

Modelagem do processo chuva-vazão pelo Tank Model e por redes neurais artificiais na bacia do rio Japarutuba, Sergipe

A. B. Celeste¹; T. L. A. Menezes¹; V. A. Fontes¹

¹Departamento de Engenharia Civil, Universidade Federal de Sergipe, 49.100-000, São Cristóvão – SE, Brasil

geimes@yahoo.com

(Recebido em 28 de janeiro de 2014; aceito em 22 de julho de 2014)

Este artigo trata da aplicação da modelagem conceitual do Tank Model e da empírica das redes neurais artificiais para simular o processo chuva-vazão na bacia hidrográfica do rio Japarutuba, Sergipe. Uma configuração com quatro tanques e onze tipos de redes neurais são testados. Os resultados indicam que sete modelos neurais são mais eficientes do que o Tank Model, mas que este também obtém desempenho satisfatório.

Palavras-chave: modelagem chuva-vazão, Tank Model, redes neurais artificiais.

Modeling the rainfall-runoff process by the Tank Model and artificial neural networks in the Japarutuba river basin, Sergipe

This paper deals with the application of the conceptual Tank Model and the data-driven artificial neural networks approaches to simulate the rainfall-runoff process in the catchment area of the Japarutuba river, Sergipe. A four-tank setup and eleven types of neural networks are tested. The results indicate that seven neural models are more efficient than the Tank Model, but that the latter also achieves suitable performance.

Keywords: rainfall-runoff modeling, Tank Model, artificial neural networks.

1. INTRODUÇÃO

A implantação de obras hidráulicas requer estudos de viabilidade e de planejamento de modo que os sistemas atendam, de forma satisfatória, às demandas atuais e futuras durante sua vida útil. Algo que se faz necessário conhecer nesses estudos são dados sobre o comportamento hidrológico da bacia hidrográfica na qual o empreendimento será estabelecido, tais como vazões mínimas para avaliar capacidade de recebimento de efluentes, vazões médias para dimensionar reservatórios e vazões máximas para projetar sistemas de segurança de barragens.

De acordo com a Agência Nacional de Águas (ANA), o monitoramento hidrometeorológico no Brasil é realizado desde o início do século XIX e hoje conta com mais de 9000 estações fluviométricas cadastradas [1]. No entanto, os registros frequentemente apresentam falhas e/ou poucos períodos de medição. Falhas são períodos sem informações ou com dados incorretos ou duvidosos que ocorrem em virtude de problemas com equipamentos ou por falta de monitoramento. Séries curtas e com falhas possuem pouca representatividade do comportamento hidrológico do curso d'água em estudo, o que pode influenciar no dimensionamento e na operação de um sistema que fará uso desta água.

Uma das formas de preencher falhas e alongar séries fluviométricas curtas é recorrer a mecanismos que relacionam os dados de vazão com os de precipitação. Tais mecanismos são chamados de modelos chuva-vazão. Uma vez que as séries de chuva são normalmente mais longas do que as de vazão [2], um modelo chuva-vazão pode ser ajustado aos dados existentes e posteriormente utilizado para estimar os deflúvios faltosos a partir da precipitação.

A modelagem do processo chuva-vazão representa um problema não-linear complexo e na literatura especializada há várias aproximações para resolvê-lo. Dois dos inúmeros modelos computacionais mais conhecidos são o pioneiro *stanford watershed model*, desenvolvido na Universidade de Stanford (EUA) e o SSARR (*streamflow synthesis and reservoir regulation*), do Corpo de Engenheiros do Exército Americano [3]. No Brasil, também já foram concebidos vários modelos com o mesmo propósito, como o SMAP (*soil moisture accounting procedure*)

[4], o MOHTSAR (modelo hidrológico para o trópico semi-árido) [5] e o MODHAC (modelo hidrológico auto-calibrável) [6].

Outro modelo bastante conhecido é o *Tank Model*, desenvolvido no Japão [7], que representa o regime de escoamento da bacia hidrográfica através de uma série de tanques. Uma vantagem do Tank Model é não precisar de informações mais elaboradas sobre a bacia em estudo tais como propriedades do solo, vegetação, etc. Os dados necessários são apenas precipitação, evapotranspiração e deflúvio, sendo, portanto, um modelo relativamente simples em comparação com os demais.

Grande parte dos modelos chuva-vazão já desenvolvidos são do tipo conceitual, que dependem da compreensão dos processos hidrológicos envolvidos e requerem profundo conhecimento intrínseco das características físicas da bacia hidrográfica. Os modelos mencionados acima são deste tipo. Nos últimos anos, a literatura vem dando importância também a modelos empíricos do tipo “caixa preta”, ou guiados por dados (DDM: *data-driven models*) que ajustam os dados de entrada e saída através de funções que não têm, necessariamente, relação com os processos físicos envolvidos [8,9]. Dentre os vários tipos de DDMs, redes neurais artificiais (RNAs) são os mais populares [10-14]. RNAs têm sido largamente aceitas e utilizadas na modelagem de sistemas não-lineares complexos com grande quantidade de informações, inclusive com dados ruidosos [15].

Este trabalho aplica e verifica a eficiência da modelagem conceitual do Tank Model e da empírica das redes neurais artificiais para representar o processo chuva-vazão na bacia hidrográfica do rio Japarutuba, localizada no estado de Sergipe. Os resultados são confrontados entre si e também com os disponibilizados pela Secretaria de Estado de Meio Ambiente e dos Recursos Hídricos de Sergipe (SEMARH-SE) que, para a elaboração do Plano Estadual de Recursos Hídricos (PERH-SE) [16], utilizou o modelo conceitual MODHAC [6] a fim de simular a transformação chuva-vazão em todas as bacias hidrográficas do estado.

2. MATERIAIS E MÉTODOS

2.1. Tank Model utilizado e processo de calibração

O Tank Model é um modelo para estimativa da vazão do curso d'água a partir dos dados de precipitação. O seu princípio [7] é substituir a bacia de drenagem da seção do rio por vários tanques de cada um dos quais a descarga q é assumida proporcional à altura d'água a partir da posição h do orifício lateral (Figura 1):

$$q = \alpha(X - h) \quad (\text{eq.1})$$

onde X é o nível de água no tanque e α é a constante de proporcionalidade.

