

# *Regionalização de Vazões com o Emprego de Redes Neurais Artificiais RBF*

*João Pedro Bazzo Vieira, Ricardo Carvalho de Almeida*

*Departamento de Engenharia Ambiental*

*Universidade Federal do Paraná*

*Curitiba, Brasil*

*joao.bazzo@gmail.com, rcalmeida@ufpr.br*

**Resumo**—O objetivo desta pesquisa foi avaliar um método de regionalização de vazões aplicado em estações fluviométricas no interior do Estado do Paraná já estudadas anteriormente, com a proposição de diferentes técnicas para tal. Com a ausência de monitoramento fluviométrico em parte dos rios de países em desenvolvimento, assim como a falta de operação e manutenção adequada das estações existentes, grande importância tem sido dada a procedimentos de transferência de informações de bacias hidrográficas com monitoramento fluviométrico para bacias carentes de registros. O método consiste em regionalizar parâmetros de um modelo chuva-vazão por meio do uso de Redes Neurais Artificiais (RNAs) para bacias hidrográficas sem monitoramento fluviométrico, mas que apresentam medições históricas de temperatura e pluviometria. As técnicas propostas dentro desta abordagem foram o uso dos Mapas Auto-Organizados de Kohonen e RNAs do tipo Função de Base Radial. Na pesquisa foram estudadas 15 estações fluviométricas, das quais duas foram utilizadas como estações teste para validação do método. Em parte das simulações realizadas, foram verificados resultados satisfatórios para regionalização, com coeficientes de determinação e Nash-Sutcliffe elevados, quando confrontadas com as vazões observadas. Os resultados indicam que, assim como o método de regionalização proposto inicialmente, o uso das diferentes técnicas propostas nesta pesquisa também é viável para a regionalização de vazões, com o diferencial de que apresenta condições de aplicação para um maior número de bacias hidrográficas.

**Palavras-chave**—modelagem chuva-vazão; rede neural artificial; regionalização de vazões.

## I. INTRODUÇÃO

Dadas as condições morfológicas favoráveis das bacias hidrográficas do estado do Paraná e a disponibilidade hídrica farta ao longo do ano, a região é considerada uma das mais propícias à instalação de aproveitamentos energéticos no Brasil [1].

Contudo, a distribuição de redes pluviométricas e fluviométricas em grande parte do território nacional tem se mostrado inadequada e, em alguns casos, insuficientes para atender demandas de projetos para este setor. Cita-se, por exemplo, a Portaria nº 463/2009 do Ministério de Minas e Energia (MME), que dispõe em seu Artigo 3º da obrigatoriedade de histórico de vazões médias mensais não inferiores a 30 anos, e gerado de maneira que seja o mais extenso e atualizado possível [2].

Dessa forma, cresce no Brasil a necessidade de se desenvolver métodos eficientes de regionalização hidrológica como

consequência da escassez de dados obtidos [3]. Há atualmente uma considerável demanda para aplicação desses métodos para bacias hidrográficas para as quais não existe uma rede de monitoramento adequada [4].

Tucci [5] define a regionalização como um conjunto de ferramentas que exploram ao máximo as informações existentes, visando a estimativa das variáveis hidrológicas em locais sem dados ou insuficientes. Por serem mais distribuídos e com séries históricas com duração normalmente mais extensa, os dados das redes de monitoramento climatológica e pluviométrica são muitas vezes utilizados como entrada para a previsão de vazão em bacias carentes de postos fluviométricos, através de modelos matemáticos denominados chuva-vazão [6].

Dentre as técnicas de modelagem chuva-vazão, as Redes Neurais Artificiais — RNA têm sido empregado de maneira crescente para previsões de variáveis em recursos hídricos e aplicados para superar dificuldades encontradas em abordagens estatísticas tradicionais [7]. Seus principais benefícios são: não-linearidade (importante para representar fenômenos físicos intrinsecamente não-lineares); adaptatividade (capacidade de se adaptar devido à respostas do ambiente); mapeamento entrada-saída (a rede aprende com os exemplos que lhe são apresentados para construir um mapeamento entrada-saída do problema em questão)[8].

Além disso, por conta das diferentes características físicas e climáticas das bacias hidrográficas, bem como a ausência destes parâmetros em certos locais, hidrólogos têm regionalizado as características das bacias de interesse com base na experiência obtida em outras bacias. Tal medida, quando aplicada em conjunto com técnicas de modelagem chuva-vazão, constitui uma abordagem importante para solucionar o problema da falta de dados fluviométricos. O objetivo desta pesquisa foi investigar a aplicação da regionalização de parâmetros de um modelo chuva-vazão, calibrado através de RNAs tipo Função de Base Radial, para bacias que não contam com registros de fluviometria, apenas pluviometria e temperatura.

## II. MÉTODO

Esta pesquisa baseia-se na regionalização de parâmetros de um modelo chuva-vazão baseado em RNAs para bacias que

não contam com dados de pluviometria, mas que apresentam séries históricas de precipitação e temperatura.

As etapas do método foram baseadas na pesquisa realizada por [1], com algumas diferenças metodológicas, a serem apresentadas neste capítulo.

As principais etapas são descritas a seguir, e ilustradas pela Figura 1.

- 1) A partir de 15 estações fluviométricas do Estado do Paraná e das características fisiográficas e climatológicas de suas respectivas áreas de drenagem, foi definido, através do emprego de mapas auto-organizados de Kohonen, quais serão as bacias com características semelhantes entre si — definição dos aglomerados (*clusters*);
- 2) Foram adotadas as duas estações fluviométricas “teste” definidas por Minucci[1], a partir das 15 totais, visando confrontar os dados observados com os calculados;
- 3) Foi desenvolvido um modelo chuva-vazão e selecionado a melhor RNA — do tipo Função de Base Radial — para cada bacia;
- 4) Em seguida, foram obtidos modelos chuva-vazão “médios” dos grupos semelhantes;
- 5) Foram obtidas as séries de vazões regionalizada para as estações “teste”;
- 6) As vazões modeladas foram confrontadas com os registros observados, para a validação do método.

