregando-se redes neurais artificiais. A arquitetura de rede utilizada é baseada numa rede MLP, com 1 camada escondida e função de ativação não linear, para representação das não-linearidades do processo precipitação-vazão. Entre os modelos de redes neurais analisados, verificou-se que um modelo de 4 neurônios (3 entradas e 1 saída) mostrou melhor desempenho.

Finalmente, considerando-se os critérios de Nash e ajustes gráficos das vazões calculadas às observadas, a análise das figuras 7 e 8 e da tabela 3 permite concluir que, neste estudo de caso, ambas as metodologias demonstraram resultados satisfatórios em previsão, levando-se em conta a escassez de informação hidrológica disponível em cada bacia

hidrográfica e as limitações relacionadas à simplificação dos processos hidrológicos, evidenciada pela utilização de um modelo de Função de Produção com somente 1 parâmetro. Ao verificarmos esses resultados, em termos de número de eventos com boa reconstituição em previsão, a metodologia DPFT apresentou aparentemente um desempenho ligeiramente superior ao modelo de redes neurais artificiais. Mas analisando-se globalmente para o conjunto de eventos, para cada bacia, percebe-se uma maior dispersão de valores do coeficiente de Nash, o que mostra menor regularidade de resultados, comparando-se com o modelo de RNA. Estas conclusões referem-se evidentemente aos casos particulares das duas bacias analisadas, sugerindo-se estudos futuros, para maior número de casos.

AGRADECIMENTOS

Os autores agradecem à CEMIG (Companhia Energética de Minas Gerais) pelo fornecimento de dados hidrológicos e à CAPES, CNPq e FAPEMIG pelo apoio ao desenvolvimento deste trabalho, através de bolsas de mestrado, pesquisa e iniciação científica. Agradecem também aos revisores anônimos, que, através de suas correções e sugestões, contribuíram para a qualidade final do artigo.

REFERÊNCIAS

- BÁRDOSSY, A.; MASCELLANI, G. e FRANCHINI, M. (2006). Fuzzy unit hydrograph, *Water Resources Research*, v.42., n.2.
- BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C. (1994). *Time Series Analysis, Forecasting and Control* – Prentice Hall, Inc., 3ª ed., USA.
- BRAGA, A.P.; CARVALHO, A.P.L.F. e LUDERMIR, T.B. (2006). *Redes Neurais Artificiais: Teoria e Aplicações* – Ed. UFMG, Universidade Federal de Minas Gerai, 1ª ed., Belo Horizonte.
- BURNASH, R. J. E.; FERRAL, R. L. e McGUIRE, R. A. (1973). A generalized streamflow system, *Rep. 220, Jt. Fed.-State River Forecast. Cent.*, Sacramento, California.
- COULIBALY, P.; ANCTIL, F. e BOBÉE, B. (2000). Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, **230**, 244-257.
- COLLISCHONN, W. e TUCCI, C.E.M. (2003). Ajuste Multiobjetivo dos Parâmetros de um Modelo Hidrológico. *Revista Brasileira de Recursos Hídricos*, **8**(3), 27-39.
- CRAWFORD, N. H. e LINSLEY, R. K. (1966). Digital simulation in hydrology: Stanford Watershed Model IV, *Tech. Rep. 39, Dep. Of Civ. Eng., Stanford Univ.*, Stanford, California.
- CRUZ, M. F. M.; (2007). *Análise de Modelos de Função de Produção Identificados pela Metodologia DPFT: aplicação para bacias do alto São Francisco, em Minas Gerais. Dissertação de Mestrado. UFMG, Belo Horizonte*.
- CRUZ, M. F. M.; CUNHA, B. T. A. e VERSIANI, B. R. (2006). *Análise de Modelos de Função de Produção Identificados pela Metodologia DPFT: aplicação para bacias do alto São Francisco, em Minas Gerais. Anais, I Simpósio de Recursos Hídricos do Sul- Sudeste- Curitiba*.
- DOOGE, J.C.I. (1959). A general theory of the unit hydrograph, *Journal of Geophysical Research*. **64**(1), 242-256.
- DOOGE, J.C.I. (1973). The linear theory of hydrologic systems. *US Dept. of Agriculture Tech. Bull.*, 1468.
- DUBAND, D.; OBLED, C. e RODRIGUEZ, J.Y. (1993). Unit hydrograph revisited: an alternative approach to UH and effective precipitation identification. *Journal of Hydrology*, **150**, 115-149.
- EDIJATNO; MICHEL, C. (1989). Un modèle plui-débit journalier à trois paramètres, *La Houille Blanche*, **2**, 113-121.
- HSU, K.; GUPTA, H.V. e SOROOSHIAN, S. (1995). Artificial neural network modeling of the rainfall-runoff process, *Water Resources Research*, v.31, n. 10, 2517-2530.
- MAIA, A.L.; AMARAL, I.R. e VERSIANI, B.R. (2006). Metodologia DPFT de identificação do Hidrograma Unitário e das Precipitações Efetivas: Estudo de caso para a bacia hidrográfica de Juatuba – MG. *Revista Brasileira de Recursos Hídricos*, **11**(1), 79-90.
- McCULLOCH, W.S. e PITS, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115-133.
- NASCIMENTO, N.O. (1995). *Appréciation à l'aide d'un modèle empirique des effets d'actions anthropiques sur la relation pluie-débit à l'échelle d'un bassin versant*. PhD thesis, École Nationale des Ponts et Chaussées, France.
- NASH, J. E. (1957). The form of instantaneous unit hydrograph, *Hydrologica Sciences Bulletin*. **3**, 114-121.
- NASH, J. E. e SULCLIFFE, J.V.:(1970) River flow forecasting through conceptual models, 1.A discussion of principles, *J. Hydrology* 10, 282-290.
- O'CONNELL, P. E. e CLARKE, R. T. (1981). Adaptive hydrological forecasting – a review, *Hydrol. Sci. Bull.*, **26**(2), 179-205.