A precipitação P é adicionada ao tanque superior e a evapotranspiração ET é subtraída de todos os tanques. A água em cada tanque é parcialmente descarregada pelas saídas laterais e percola através do fundo para os tanques inferiores. A percolação z também é proporcional ao nível do tanque, sendo β a constante de proporcionalidade:

$$z = \beta X \quad (\text{eq.2})$$

Neste trabalho, após algumas simulações iniciais, foi escolhida uma configuração final com quatro tanques em série na qual o tanque superior possui dois orifícios laterais, os dois tanques seguintes possuem apenas um orifício lateral e o tanque inferior não apresenta orifício de fundo (i.e., percolação profunda) nem seu orifício lateral possui altura em relação ao fundo (Figura 1).

A soma das vazões de todos os orifícios laterais dos tanques equivale à descarga Q a ser calculada que, neste caso, é:

$$Q = \sum_{i=1}^5 q_i \quad (\text{eq.3})$$

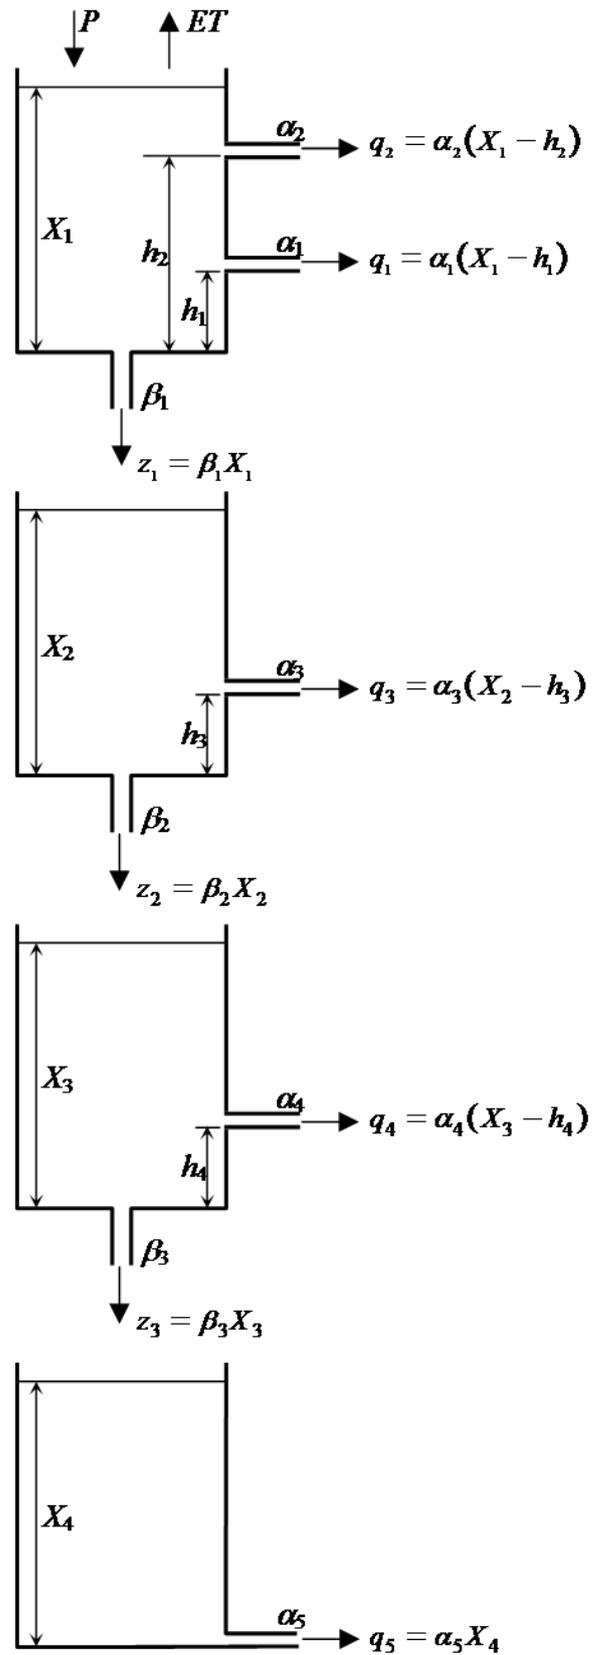


Figura 1: Configuração do Tank Model utilizado.

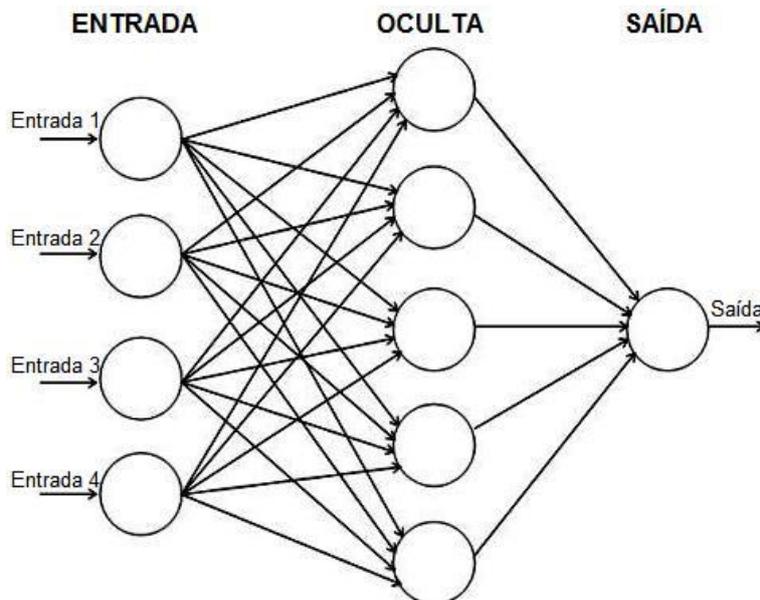


Figura 2: Rede neural do tipo feedforward.

O conjunto de tanques pode ser assumido como uma representação dos aquíferos de uma bacia, onde a água de chuva percola dos aquíferos superiores para os inferiores e a descarga de cada aquífero contribui para a vazão do rio [17].

Os parâmetros que necessitam de calibração são as constantes de proporcionalidade α e β e as alturas dos orifícios laterais h . Neste trabalho, a calibração foi realizada em escala diária com o objetivo de minimizar a soma do quadrado das diferenças entre vazões simuladas e observadas. Para essa tarefa, utilizou-se o algoritmo *Shuffled Complex Evolution – University of Arizona* (SCE-UA) desenvolvido por Duan et al. [18]. O SCE-UA é um algoritmo de otimização global desenvolvido para lidar com vários problemas encontrados na calibração de modelos não lineares, particularmente com a multimodalidade das funções encontradas em modelos chuva-vazão conceituais. O método combina a estratégia de otimização determinística de Nelder-Mead (*downhill simplex method*) com a estocástica dos algoritmos genéticos.