As séries regionalizadas são geradas a partir da operação da RNA calibrada da estação auxiliar que utilizou como entrada os registros de precipitação e temperatura da Estação Teste (a ser regionalizada).

Minucci[1] utilizou o método *k-means* para a etapa de clusterização, enquanto nessa pesquisa foram utilizados os mapas auto-organizados de Kohonen; e ele empregou RNAs tipo *perceptron* multicamadas para o modelo chuva-vazão, sendo RNAs tipo RBF as redes neurais utilizadas neste projeto. Tanto as variáveis físicas/fisiográficas das bacias hidrográficas, como seus registros de pluviometria, fluviometria e climatologia foram obtidos a partir de Minucci[1], sendo as principais etapas para regionalização descritas nesse capítulo.

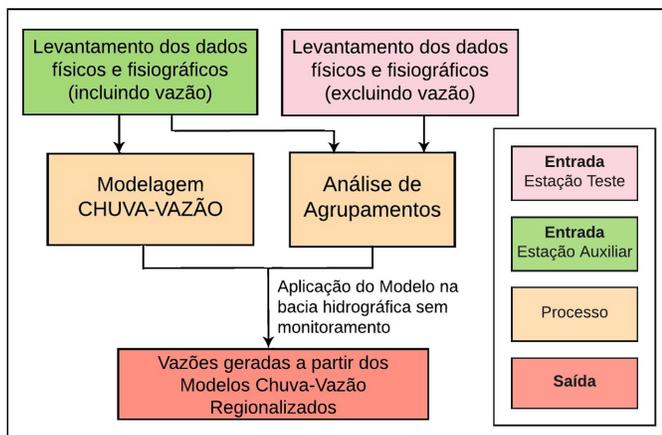


Figura 1. Abordagem adotada para regionalizar registros de vazões.

### A. Área de Estudo

Foram selecionadas estações fluviométricas com áreas de drenagem inferiores a 5.000 km<sup>2</sup>, com 16 anos de dados mensais, localizadas em bacias hidrográficas com baixa expansão urbana no período das medições. As estações fluviométricas e pluviométricas utilizadas na pesquisa estão relacionadas na Tabela I.

### B. Variáveis utilizadas na Análise de Agrupamento

Para que sejam selecionados os atributos que são mais representativos para descrição de uma bacia hidrográfica, é necessário que as características sejam reduzidas a uma dimensão que facilite o trabalho de processamento e que mantenha a amostra com grau de significância razoável. Diniz [3] destaca que “os atributos redundantes prejudicam o desempenho da ferramenta de aprendizagem tanto na velocidade (devido à dimensionalidade dos dados) quanto no índice de acerto (devido à presença de informações redundantes)”.

Na pesquisa conduzida por Minucci[1], foi aplicada uma técnica de Estatística Multivariada — Análise dos Componentes Principais (ACP)— com o objetivo de reduzir a dimensão dos dados descritivos. De acordo com os resultados, foi verificado que as características mais relevantes das bacias, ou seja, os atributos que explicam maior porcentagem da variância, foram temperatura média, área de drenagem, precipitação média anual e longitude do centróide da bacia. Assim, foram analisados os resultados da clusterização para os seguintes conjuntos de variáveis:

- **Agrupamento A** (Quatro variáveis): temperatura média, área de drenagem, precipitação média anual, longitude do centróide da área de drenagem;
- **Agrupamento B** (11 variáveis): temperatura média, área de drenagem, precipitação média anual, longitude do centróide da área de drenagem, coeficiente de variação da precipitação, declividade média da área de drenagem, altitude do centróide da área de drenagem, altitude da estação fluviométrica, coeficiente de variação da temperatura e densidade de drenagem.

### C. Análise de Agrupamentos

Uma vez levantadas as variáveis físicas e fisiográficas das bacias hidrográficas, bem como a redução destas variáveis a um conjunto significativo o suficiente, foi realizada a clusterização, através do emprego do algoritmo SOM (*Self Organized Maps*) de Kohonen.

As principais configurações para o aprendizado da rede são:

- Dimensão do vetor de entrada
- Número de linhas e colunas da estrutura topológica (camada de saída)
- Número de épocas de treinamento
- Limite máximo do raio de vizinhança

A Figura 2 ilustra o esquema para a aplicação da metodologia de agrupamento entre as Bacias Hidrográficas da pesquisa.

Tabela I  
ESTAÇÕES FLUVIOMÉTRICAS E PLUVIOMÉTRICAS UTILIZADAS NA PESQUISA. FONTE: MINUCCI[1].

