

# Previsão de Cheias do Rio Itajaí-Açu Utilizando Redes Neurais Artificiais

Daniel Gomes Soares<sup>1</sup>, Raimundo Celeste Ghizoni Teive<sup>2</sup>

<sup>1</sup>Curso de Ciência da Computação – Instituto Federal Catarinense (IFC) – Rio do Sul, SC – Brasil

<sup>2</sup>Mestrado em Computação Aplicada – Centro de Ciências Tecnológicas da Terra e do Mar (CTTMAR) – Universidade do Vale do Itajaí (Univali) – Itajaí, SC - Brasil

[daniel@ifc-riodosul.edu.br](mailto:daniel@ifc-riodosul.edu.br), [rteive@univali.br](mailto:rteive@univali.br)

**Abstract.** *The river floods are natural phenomena that cause socio-economic losses in many parts of the world. Measures can be taken to mitigate the damage, this can be of two types: structural and non-structural. In this research was developed a model of short term flood forecasting, which is a non-structural measure, using for this Artificial Neural Networks (ANN). The municipality of Rio do Sul-SC was chosen as the study area. The performances of the ANNs are presented through graphs and statistical indices. The results show that it is possible to forecast floods in the study area, with acceptable error and time in advance to be used as a non-structural measure of a system of flood warning, by using ANNs and taking as input rainfall data and river level.*

**Resumo.** *As cheias dos rios são fenômenos naturais que causam prejuízos socioeconômicos em diversas partes do mundo. Medidas podem ser tomadas para atenuar os prejuízos, estas podem ser de dois tipos: estruturais e não-estruturais. Neste trabalho foi desenvolvido um modelo de previsão de cheias em curto prazo, que é uma medida não-estrutural, utilizando, para isto, Redes Neurais Artificiais (RNAs). O município de Rio do Sul-SC foi o local escolhido como área de estudo. O desempenho das RNAs modeladas é analisado por meio de índices estatísticos e gráficos. Os resultados demonstram que é possível fazer previsão de cheias na área de estudo, com erro e antecedências aceitáveis para ser utilizado como uma medida não-estrutural de um sistema de alerta de cheias, utilizando-se RNAs e tendo como entrada dados de precipitação e nível do rio.*

## 1. Introdução

As cheias são fenômenos naturais registrados desde a antiguidade e que fazem parte, na maioria das vezes, do ciclo hidrológico natural das águas. Os problemas resultantes dessas inundações naturais vêm do fato de a várzea ser frequentemente ocupada pela população, seja para habitação, uso agrícola, comercial ou industrial.

Para se reduzirem os impactos catastróficos que esses eventos causam, medidas podem ser tomadas, sendo que essas medidas podem ser do tipo estrutural e não-

estrutural. As medidas estruturais são aquelas que modificam o sistema fluvial evitando os prejuízos decorrentes das cheias. Este tipo de medida tem um alto custo e dificilmente resolve totalmente o problema. Por outro lado, as medidas não-estruturais têm baixo custo de implantação e não modificam o sistema fluvial, são projetadas não para dar uma proteção completa, mas para reduzirem os impactos causados pelas cheias.

Nesse sentido, a previsão de cheias em curto prazo tem-se apresentado como uma das medidas não-estruturais mais eficientes para atenuar os prejuízos econômicos e a perda de vidas causadas pelas cheias dos rios.

Na última década, as Redes Neurais Artificiais (RNAs) vêm sendo amplamente utilizadas na previsão de séries temporais em geral e de vazão ou nível de rio com foco na previsão de cheias de forma particular. Isto acontece principalmente devido à facilidade em comparação aos modelos hidrológicos conceituais, os quais exigem a coleta de diversos dados hidrológicos que, na maior parte dos casos, não estão disponíveis e, mesmo estando, tornariam a previsão de curto prazo um processo complexo e demorado.

Segundo Gopakumar e Takara (2009), a principal vantagem das técnicas baseadas em Redes Neurais são a sua capacidade de modelar as relações de entrada-saída não-lineares, característica marcante dos processos hidrológicos, sem a necessidade de saber todos os detalhes dos processos físicos e suas interações. Para Gomes, Montenegro e Valença (2010), estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries hidrológicas, tais como sazonalidade, periodicidade e tendência, muitas vezes, camufladas por ruídos.

Vários autores têm apresentado resultados satisfatórios na previsão de cheias utilizando RNAs (Napolitano et al., 2010; Gopakumar & Takara 2009; Freitas & Silva, 2011; Adnan et al., 2012; Dornelles, 2007; XIE et al., 2010), sendo que todos encontraram resultados melhores que os obtidos com outros modelos hidrológicos.

Este trabalho apresenta os resultados de um modelo de previsão de cheias do rio Itajaí-Açu com 6 horas de antecedência, que utilizou Redes Neurais Artificiais do tipo MLP, considerando como dados de entrada precipitação e nível do rio de duas estações localizadas à montante do ponto de interesse.

## **2. Redes Neurais Artificiais**

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais) (SILVA; SPATTI; FLAUZINO, 2010).

Silva, Spatti e Flauzino (2010), afirmam que as características mais atrativas das RNAs, fazendo destas ferramentas poderosas para aplicação em diversos tipos de problemas, consistem de suas elevadas habilidades em mapear sistemas não-lineares, aprendendo os comportamentos a partir de informações (medidas, amostras ou padrões) obtidas.

A arquitetura de uma RNA define a forma como os neurônios estão arran­jados uns em relação os outros. Já a topologia, define a maneira com que os vários neurônios constituintes de uma RNA são interconectados (GOMES; MONTENEGRO, 2010).