2.2. Rede neural utilizada e processo de calibração

Redes neurais artificiais são sistemas computacionais capazes de estabelecer relações não lineares entre dados de entrada e saída de um sistema. Esse mapeamento é conduzido por elementos que funcionam como neurônios artificiais, pois recebem uma série de informações, processam-nas e produzem uma saída, assim como as células do tecido nervoso humano. Existem muitos modelos de RNAs e, neste estudo, foi utilizado um modelo com treinamento supervisionado e estrutura *feedforward* com três camadas: entrada, intermediária (ou oculta) e saída (Figura 2). O número de neurônios da camada de entrada depende da quantidade de atributos de períodos passados (chuva, vazão, etc.) usados para prever a vazão do próximo período. O número de neurônios da camada oculta é determinado fazendo simulações e verificando a melhor combinação de resultados. Por último, a camada de saída tem um único neurônio representando a vazão a ser estimada. Na rede *feedforward*, os neurônios de uma mesma camada não são conectados entre si.

A Figura 3 mostra como funciona um neurônio na camada oculta. Cada elemento do vetor de entrada está conectado a cada neurônio na camada oculta e cada elemento da camada oculta está conectado ao neurônio de saída. Nota-se que o i -ésimo neurônio da camada oculta possui um somatório que coleta o valor de entrada multiplicado pelo peso de sua conexão (w_{ij}) e o *bias* (b_i) para formar o valor de saída ou campo local induzido (m_i). Cada campo local induzido é

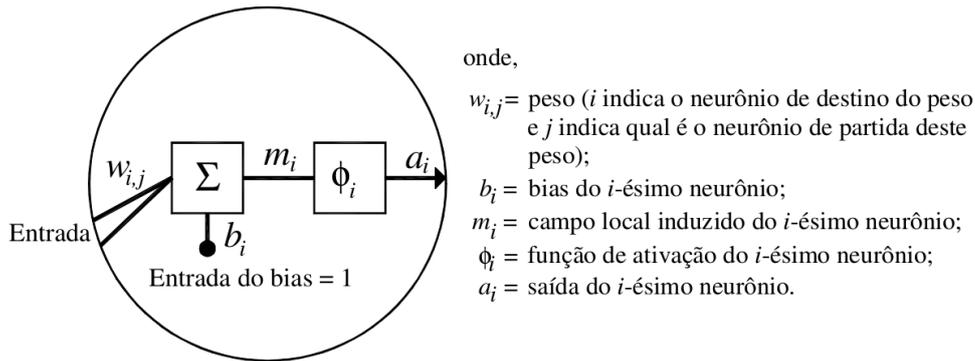


Figura 3: Configuração de neurônio na camada oculta de uma RNA. (Fonte: Farias et al. [2]).

submetido a uma função de ativação (ϕ_i) para que se torne o valor de entrada do neurônio da camada de saída. O neurônio da camada de saída possui o mesmo esquema dos neurônios da camada oculta e o seu campo local induzido, depois de submetido à função de ativação, torna-se a saída final da RNA, ou seja, o valor da vazão a ser prevista [10].

Neste trabalho, RNAs foram utilizadas para a modelagem mensal do processo chuva-vazão. A aplicação foi conduzida por meio do software NeuroHidro [19] que utiliza uma arquitetura constituída com base em redes compostas por blocos de regressões sigmóides não-lineares (NSRBN: *nonlinear sigmoidal regression blocks networks*). Redes neurais do tipo NSRBN possuem uma poderosa capacidade de mapeamento no sentido de que qualquer função contínua definida em um conjunto compacto do espaço multidimensional pode ser uniformemente aproximada [19]. O NeuroHidro realiza o treinamento da rede (ajuste dos pesos) por meio do reconhecido algoritmo *backpropagation*, modificado para minimizar a influência dos valores iniciais dos pesos.

Como indicado por Valença [19], a sazonalidade dos dados mensais foi considerada por meio de dois neurônios com funções seno e cosseno, compreendendo duas entradas adicionais na rede neural. Utilizaram-se as seguintes expressões:

$$\begin{cases} \text{Neurônio 1} = \text{sen } 2\pi \left(\frac{N}{12} \right) \\ \text{Neurônio 2} = \text{cos } 2\pi \left(\frac{N}{12} \right) \end{cases} \quad (\text{eq.4})$$

onde N varia de 1 (janeiro) até 12 (dezembro).

Para realizar o treinamento da rede neural e avaliar o seu desempenho, é preciso dividir os dados em três subconjuntos [19]:

1. Treinamento: serve para ajustar os pesos da rede neural. Adotou-se 60% da amostra.
2. Validação Cruzada: serve para informar quando se deve parar de treinar a rede neural de forma a evitar que ela perca a sua capacidade de generalização. Adotou-se 20% da amostra.
3. Verificação: serve para avaliar o desempenho do modelo, sendo utilizado após a rede ter sido treinada. Adotou-se 20% da amostra.

As variáveis também devem ser normalizadas para assegurar que recebam igual atenção durante o processo de treinamento. No trabalho, foram utilizadas a função sigmóide e a transformação linear para normalizar os dados. O software NeuroHidro faz essa transformação de forma automática.

Onze tipos de entradas diferentes foram testados com a intenção de se determinar a melhor combinação. As variáveis usadas como neurônios de entrada e saída para cada alternativa são mostradas na Tabela 1 (modelos RNA-1 até RNA-11). Os neurônios são formados por dados de chuva e/ou vazão com diferentes *lags* (defasagens). As variáveis $P(t)$ e $Q(t)$ indicam, respectivamente, chuva e vazão no mês t .



Figura 4: Bacias hidrográficas do estado de Sergipe. (Fonte: Atlas Digital Sobre Recursos Hídricos de Sergipe, SEMARH-SE).

Os modelos mais simples, neste caso, são os três primeiros, com apenas cinco entradas e uma saída. Os modelos com maior número de entradas são os sete últimos, com seis entradas e uma saída. Uma vez calibrada a rede, a vazão $Q(t)$ pode ser estimada em função da combinação de entradas.