Código ANA	Estação Fluvio-métrica	A.D. (km <sup>2</sup> )	Estações pluviométricas associadas
64775000	Balsa do Cantú	2520,1	Altamira do Paraná, Balsa do Cantú, Barra Grande, Laranjal, Palmital e Roncador
65809000	ETA Guarapuava	312,8	Guarapuava, Campo de Dentro, Invernadinha e Palmeirinhas
65415000	Fazenda Maracanã	323,6	Fazenda Maracanã, Pátio Velho, Salto do Vau e Santana
64764000	Guampará	1006,0	Campina do Simão, Marquinhos, Palmital e Santa Maria do Oeste
65764000	Madeira Gavazzoni	935,7	Campina Bonita, Colônia Alegre, Fazenda Zaniolo, Inácio Martins, Leonópolis e Madeira Gavazzoni
64785000	Ponte do Goio Bang	1341,8	Campina da Lagoa, Guarani, Mamborê, Pensamento e Ponte do Goio-Bang
64773000	Ponte Leôncio Primo	696,6	Barra Grande, Roncador, Palmital e Pitanga
64767000	Porto Carriel	3569,3	Campina do Simão, Campo Verde, Laranjal, Marquinhos, Palmital, Porto Carriel e Santa Maria do Oeste
64771500	Porto Guarani	4165,0	Campina do Simão, Campo Verde, Laranjal, Marquinhos, Palmital, Porto Carriel e Santa Maria do Oeste
65970001	Porto Santo Antônio	1084,1	Goioxim, Guaraniaçu, Linha Mirim, Porto Santo Antônio, Torra Alta e Vila Guarani
64620000	Rio dos Patos	1097,7	Apiaba, Itapara, Relógio, Rio dos Patos, Tijuco Preto e Inácio Martins
64790000	Salto Sapucaí	693,3	Corbélia, Ponte Tourinho – Braganey, Salto Sapucaí e São João do Oeste
65979000	São Sebastião	1311,6	Boi Preto, Cascavel – Oepar, Flor da Serra, Linha Santa Catarina, Nelson Taborda, Rio do Salto, Santa Lúcia e São João do Oeste
64625000	Tereza Cristina	3567,9	Apiaba, Bairro da Imbuia, Campo de Dentro, Inácio Martins, Itapara, Laranjeiras, Relógio, Rio dos Patos, Saltinho, Tereza Cristina e Tijuco Preto
65971050	Tormenta Fazenda Trento	319,6	Catanduvas, Flor da Serra, Ibema, Ibiracema, Nelson Taborda e Rio do Salto

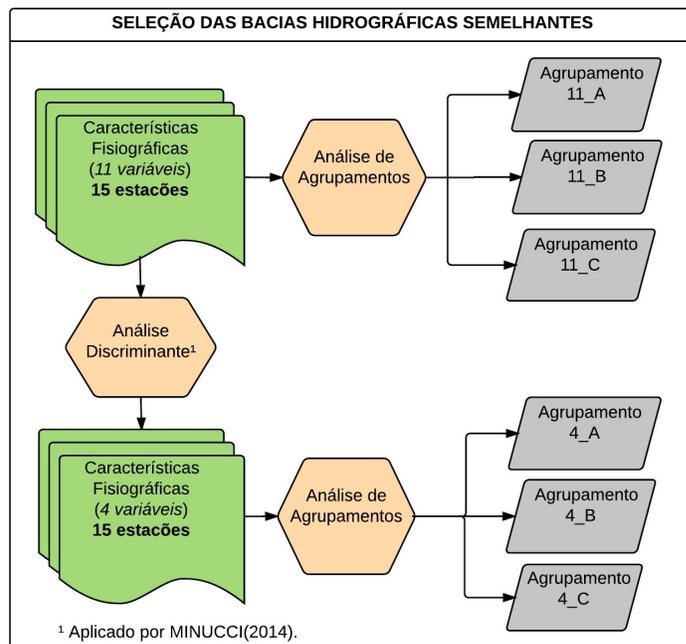


Figura 2. Abordagem adotada para aplicação dos agrupamentos.

#### D. Modelagem Chuva-Vazão

A modelagem chuva-vazão realizada na presente pesquisa visam verificar a melhor configuração de treinamento da rede neural, a partir de dois diferentes conjuntos de dados de pluviometria e temperatura utilizados como entrada:

- **Modelo Chuva-Vazão I:**  $P_m(t)$ ,  $P_m(t-1)$ ,  $P_m(t-2)$ ,  $T_m(t)$ ;
- **Modelo Chuva-Vazão II:**  $P_1(t)$ ,  $P_1(t-1)$ ,  $P_1(t-2)$ ,  $P_2(t)$ ,  $P_2(t-1)$ ,  $P_2(t-2)$ ,  $P_3(t)$ ,  $P_3(t-1)$ ,  $P_3(t-2)$ ,  $P_4(t)$ ,  $P_4(t-1)$ ,  $P_4(t-2)$ ,  $T_m(t)$ ;

onde  $P_1()$ — $P_4()$ , referem-se a precipitação média mensal das estações pluviométricas 1—4;  $P_m()$  a precipitação de Thiessen média da bacia;  $T_m()$  a temperatura média da bacia (calculadas através dos Polígonos de Thiessen); e as expressões  $t$ ,  $t-1$ ,  $t-2$  ao mês atual, um e dois meses anteriores, respectivamente.

#### E. Regionalização de Vazões

A partir da definição da melhor configuração de treinamento da rede neural, assim como a seleção dos grupos semelhantes, foi realizada a regionalização dos modelos chuva-vazão a partir da operação das RNAs utilizando os dados de precipitação das estações teste como entrada.

Uma vez regionalizadas as vazões das estações teste para cada estação auxiliar semelhante, foram calculadas as médias das vazões modeladas e confrontadas com as vazões observadas nas estações teste. A Figura 3 exemplifica a abordagem adotada para regionalização das vazões para uma estação teste.

Tendo os modelos chuva-vazão calibrados e validados, os dados de entrada da RNA da estação auxiliar foram substituídos pelos registros de precipitação e temperatura da estação teste (regionalizada).