- PILGRIM, D. H. (1976). Travel times and nonlinearity of flood runoff from tracer measurements on a small watershed, *Water Resources Research*, 12(3), 487-496.
- SHAMSELDIN, A.Y. (1997). Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology*, **199**, 272-294.
- SHERMAN, L. K. (1932). Stream flow from rainfall by the unit-hydrograph method. *Eng. News. Rec.*, **108**, 801-805.
- SINGH, V. P. (1964). Non-linear instantaneous unit hydrograph theory, *J. Hydraulic. Soc. Civ. Eng.*, 90(HY2), 313-347.
- SOROOSHIAN, S. (1983). Surface water hidrology: on-line estimation, *Rev. Geophys.*, 21(3), 706-721.
- TUCCI, C. E. M. (2005). Modelos Hidrológicos. Editora da UFRGS. 2ª edição.
- YANG, Z. e HAN, D. (2006). Derivation of unit hydrograph using a transfer function approach, *Water Resources Research*, v.42, n. 1.
- YOUNG, P. e WALLIS, S. (1985). Recursive estimation: a unified approach to the identification, estimation and forecasting of hydrological systems, *Applied Math. Comput.*, 17, 299-334.
- VALENÇA, M. (2005). *Aplicando Redes Neurais: um guia completo*. Ed. do Autor, 1ª ed., Olinda, Pernambuco.
- VALENÇA, M. e LUDERMIR, T. (2005). Neurodiário – um modelo multivariado para previsão de vazões médias diárias, in *Anais do XVI Simpósio Brasileiro de Recursos Hídricos*, João Pessoa (Paraíba).

application and comparison of the methods in two medium sized watersheds are presented and analysed. In this study case, the DPFT methodology showed a slightly better fitting than the ANN model, despite more irregular results.

Keywords: rainfall-runoff modeling, methodology DPFT, artificial neural networks.

Predicting Floods With the DPFT Methodology and With Artificial Neural Networks

ABSTRACT

The comparison of two flood forecasting methodologies, using models with few parameters to calibrate is presented. In DPFT method (First Differences of the Transfer Function) one uses a multi-events rainfall-runoff set and an iterative algorithm for the simultaneous identification of the average Unit Hydrograph (Transfer Function) of the watershed and of a series of effective precipitations associated to each event. This last particularity allows to the calibration and comparison of different Loss Function models, relating observed precipitations to calculated effective precipitations identified by the methodology. In this case a simple Loss Function model is used, the GR3 model. The DPFT methodology is compared with a simple Artificial Neural Network (ANN) model approach, where the non-linearities inherent to the rainfall-runoff process are represented by a MLP structure with 4 neurons concerning to the discharges and the precipitations. The results of