Tabela 1: Modelos de RNAs testados.

Modelo	Neurônios na Camada		Observação*
	Entrada	Saída	
RNA-1	$P(t); P(t-1); Q(t-1)$	$Q(t)$	5 entradas; 1 saída
RNA-2	$P(t); P(t-1); P(t-2)$	$Q(t)$	5 entradas; 1 saída
RNA-3	$P(t); Q(t-1); Q(t-2)$	$Q(t)$	5 entradas; 1 saída
RNA-4	$Q(t-1); Q(t-2); Q(t-3)$	$Q(t)$	5 entradas; 1 saída
RNA-5	$P(t); P(t-1); P(t-2); P(t-3)$	$Q(t)$	6 entradas; 1 saída
RNA-6	$P(t-1); P(t-2); Q(t-1); Q(t-2)$	$Q(t)$	6 entradas; 1 saída
RNA-7	$P(t); P(t-1); P(t-2); Q(t-1)$	$Q(t)$	6 entradas; 1 saída
RNA-8	$P(t); P(t-1); Q(t-1); Q(t-2)$	$Q(t)$	6 entradas; 1 saída
RNA-9	$P(t-1); P(t-2); P(t-3); Q(t-1)$	$Q(t)$	6 entradas; 1 saída
RNA-10	$Q(t-1); Q(t-2); Q(t-3); Q(t-4)$	$Q(t)$	6 entradas; 1 saída
RNA-11	$P(t); Q(t-1); Q(t-2); Q(t-3)$	$Q(t)$	6 entradas; 1 saída

*Considerando os dois neurônios de sazonalidade.

2.3. Estudo de caso e dados utilizados

O estudo de caso foi a bacia hidrográfica do rio Japaratuba, em Sergipe (Figura 4), que possui boa disponibilidade de dados. A bacia tem uma área de drenagem de 1.735 km², equivalentes a 7,65% do território estadual e abrange 20 municípios, com população urbana e rural de 122.879 e 79.052 habitantes, respectivamente. A bacia é constituída pelo rio que lhe empresta o nome e tem como principais afluentes os rios Japaratuba Mirim, Lagartixo, Siriri, Cancelo e Riacho do Prata. Nascendo na Serra da Boa Vista e desaguando no Oceano Atlântico, a bacia possui

planície aluvial muito larga, onde se desenvolve o cultivo da cana de açúcar. As principais atividades, em termos econômicos, são a exploração do petróleo, gás natural, sal gema, potássio, calcário, magnésio, turfa e areia, além da irrigação e expansão da cultura da cana de açúcar, também o turismo e lazer, pesca e abastecimento humano e animal [20].

O talvegue principal é o rio Japarutuba, que possui extensão de 113,21 km e nasce em Feira Nova, município de Sergipe [16]. A bacia localiza-se entre os paralelos 10°13' e 10°47' de latitude sul e os meridianos 36°49' e 37°19' de longitude oeste. Segundo a classificação climática de Köppen, há a predominância do clima tropical com estação seca de verão, com período chuvoso compreendido entre abril e agosto, concentrado nos meses de maio, junho e julho. A precipitação na bacia apresenta valores anuais médios de 1.270 mm, com cerca de 900 mm/ano na sua porção noroeste e 1.500 mm/ano junto à sua foz [21].

O posto de Japarutuba (código ANA: 50040000) é a mais antiga estação fluviométrica da bacia e possui área de drenagem de 735,48 km². Foi instalado em 1943 pelo Departamento Nacional de Obras Contra as Secas (DNOCS) e hoje está sob responsabilidade da ANA. Por possuir o maior período de observação, este posto foi selecionado para a calibragem e simulação do modelo chuva-deflúvio MODHAC no estudo realizado pelo PERH-SE [16], que obteve melhores resultados quando os dados do posto fluviométrico de Japarutuba foram correlacionados com os do posto pluviométrico de Capela (código ANA: 1037009).

A combinação dos postos de chuva-vazão Capela-Japarutuba também foi usada no presente estudo. Os dados pluviométricos, fluviométricos e de evapotranspiração necessários (estes últimos usados apenas pelo Tank Model) foram extraídos do PERH-SE e do HidroWeb – Sistema de Informações Hidrológicas da ANA (hidroweb.ana.gov.br).

2.4. Avaliação do desempenho dos modelos

Neste trabalho, o desempenho de cada modelo foi avaliado pelo coeficiente de correlação de Pearson (que mede a correlação linear entre dados observados e modelados) assim como pelo índice de eficiência E de Nash-Sutcliffe [22], dado por:

$$E = 1 - \frac{\sum_{t=1}^T [Q_{\text{obs}}(t) - Q_{\text{sim}}(t)]^2}{\sum_{t=1}^T [Q_{\text{obs}}(t) - \bar{Q}_{\text{obs}}]^2} \quad (\text{eq.5})$$

em que $Q_{\text{obs}}(t)$ e $Q_{\text{sim}}(t)$ são, respectivamente, as vazões observadas e simuladas no período t , e \bar{Q}_{obs} é a vazão observada média ao longo do horizonte $t = 1, \dots, T$.

A eficiência de Nash-Sutcliffe pode variar de $-\infty$ a 1. Uma eficiência de $E = 1$ corresponde a um ajuste perfeito da descarga modelada aos dados observados. Uma eficiência de $E = 0$ indica que as previsões do modelo são tão precisas quanto a média dos dados observados, enquanto que uma eficiência inferior a zero ocorre quando a média observada é um indicador melhor do que o modelo ou, em outras palavras, quando a variância residual (descrita pelo numerador da expressão acima), é maior do que a variância dos dados (descrita pelo denominador). Essencialmente, quanto mais perto a eficiência for do valor unitário, mais preciso será o modelo.

3. RESULTADOS E DISCUSSÃO

3.1. Resultados do Tank Model

Na aplicação do Tank Model, foram empregados os registros diários do período 1969-2005. Os melhores resultados foram obtidos escolhendo-se os cinco primeiros anos de dados (1969-1973) para calibração e o restante (1974-2005) para validação. A partir de 1980, os registros fluviométricos históricos apresentavam muitas falhas, i.e., períodos sem informações os quais não foram considerados no cálculo dos índices de desempenho da validação.