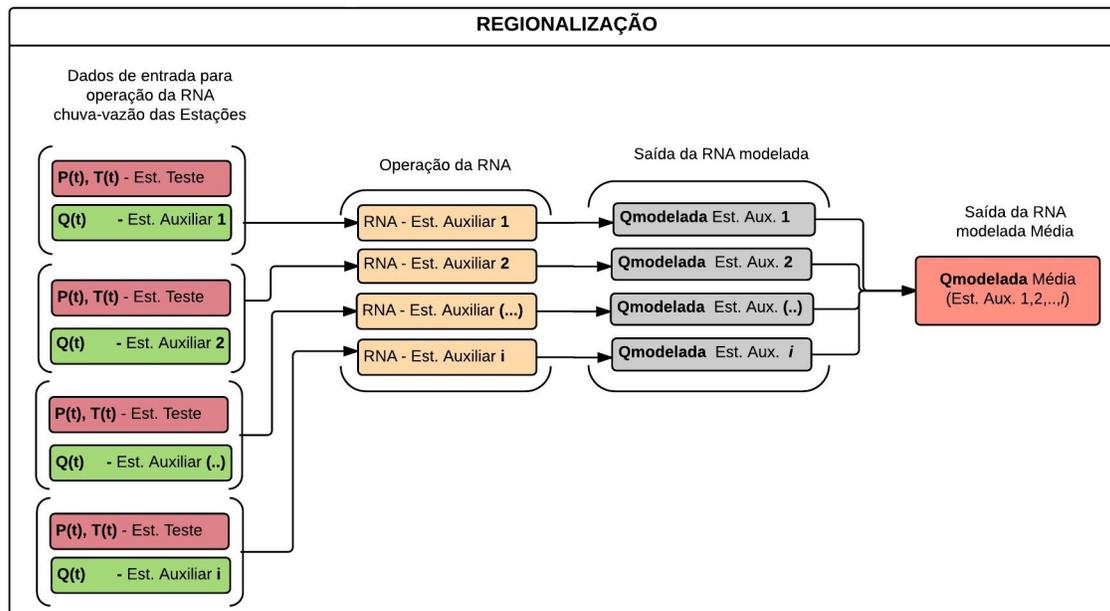


Figura 3. Representação esquemática da abordagem adotada para o cálculo da vazão modelada média a partir de  $i$  estações.

### III. RESULTADOS E DISCUSSÃO

#### A. Seleção dos Grupos Semelhantes

Os resultados obtidos através do emprego do algoritmo SOM, desenvolvido em linguagem FORTRAN 95, são apresentados na Tabela II, sendo as estações sublinhadas as estações teste (a serem regionalizadas). Foram selecionadas as configurações da rede que permitiram verificar a estabilização das variações dentro de determinado *cluster*, a partir da variação de número de épocas, dimensionalidade (número de linhas e colunas) da estrutura topológica, e raio de influência na vizinhança.

Quando comparados os grupos formados a partir do agrupamento A e do definido por Minucci[1] (os quais são formados a partir das mesmas quatro variáveis físicas), verifica-se que apenas um grupo obteve maior número de estações em comum - sendo quatro no total. Contudo, nesta situação, as estações teste Guampará e Madeira Gavazzoni se encontraram em diferentes grupos.

As estações teste também se deslocaram de grupo para as simulações desta pesquisa (Agrupamentos A e B), apesar de serem verificadas 10 estações sem alterações de *clusters*. Contudo, uma vez que as estações teste se deslocaram de grupos, esperam-se alterações mais significativas quando for aplicada a regionalização de vazões.

Kalteh *et al* [9] destacam a importância de se introduzir dados de entrada “eficientes”, uma vez que a simples apresentação de todas as potenciais variáveis para a rede neural e a expectativa de que a rede identificará as mais cruciais pode criar problemas. As principais desvantagens dessa abordagem, além da necessidade de maior memória computacional, são: dificuldade de aprendizagem; a não convergência e baixo desempenho do modelo; dificuldade de compreensão do mo-

Tabela II  
CLUSTERS FORMADOS A PARTIR DE DIFERENTES ENTRADAS DO ALGORITMO SOM E O MÉTODO *k-means* - PROPOSTO POR MINUCCI[1].

<b>Agrupamento A<sup>1</sup></b>	- Guampará - <u>Madeira Gavazzoni</u> - Ponte Goio Bang - Porto Santo Antônio - Rio dos Patos - São Sebastião	- Balsa do Cantú - Porto Carriel - Porto Guarani - Tereza Cristina	- ETA Guarapuava - Fazenda Maracanã - Ponto Leôncio Primo - Salto Sapucaí - Tormenta Fazenda Trento
<b>Agrupamento B<sup>2</sup></b>	- Ponto Leôncio Primo - Porto Santo Antônio - Rio dos Patos - Salto Sapucaí - São Sebastião	- Balsa do Cantú - Guampará - Ponte Goio Bang - Porto Carriel - Porto Guarani - Tereza Cristina	- ETA Guarapuava - Fazenda Maracanã - <u>Madeira Gavazzoni</u> - Tormenta Fazenda Trento
<b>Minucci (2014)<sup>3</sup></b>	- Ponte Goio Bang - Ponte Leôncio Primo - Porto Santo Antônio - Salto Sapucaí - São Sebastião - Tormenta Fazenda Trento	- Balsa do Cantú - Porto Carriel - Porto Guarani - Tereza Cristina - <u>Guampará</u>	- ETA Guarapuava - Fazenda Maracanã - Rio dos Patos - <u>Madeira Gavazzoni</u>

<sup>1</sup>Formado a partir da clusterização de quatro variáveis físicas/fisiográficas

<sup>2</sup>Formado a partir da clusterização de 11 variáveis física/fisiográficas

<sup>3</sup>Formado a partir do emprego do algoritmo *k-means* - utilizando 4 variáveis físicas/fisiográficas, por Minucci[1].

delo; e o aumento de ruído devido à introdução de variáveis irrelevantes [9]-[10].

#### B. Modelagem Chuva-Vazão

Diversos parâmetros de configuração de RNA foram testados visando obter melhor resultado de calibração, sendo as configurações que proporcionaram melhores resultados e

atingiram o *overtraining*<sup>1</sup>, listadas na Tabela III. Foi utilizado como critério de melhor configuração as calibrações que obtiveram melhores coeficientes de determinação ( $R^2$ ) e Nash-Sutcliffe (*NASH*).

Tabela III  
PARÂMETROS DE CONFIGURAÇÃO DE TREINAMENTO E OPERAÇÃO DA REDE RBF, PARA O MODELO CHUVA-VAZÃO I E II.

Parâmetro	Valor
Número de iterações	10
Método de normalização dos dados	Mínimo/Máximo [-1,1]
Percentuais de dados para treinamento, teste e validação (respectivamente)	80%, 10% e 10%
Épocas de treinamento da 1ª camada da rede RBF	2 000
Taxa de aprendizado da 1ª camada da rede RBF	0,025
Erro máximo para treinamento da 1ª camada da rede RBF	$10^{-7}$
Épocas de treinamento da 2ª camada da rede RBF	10 000
Taxa de aprendizado da Variância $\sigma_k^2$ , Centro $t_k$ e Pesos Sinápticos $w_k$ da RBF	0,005
Função de ativação na saída	Linear
Número de neurônios da camada oculta da rede*	15, 20, 25 ou 30

\*Variação de 15, 20, 25 ou 30 neurônios na camada oculta conforme melhores estatísticas de calibração de cada RNA.

As Tabelas IV e V, resumem as estatísticas médias relevantes dos modelos chuva-vazão I e II, respectivamente.

Durante a calibração das RNAs Chuva-Vazão, verificou-se, de modo geral, baixos coeficientes de *NASH* para as 11 estações auxiliares modeladas. Para o Modelo Chuva-Vazão I (4 entradas, 1 saída), as estações Porto Carriel e Rio dos Patos apresentaram valores de *NASH* 0,66 e 0,7, respectivamente, com baixas *REQM* (Raiz do Erro Quadrático Médio); enquanto as estações Porto Carriel e Porto Guarani apresentaram valores de *NASH* de 0,7 e 0,72, respectivamente, com valores *REQM* mais elevadas (superiores a 38 m<sup>3</sup>/s). Para a operação, verificou-se altos valores de *NASH* (superiores a 0,79) e valores baixos de *REQM* para todas as estações.

O Modelo Chuva-Vazão II (13 entradas, 1 saída) apresentou estatísticas médias de calibração e operação inferiores aos verificados no Modelo I. Tal resultado é diferente do verificado por Minucci[1], que não obteve resultados satisfatórios quando utilizada apenas a precipitação média mensal (obtida pelo método de Thiessen). Para a referido pesquisa, ao empregar o Modelo Chuva-Vazão II, "...A variância inserida na amostra trazia mais informações às redes, fazendo com que elas "aprendessem" melhor as características no entorno da região e levassem à melhores resultados no momento da validação". A razão pela qual verificaram-se baixos valores de Nash-Sutcliffe durante a calibração se dá pelo fato de se utilizarem menores

<sup>1</sup>Quando a rede memoriza todos os registros de treinamento ao ter aprendido muitos exemplos de padrões de "entrada-saída" dos dados [8].

percentuais dos registros para a validação - 10% (17 registros de um total de 165).

#### IV. REGIONALIZAÇÃO DE VAZÕES

Foram definidos quatro diferentes resultados da regionalização de vazões para a estação teste Madeireira Gavazzoni e Guampará, totalizando oito simulações. A Tabela VI resume as simulações que obtiveram melhores resultados - em termos de coeficientes de determinação  $R^2$  e *NASH*.

Ressalta-se que os resultados obtidos por Minucci[1] não são diretamente comparáveis com os modelos chuva-vazão acima apresentados, uma vez que os agrupamentos das estações semelhantes foram distintos. As Tabelas VII e VIII resumem os valores modelados para as estações teste e seus respectivos registros observados.

Destaca-se que o Modelo Chuva-Vazão II utilizou 13 registros de dados como entrada para a rede, sendo quatro registros mensais médios de  $p(t)$ ,  $p(t-1)$  e  $p(t-2)$  das quatro estações pluviométricas mais representativas da bacia, totalizando 12; e a temperatura média da bacia. Assim, as bacias hidrográficas que não contam com ao menos quatro estações pluviométricas não podem ter suas vazões regionalizadas a partir do modelo proposto. De modo análogo, as bacias que tem mais de 4 estações pluviométricas, e portanto maior quantidade de registro de precipitação, terão de selecionar apenas as quatro estações pluviométricas mais representativas e descartar os registros restantes. Tal abordagem pode tanto inviabilizar a aplicação da regionalização - para o caso de bacias com menos de quatro estações - assim como demandar a realização de análise discriminante e o conseqüente descarte de registro de dados de precipitação - para o caso de bacias com mais de quatro estações pluviométricas.

Os resultados verificados entre o Modelo Chuva-Vazão I e II demonstram que a utilização da precipitação média mensal de Thiessen como entrada pode melhorar os resultados de previsão. Tal medida é vantajosa em relação à abordagem proposta por Minucci[1], uma vez que nenhum registro histórico de estações pluviométricas das bacias hidrográficas necessitará ser descartado.

Conforme verificado, o desempenho da regionalização através das estações do Agrupamento B foi baixo para ambas as estações teste. A estação Madeireira Gavazzoni teve sua vazão média subestimada em 63%, enquanto a vazão média da estação Guampará foi superestimada em cerca de 184% com relação ao valor observado. Vale destacar que a mudança de *clusters* das estações teste foi significativa, quando verificadas as estações dos Agrupamentos A e B. Nesse sentido, destaca-se que a apresentação de todas as variáveis das bacias hidrográficas para a clusterização via algoritmo SOM foi crucial para mudança dos agrupamentos e o conseqüente baixo desempenho da regionalização.

As melhores estatísticas médias verificadas na presente pesquisa, Modelo Chuva-Vazão I - Agrupamento A, foram comparadas com os valores observados e os modelados por Minucci[1]. Conforme se observa nas Tabelas VII e VIII,

Tabela IV  
ESTATÍSTICAS MÉDIAS DA CALIBRAÇÃO E OPERAÇÃO DO MODELO CHUVA-VAZÃO I (4 ENTRADAS, 1 SAÍDA) DE CADA ESTAÇÃO AUXILIAR.