A Tabela 2 mostra os valores dos índices de desempenho obtidos. As figuras 5 e 6 apresentam, para os casos diário e mensal, respectivamente, a comparação entre vazões

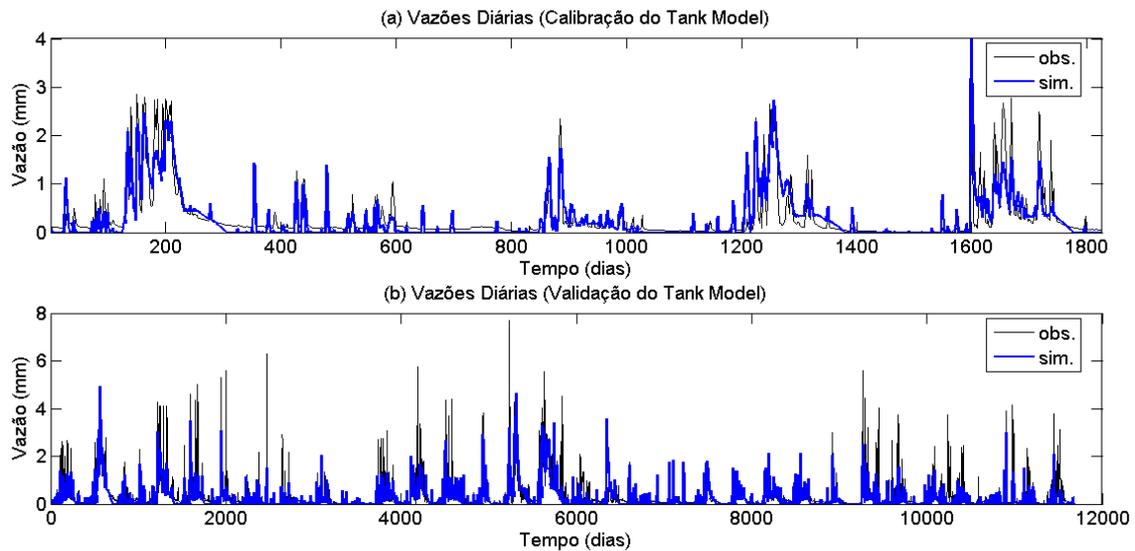


Figura 5: Comparação entre vazões diárias durante (a) calibração e (b) validação do Tank Model.

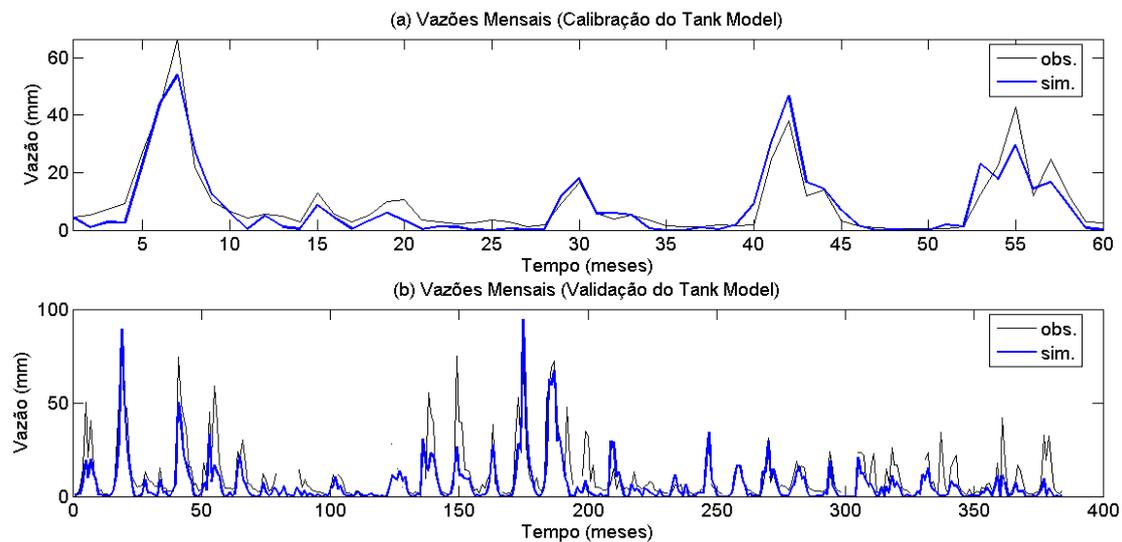


Figura 6: Comparação entre vazões mensais durante (a) calibração e (b) validação do Tank Model.

observadas e simuladas ao longo dos períodos de calibração e validação. As vazões em cada mês foram obtidas pela média dos valores diários do mês correspondente.

Tabela 2: Desempenho do Tank Model durante calibração e validação.

	Correlação		Eficiência	
	Calibração	Validação	Calibração	Validação
Diária	0,88	0,74	0,76	0,48
Mensal	0,94	0,83	0,88	0,57

3.2. Resultados da RNA

Na aplicação da RNA, foram empregados os registros mensais do período 1969-1979. Aqui, os dados com falhas do período 1980-2005 foram desconsiderados. Para calibração e validação, utilizaram-se, respectivamente, os 60% iniciais e os 40% finais dos registros. A Tabela 3 mostra os valores dos índices de desempenho obtidos por todos os modelos de RNAs testados.

Tabela 3: Desempenho dos modelos de RNAs durante calibração e validação.

Modelo	Correlação		Eficiência	
	Calibração	Validação	Calibração	Validação
RNA-1	0,96	0,95	0,91	0,75
RNA-2	0,96	0,94	0,93	0,73
RNA-3	0,95	0,95	0,91	0,82
RNA-4	0,77	0,70	0,59	0,48
RNA-5	0,97	0,95	0,93	0,75
RNA-6	0,80	0,72	0,63	0,48
RNA-7	0,96	0,95	0,93	0,76
RNA-8	0,96	0,95	0,93	0,80
RNA-9	0,80	0,73	0,63	0,48
RNA-10	0,77	0,47	0,58	0,47
RNA-11	0,95	0,93	0,90	0,80

As figuras 7 e 8 apresentam, para os modelos RNA-8 e RNA-10, respectivamente, a comparação entre vazões observadas e simuladas ao longo dos períodos de calibração e validação. Os gráficos dos outros modelos foram semelhantes.