Estação	Treinamento					Operação			
	REQM	NASH	EMA	ER	EM	REQM	NASH	EMA	DV
Balsa do Cantú	39,47	0,38	30,01	-28,86	0,0352	25,61	0,81	19,55	-22,43
ETA Guarapuava	3,46	0,65	2,34	-12,66	0,0164	1,77	0,94	1,34	-7,31
Fazenda Maracanã	3,83	0,70	2,76	-14,13	0,0203	2,78	0,87	2,03	-13,50
Ponte do Goio Bang	10,21	0,40	7,65	-11,82	0,0284	6,92	0,79	5,40	-9,33
Porto Carriel	38,82	0,70	29,62	-19,21	0,0120	23,59	0,94	17,70	-12,81
Porto Guarani	45,65	0,72	35,01	-23,07	0,0137	30,42	0,92	23,12	-14,59
Porto Santo Antônio	17,13	0,24	11,67	-35,62	0,0238	9,29	0,89	6,63	-21,29
Rio dos Patos	13,23	0,69	9,18	-14,57	0,0135	8,71	0,90	6,31	-14,15
São Sebastião	18,50	0,43	13,42	-25,67	0,0238	11,88	0,87	8,41	-17,63
Tereza Cristina	35,53	0,66	26,05	-16,21	0,0155	21,45	0,92	16,02	-11,29
Tormenta Fazenda Trento	5,59	0,37	3,80	-43,25	0,0299	3,63	0,83	2,61	-24,79

REQM: Raiz do Erro Quadrático Médio; NASH: Coeficiente de Nash-Sutcliffe; EMA: Erro Médio Absoluto; DV: Desvio de Vazões (%); ER: Erro Relativo; EM: Erro Médio.

Tabela V  
ESTATÍSTICAS MÉDIAS DA CALIBRAÇÃO E OPERAÇÃO DO MODELO CHUVA-VAZÃO II (13 ENTRADAS, 1 SAÍDA) DE CADA ESTAÇÃO AUXILIAR.

Estação	Treinamento					Operação			
	REQM	NASH	EMA	ER	EM	REQM	NASH	EMA	DV
Balsa do Cantú	38,14	0,13	29,96	-49,05	0,0331	21,34	0,87	17,43	-26,23
ETA - Guarapuava	4,10	0,45	3,03	-22,00	0,0214	1,86	0,93	1,50	-9,02
Fazenda Maracanã	3,73	0,73	2,75	-18,72	0,0197	2,31	0,91	1,77	-12,85
Ponte do Goio Bang	9,72	0,44	7,52	-11,83	0,0257	6,42	0,82	4,93	-7,45
Porto Carriel	58,39	0,38	42,38	-40,86	0,0260	27,69	0,91	20,67	-18,85
Porto Guarani	59,09	0,57	43,31	-30,80	0,0236	31,54	0,91	23,74	-17,21
Porto Santo Antônio	19,81	0,06	14,14	-44,76	0,0297	9,38	0,89	7,06	-23,00
Rio dos Patos	17,09	0,46	12,89	-46,35	0,0217	10,50	0,86	8,09	-31,09
São Sebastião	22,23	0,09	15,62	-26,33	0,0337	12,60	0,85	9,19	-18,47
Tereza Cristina	39,65	0,60	30,15	-28,34	0,0196	20,51	0,92	15,90	-15,74
Tormenta Fazenda Trento	6,01	0,41	4,32	-50,00	0,0352	3,58	0,83	2,68	-23,33

REQM: Raiz do Erro Quadrático Médio; NASH: Coeficiente de Nash-Sutcliffe; EMA: Erro Médio Absoluto; DV: Desvio de Vazões (%); ER: Erro Relativo; EM: Erro Médio.

Tabela VI  
RESUMO DOS VALORES  $R^2$  E NASH OBTIDOS PARA OS DIFERENTES MODELOS E AGRUPAMENTOS UTILIZADOS, ASSIM COMO AS ESTATÍSTICAS ENCONTRADAS POR MINUCCI[1].

			Guampará	Madeira Gavazzoni
Modelo Chuva-Vazão I	Agrup. A	$R^2$	0,82	0,87
		NASH	0,81	0,79
	Agrup. B	$R^2$	0,843	0,877
		NASH	-6,775	-0,18
Modelo Chuva-Vazão II	Agrup. A	$R^2$	0,74	0,88
		NASH	0,71	0,73
	Agrup. B	$R^2$	0,82	0,803
		NASH	-7,08	-0,292
Minucci (2014)	Agrup.	$R^2$	0,82	0,88
		NASH	0,82	0,88

Agrup.: Agrupamento.

as vazões específicas regionalizadas superestimaram a vazão observada, porém com desvios padrão similares.

Tabela VII  
RESULTADOS OBTIDOS POR MINUCCI[1] E PELO AUTOR (2016), COM OS VALORES OBSERVADOS - ESTAÇÃO MADEIREIRA GAVAZZONI.

	Regionalização Minucci[1]	Regionalização (Autor, 2016)	Vazão Observada
Vazão Esp. Média (L/s/km <sup>2</sup> )	30,49	36,34	30,34
Desvio Padrão (L/s/km <sup>2</sup> )	21,34	24,19	23,36
Nash-Sutcliffe	0,88	0,79	-
$R^2$	0,88	0,87	-

Tabela VIII  
RESULTADOS OBTIDOS POR MINUCCI[1] E PELO AUTOR (2016), COM OS VALORES OBSERVADOS - ESTAÇÃO GUAMPARÁ.

	Regionalização Minucci[1]	Regionalização (Autor, 2016)	Vazão Observada
Vazão Esp. Média (L/s/km <sup>2</sup> )	28,09	32,60	30,2
Desvio Padrão (L/s/km <sup>2</sup> )	22,25	22,21	24,45
Nash-Sutcliffe	0,82	0,81	-
$R^2$	0,82	0,82	-

As Tabelas IX e X resumem as estatísticas médias e individuais das RNAs regionalizadas do Agrupamentos A para as estações teste Madeireira Gavazzoni e Guampará. As Figuras 4 e 6 ilustram as relações vazão específica média modelada e vazão observada com a função identidade, visando comparar a qualidade das predições com relação ao ideal (1 : 1). Além disso, são mostradas nas Figuras 5 e 7 o histórico das vazões específicas ao longo do tempo.

Tabela IX  
ESTATÍSTICAS DA REGIONALIZAÇÃO PARA A ESTAÇÃO TESTE MADEIREIRA GAVAZZONI REALIZADAS ATRAVÉS DO MODELO CHUVA-VAZÃO I E DO AGRUPAMENTO A.

Vazões	Cor.	R <sup>2</sup>	NASH	REQM	MAD	DV(%)
Ponto do Goio Bang	0,798	0,637	0,609	13,626	2,345	8,26
Porto Santo Antônio	0,913	0,834	0,783	10,150	0,793	2,79
Rio dos Patos	0,928	0,862	0,668	12,566	7,097	25,00
São Sebastião	0,904	0,818	0,368	17,325	12,19	42,93
M.V.M.	0,932	0,869	0,793	9,926	5,606	19,74

Cor.: Correlação Linear; REQM: Raiz do Erro Quadrático Médio; NASH: Coeficiente de Nash-Sutcliffe; MAD: Média Absoluta dos Desvios; DV: Desvio de Vazões (%).  
M.V.M.: Média das Vazões Modeladas.

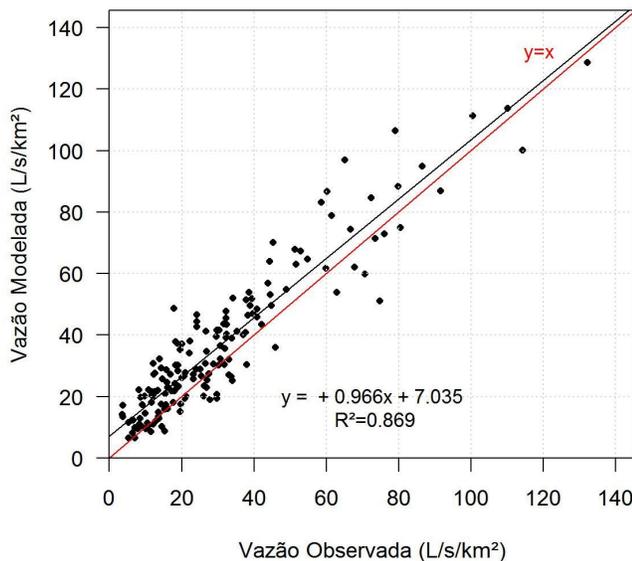


Figura 4. Relação Vazão específica média modelada x Vazão específica observada para a estação teste Madeireira Gavazzoni através do Modelo Chuva-Vazão I e do agrupamento A.

## V. CONCLUSÃO

No geral, com relação à análise de *clusters* realizada nesta pesquisa, verificou-se que o algoritmo SOM identificou 9 estações fluviométricas, de um total de 16, nos mesmos grupos dos formados por Minucci[1] — considerando os mesmos dados de entrada; o que representa uma diferença razoável

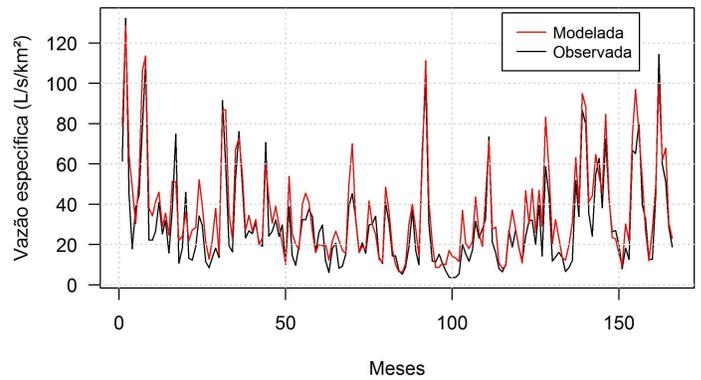


Figura 5. Vazão específica média modelada e observada ao longo do tempo para a estação teste Madeireira Gavazzoni através do Modelo Chuva-Vazão I e do agrupamento A.

Tabela X  
ESTATÍSTICAS DA REGIONALIZAÇÃO PARA A ESTAÇÃO TESTE GUAMPARÁ REALIZADAS ATRAVÉS DO MODELO CHUVA-VAZÃO I E DO AGRUPAMENTO A.

Vazões	Cor.	R <sup>2</sup>	NASH	REQM	MAD	DV(%)
Ponto do Goio Bang	0,752	0,566	0,535	16,625	0,619	2,051
Porto Santo Antônio	0,908	0,824	0,795	11,047	-3,45	-11,58
Rio dos Patos	0,891	0,793	0,716	13,002	5,115	16,936
São Sebastião	0,881	0,777	0,594	15,536	8,149	26,985
M.V.M.	<b>0,906</b>	<b>0,82</b>	<b>0,809</b>	<b>10,655</b>	<b>2,597</b>	<b>8,598</b>

Cor.: Correlação Linear; REQM: Raiz do Erro Quadrático Médio; NASH: Coeficiente de Nash-Sutcliffe; MAD: Média Absoluta dos Desvios; DV: Desvio de Vazões (%).  
M.V.M.: Média das Vazões Modeladas.