3.3. Modelagem usada no PERH-SE

A Figura 9 mostra a comparação entre as vazões mensais observadas e simuladas pelo modelo MODHAC no estudo realizado pelo PERH-SE. Os dados utilizados para o desenho deste gráfico foram retirados diretamente dos relatórios do PERH-SE [16] e correspondem ao período 1969-2007. Empregando-se estes dados, durante todo o período, obtém-se uma correlação de 0,70 e uma eficiência de 0,21.

O MODHAC utilizou intervalo de computação diária e de simulação mensal, i.e., todas as vazões diárias foram calculadas, mas a calibração foi conduzida de acordo com ajuste dos valores mensais. Para efeito de comparação, no presente estudo, o Tank Model utilizou intervalos diários tanto para a computação das vazões quanto para o ajuste, enquanto que os modelos de RNAs utilizaram intervalos mensais para ambas, computação e simulação.

3.4. Comparação entre os modelos

Com o intuito de avaliar o desempenho do Tank Model, de todos os modelos de RNAs e do MODHAC para um mesmo horizonte de simulação, os dados fluviométricos estimados por todos eles para o período comum de 1969-1979 foram comparados com os observados correspondentes. A Figura 10 mostra essa comparação enquanto que a Tabela 4 apresenta os índices de desempenho obtidos.

Tabela 4: Desempenho de todos os modelos para o período 1969-1979.

Tank	Modelos de RNAs											MODHAC	
	Model	1	2	3	4	5	6	7	8	9	10		11
Correlação	0,89	0,93	0,93	0,94	0,74	0,94	0,77	0,94	0,95	0,76	0,74	0,94	0,78
Eficiência	0,71	0,85	0,86	0,88	0,55	0,87	0,58	0,86	0,88	0,57	0,54	0,86	0,50

3.5. Discussão dos resultados

A Tabela 4 indica que, para o período comum de comparação, sete dos onze modelos de RNAs foram mais eficientes do que o Tank Model e do que o MODHAC. O Tank Model apresentou correlação e eficiência melhores do que o MODHAC, embora tenha fornecido eficiências relativamente baixas durante seu processo de validação diária e mensal, como mostrado na Tabela 2.

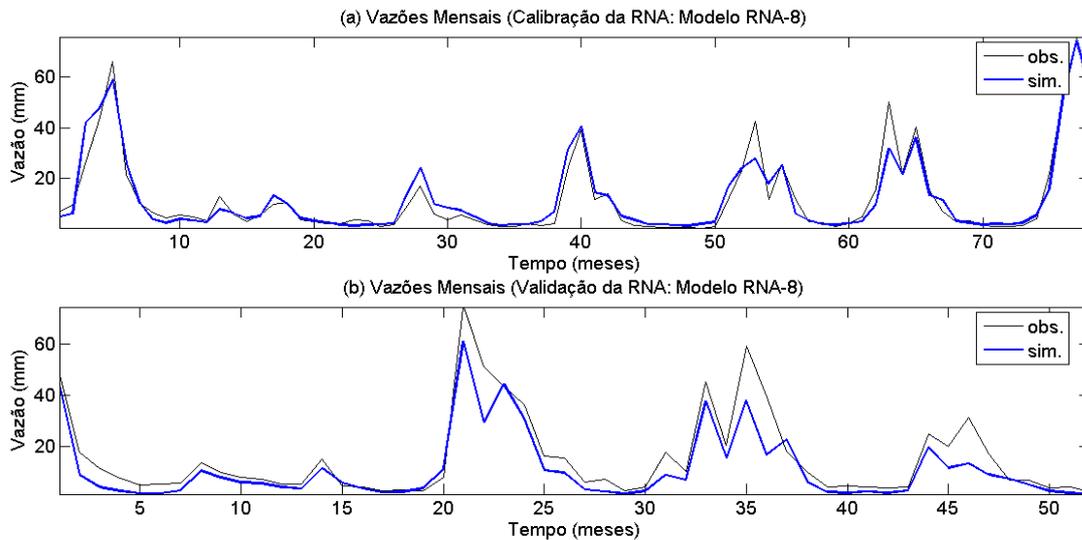


Figura 7: Comparação entre vazões mensais durante (a) calibração e (b) validação do modelo RNA-8.

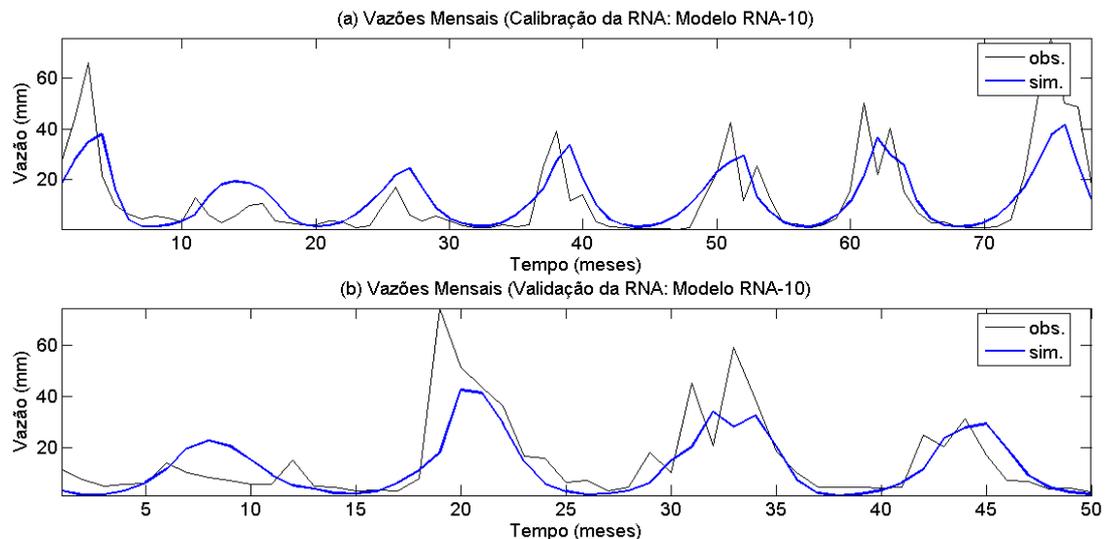


Figura 8: Comparação entre vazões mensais durante (a) calibração e (b) validação do modelo RNA-10.

Os modelos baseados em RNAs mais eficientes durante a calibração e validação foram o RNA-3, RNA-8 e RNA-11 (Tabela 3). Na comparação com todos os modelos (Tabela 4), o RNA-8 foi o melhor em termos de correlação e eficiência. Já o modelo RNA-10 foi o pior modelo de redes neurais, apresentando eficiência de $E=0,54$, pior do que o Tank Model ($E=0,71$), porém melhor do que o MODHAC ($E=0,50$).