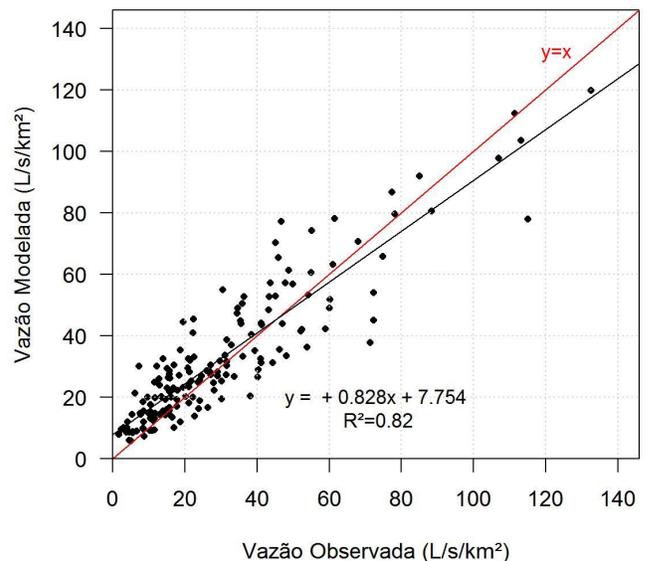


Figura 6. Relação Vazão específica média modelada x Vazão específica observada para a estação teste Guampará através do Modelo Chuva-Vazão I e do agrupamento A.

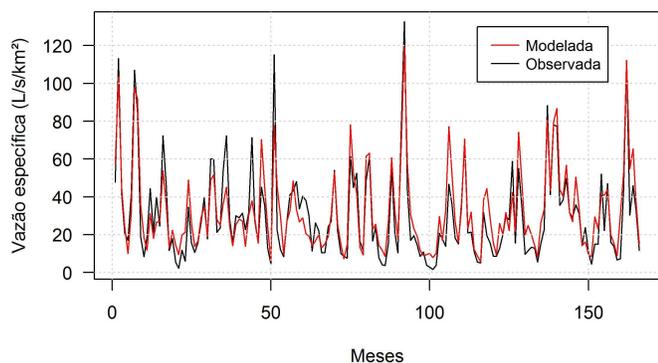


Figura 7. Vazão específica média modelada e observada ao longo do tempo para a estação teste Guampará através do Modelo Chuva-Vazão I e do agrupamento A.

com relação aos resultados da aplicação do método tradicional *k-means*. Contudo, conforme exposto, tendo em vista que as estações teste foram encontradas entre as oito estações que mudaram de *cluster*, se verificaram maiores diferenças no momento da regionalização.

A modelagem chuva-vazão apresentou índice de determinação e Nash-Sutcliffe baixos durante sua calibração, e satisfatórios para a operação, sendo que os dados de precipitação média mensal de Thiessen foram os *inputs* de precipitação que apresentaram melhores desempenhos; o que pode representar uma vantagem na aplicabilidade da abordagem da regionalização reproduzida.

A série de vazões regionalizadas para as duas estações teste apresentaram resultados satisfatórios — em se tratando do Modelo Chuva-Vazão I, Agrupamento A — com índices de determinação, NASH e REQM adequados, quando confrontados os registros observados e modelados. Os desvios de vazão *DV* foram positivos para ambas as estações, indicando que, na média dos valores, o modelo superestimou as vazões observadas; o coeficiente de determinação  $R^2$  superior a 0,8 indicou uma relação linear satisfatória entre os valores observados e modelados; e os desvios médios absolutos foram baixos, sendo inferiores a  $6 \text{ m}^3/\text{s}$ . Além disso, o modelo identificou as máximas vazões mensais satisfatoriamente, conforme Figuras 5 e 7 - evidenciando a característica da RNA tipo RBF de gerar aproximações locais do valor modelado. Finalmente, conclui-se que a metodologia analisada nesta pesquisa permite a obtenção de resultados adequados para aplicação em regionalização de vazões.

## REFERÊNCIAS

- [1] L. R. Minucci. Regionalização de série de vazões mensais utilizando redes neurais artificiais. Mestrado em engenharia de recursos hídricos e ambiental, Programa de Pós Graduação em Engenharia de Recursos Hídricos e Ambiental - Universidade Federal do Paraná, Curitiba, 2014.
- [2] MME. Portaria nº 463, de 03 de dezembro de 2009, alterada pela portaria mme nº 376, de 05 de agosto de 2015. Technical report, Brasil, 2009. Suplemento.
- [3] L. S. Diniz. *Regionalização de parâmetros de modelo chuva-vazão usando redes neurais*. Doutorado em engenharia, Programa de Pós Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

- [4] I. S. Saraiva. Regionalização de parâmetros de modelos de simulação hidrológica para emprego em bacias hidrográficas sem monitoramento fluviométrico. Mestrado em meio ambiente e recursos hídricos, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.
- [5] C E M Tucci. *Regionalização de Vazões*, chapter 15, pages 573–611. UFGRS - Universidade Federal do Rio Grande do Sul, ABRH - Associação Brasileira de Recursos Hídricos, Porto Alegre, 4 edition, 2007.
- [6] C E M Tucci. *Modelos Hidrológicos*. Cambridge, Porto Alegre, 2 edition, 1998.
- [7] H R Maier and G C Dandy. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*, 15:101–124, mar. 1999.
- [8] S. Haykin. *Neural Networks and Learning Machines*. PEARSON Prentice Hall, Canadá, 3 edition, 1999. Bibliografia: p. 847–938.
- [9] A M Kalteh, PHjorth, and R Berndtsson. Review of the self-organizing map (som) approach in water resources: Analysis, modelling and application. *Environmental Modelling & Software*, 23:835 – 845, nov. 2007.
- [10] G J Bowden, G C Dandy, and H R Maier. Input determination for neural network models in water resources applications: Part 1 - background and methodology. *Journal of Hydrology*, 301:75–92, 2005.