Por meio da Figura 8(a) nota-se que, durante a calibração, o modelo RNA-10 apresentou um razoável comportamento para vazões baixas (com pequenas dispersões), mas esta tendência não prevaleceu com o aumento da vazão e uma grande dispersão ocorreu para vazões altas. Na Figura 8(b), durante a validação, o RNA-10 não representou bem tanto as vazões baixas quanto as altas, apresentando muita dispersão nos picos do gráfico.

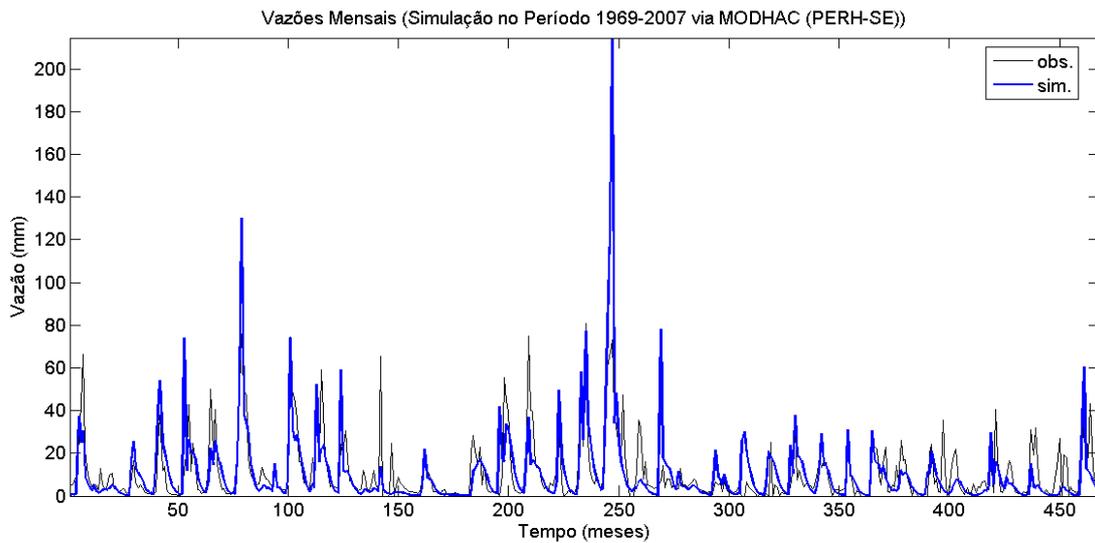


Figura 9: Comparação entre vazões mensais observadas e simuladas para o período 1969-2007 pelo MODHAC. (Fonte dos Dados: SEMARH-SE [16]).

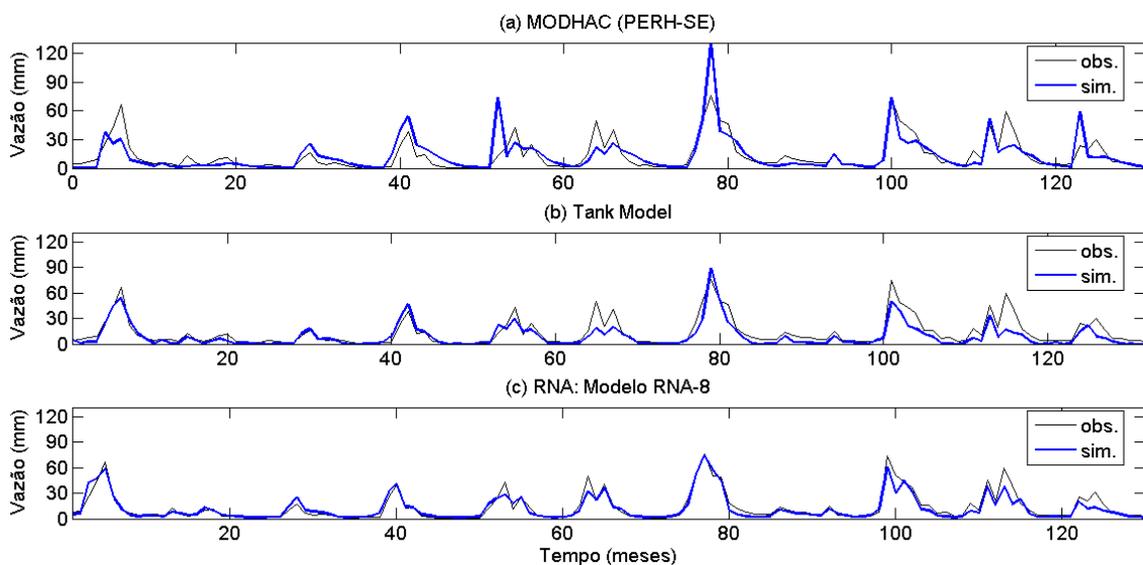


Figura 10: Comparação entre vazões mensais observadas e simuladas para o período 1969-1979 por todos os modelos.

Os modelos de RNAs que apresentaram menores eficiências (RNA-4, RNA-6, RNA-9 e RNA-10) foram justamente os que não usaram a chuva do mês atual como neurônio de entrada. Isso significa que a vazão a ser estimada tem alta correlação com a chuva do mês correspondente. O modelo RNA-4 juntamente com o RNA-10, que usaram apenas vazões como entrada (são, de fato, modelos vazão-vazão), foram os que apresentaram pior desempenho dentre os baseados em redes neurais. Logo, percebe-se também que a vazão atual tem pouca correlação com vazões passadas.

Observa-se na Figura 7(a) que, durante a calibração, o modelo RNA-8 apresentou bom comportamento tanto para vazões baixas quanto para vazões altas. Já de acordo com a Figura 7(b), durante a validação, o RNA-8 representou relativamente bem as vazões baixas, mas ocorreu uma pequena dispersão para vazões altas. A Tabela 3 indica que, em relação ao modelo RNA-8, o RNA-3 foi mais eficiente na validação do que na calibração.

Os modelos RNA-1, RNA-2 e RNA-3, que necessitam de apenas três informações de entrada, deram resultados muito satisfatórios. O RNA-3, particularmente, apresentou desempenho semelhante ao do RNA-8, que precisa de um dado adicional de entrada.

4. CONCLUSÃO

Este trabalho comparou três metodologias para a modelagem do processo chuva-vazão na bacia hidrográfica do rio Japarutuba, no estado de Sergipe. A primeira delas utilizou a fundamentação conceitual do Tank Model em escala diária. Foi verificado que, mesmo com sua formulação simplificada e requerimento de poucos dados de entrada, o Tank Model adaptou-se satisfatoriamente às características da bacia em estudo e mostrou um bom desempenho.

Uma vez que a relação chuva-vazão é complexa e altamente não linear e que redes neurais artificiais são ditas aproximadores universais de funções não lineares, sua aplicabilidade também foi estudada. Percebeu-se que a abordagem empírica das RNAs dependia do número, do tipo e da defasagem (*lags*) dos elementos de entrada (neurônios artificiais). Onze modelos distintos em escala mensal foram testados e verificou-se que os melhores foram os que usaram a chuva de *lag* zero na estimativa da vazão. O uso de RNAs foi interessante no sentido de que permitiu trabalhar apenas com as duas variáveis principais (chuva e vazão), sem necessidade de dados adicionais de evapotranspiração, condições iniciais de umidade do solo ou outras informações hidrológicas requisitadas por modelos conceituais.

O desempenho do Tank Model e dos onze modelos baseados em RNAs foram comparados com dados obtidos do Plano Estadual de Recursos Hídricos de Sergipe, que utilizou o modelo MODHAC para simular o processo precipitação-vazão em bacias do estado. É preciso salientar que o MODHAC não foi calibrado no presente estudo, que apenas usou os dados publicados nos relatórios do PERH-SE. Todos os modelos forneceram melhores ajustes em comparação com o MODHAC para o estudo de caso.

Os testes realizados indicaram superioridade em termos de eficiência (i.e., ajuste entre vazões observadas e simuladas) de sete modelos de RNAs (em ordem numérica: RNA-1, RNA-2, RNA-3, RNA-5, RNA-7, RNA-8 e RNA-11) sobre o Tank Model, este mais eficiente do que os modelos neurais restantes (RNA-4, RNA-6, RNA-9 e RNA-10).

-
1. ANA. Inventário das estações fluviométricas. 2 ed. Agência Nacional de Águas (Brasília); 2009.
 2. Collischonn W, Tucci CEM. Calibração automática global do modelo IPH2. In: Anais do XIV Simpósio Brasileiro de Recursos Hídricos; 2001. Aracaju.
 3. Beven KJ. Rainfall-runoff modelling: the primer. Chichester: Wiley, 2001.
 4. Lopes JEG, Braga BPF, Conejo JGL. SMAP - A simplified hydrological model. In: Singh VP, editor. Applied modelling in catchment hydrology. Proceedings of the International Symposium on Rainfall-Runoff Modelling, Water Resources Publications. 1982.
 5. Marwell Filho P, Lanna AEL. MOHTSAR: Um modelo hidrológico para o trópico semi-árido. Caderno de Recursos Hídricos da Revista Brasileira de Engenharia. 1986; 4(1):95-118.
 6. Viegas Filho JS, Lanna AEL, Pereira JS, Troger FH, Conceição A. MODHAC - Modelo hidrológico auto-calibrável, versão 98 para Windows. In: Anais do Congresso Brasileiro de Engenharia Agrícola; 1999. Pelotas.
 7. Sugawara M. Tank Model. In: Singh VP, editor. Computer models of watershed hydrology. Water Resources Publication; 1995, p. 165-214.
 8. Solomatine DP, Maskey M, Shrestha, DL. Instance-based learning compared to other data-driven methods in hydrological forecasting. Hydrological Processes. 2008; 22(2):275-287.
 9. Solomatine DP. Data-driven modeling and computational intelligence methods in hydrology. In: Anderson M., editor. Encyclopedia of Hydrological Sciences. John Wiley & Sons; 2006.
 10. Farias CAS, Kadota A, Celeste AB, Suzuki K. RNN-based inflow forecasting applied to reservoir operation via implicit stochastic optimization. In: Boegh E et al., editors. Quantification and Reduction of Predictive Uncertainty for Sustainable Water Resources Management. IAHS Publ. 313; 2007. p. 452-62.
 11. Dawson CW, Wilby RL. Hydrological modeling using artificial neural networks. Progress in Physical Geography. 2001; 25(1):80-108.

12. Abrahart RJ, See L. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological Processes*. 2000; 14:2157-72.
13. Minns AW, Hall MJ. Artificial neural networks as rainfall-runoff models. *Hydrological Science Journal*. 1996; 41:399-417.
14. Hsu K, Gupta HV, Sorooshian S. Artificial neural network modelling of the rainfall-runoff process. *Water Resources Research*. 1995; 31(10):2517-30.
15. Sousa FAZ, Sousa WS. Rede neural aplicada ao processo chuva-vazão da bacia hidrográfica de Caraúbas - PB. In: *Anais do 14º. Congresso Brasileiro de Meteorologia*; 2006. Florianópolis.
16. SEMARH-SE. *Elaboração do plano estadual de recursos hídricos: RE-6, Volume 1, Tomo I (bacia hidrográfica do rio Japarutuba)*. Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos (Sergipe); 2010.
17. Celeste AB, Suzuki K, Watanabe M, Santana CWS. Calibração automática do Tank Model via algoritmos genéticos. In: *Anais do XIV Simpósio Brasileiro de Recursos Hídricos*; 2001. Aracaju.
18. Duan Q, Sorooshian S, Gupta VK. Optimal use of the SCE-UA global optimization method for calibrating watershed models. *Journal of Hydrology*. 1994; 158(3):265-84.
19. Valença M. *Aplicando redes neurais: um guia completo*. Olinda (PE): Ed. do Autor, 2005.
20. SEMARH-SE. *As bacias hidrográficas em Sergipe* [Internet]. [acesso em set 2013]. Disponível em: <http://www.semarh.se.gov.br/comitesbacias/>.
21. Cruz MAS. *Avaliação de séries históricas de vazão monitoradas em duas sub-bacias do rio Japarutuba em Sergipe com auxílio de algoritmos genéticos*. Embrapa Tabuleiros Costeiros; 2010. Boletim de Pesquisa e Desenvolvimento.
22. Nash JE, Sutcliffe JV. River flow forecasting through conceptual models part 1 - a discussion of principles. *Journal of Hydrology*. 1970; 10:282-290.