### 2.1 Rede Multilayer Perceptron (MLP).

As RNAs do tipo MLP são caracterizadas por conterem, pelo menos, uma camada intermediária ou escondida. De acordo Haykin (2001), estas redes apresentam um poder computacional muito maior do que as redes sem camadas escondidas, pois possuem a capacidade de tratar problemas que não são linearmente separáveis, como é o caso da previsão de cheias em rios.

O MLP convencional pertence à arquitetura *feedforward* com múltiplas camadas, sendo o treinamento realizado de forma supervisionada. Nesta estratégia de treinamento, para cada amostra dos sinais de entrada é disponibilizada juntamente a saída desejada. Desta forma, cada amostra de treinamento é composta pelos sinais de entrada e suas respectivas saídas. Este tipo de treinamento é o mais utilizado em problemas de previsão hidrológica, inclusive para previsão de cheias. Nesse caso, durante o treinamento da RNA, os sinais de entrada, geralmente nível do rio, e/ou vazão e/ou precipitação, são disponibilizados juntamente com a saída, comumente o nível do rio, de um posto a jusante dos postos de coleta que forneceram os sinais de entrada.

O algoritmo mais tradicional utilizado no treinamento do MLP é o algoritmo de retropropagação do erro ou *backpropagation*, conhecida também como regra delta generalizada.

A utilização do algoritmo *backpropagation* convencional na prática tende a convergir de forma demasiadamente lenta, exigindo-se, assim, um elevado esforço computacional. Algumas das alternativas para tornar o processo de convergência da rede mais eficiente são: a inserção do termo de *momentum*, ou a utilização de variantes do *backpropagation* como o algoritmo de Levenberg-Marquardt e a Regularização Bayesiana.


## 3. Material e Métodos

### 3.1 Área de Estudo

A bacia hidrográfica do rio Itajaí está localizada na vertente atlântica do Estado de Santa Catarina, entre as coordenadas 26°22' e 27°53' de latitude sul e 48°30' e 50°22' de longitude oeste. De acordo Shult et al. (2013), esta é a maior bacia da vertente atlântica do Estado de Santa Catarina, abrangendo uma área de aproximadamente 15.000km<sup>2</sup>, dividida em três compartimentos naturais: o Alto, o Médio, e o Baixo Vale do Itajaí. O maior curso d'água da bacia é o rio Itajaí-Açu, formado pela junção dos rios Itajaí do Oeste e Itajaí do Sul no município de Rio do Sul.

As chuvas da bacia do rio Itajaí-Açu são bem distribuídas ao longo do ano, sendo que nas estações mais quentes elas são de maior intensidade, mas, geralmente, de duração curta, sendo este tipo de chuva mais propício a causar enxurradas. Nas estações mais frias, elas são menos intensas, porém mais duradouras, sendo estas as chuvas mais favoráveis a eventos geradores de enchentes (CORDERO; MOMO; SEVERO, 2011).

O local selecionado para as previsões de cheias está localizado no Alto Vale do Itajaí no município de Rio do Sul. Segundo Cordero, Momo e Severo (2011), a cidade de Rio do Sul encontra-se entre a Serra do Mar e Serra Geral e sua população é de cerca de 60.000 habitantes. A área de drenagem da bacia é de aproximadamente 5.100,00 km<sup>2</sup> até a estação fluviométrica de Rio do Sul. A precipitação pluviométrica ao ano pode variar de 1.320 a 1.640mm, com o total anual de dias de chuva entre 130 e 165 dias. A cidade de Rio do Sul é mostrada na Figura 1, com os Rios Itajaí do Oeste (abaixo à esquerda), Itajaí do Sul (abaixo à direita) e a junção dos dois rios ao centro, formando o rio Itajaí-Açu.



**Figura 1. Rio do Sul - SC**

O convívio com as cheias do rio Itajaí-Açu e, conseqüentemente, os problemas causados por estas, são registrados desde os primeiros povoamentos na região por volta de 1850. Os registros históricos indicam a região como um cenário expressivo para ocorrência de eventos de cheia. Na cidade de Rio do Sul, foram registrados diversos desses eventos no decorrer da sua história. Há registros de grandes inundações nos anos de 1927 (12m), 1954 (11,84m), 1983 (15,08m), 1984 (13,64m), 2011 (12,98m) e 2013 (10,32m).

### **3.2 Dados Disponíveis**

Os dados observados na bacia do rio Itajaí-Açu são registrados pela rede telemétrica da Agência Nacional de Águas (ANA) e operadas pela Epagri. Para esta pesquisa, que levou em consideração a configuração geográfica da bacia, os dados disponíveis são dos postos de coleta localizados nos municípios de Ituporanga, Taió e Rio do Sul, sendo os dados dos dois primeiros postos utilizados como entradas do modelo (nível do rio e precipitação para ambas as entradas) e nível do rio em Rio do Sul como saída.

Os dados utilizados no treinamento e testes das RNAs estão no intervalo entre 08/2005 e 02/2014. Estes dados foram obtidos no Sistema de Informações Hidrológicas (Hidroweb) da ANA.

### 3.3 RNA Proposta

As RNAs construídas neste trabalho são do tipo MLP e possuem quatro entradas, uma camada oculta com  $n$  neurônios e um neurônio na camada de saída (ver Figura 2). A opção pela utilização de uma camada oculta foi definida após a realização de alguns testes preliminares, em que se observou que o uso de mais do que uma camada não produzia melhorias significativas nos resultados, apenas aumentava consideravelmente o tempo de treinamento.

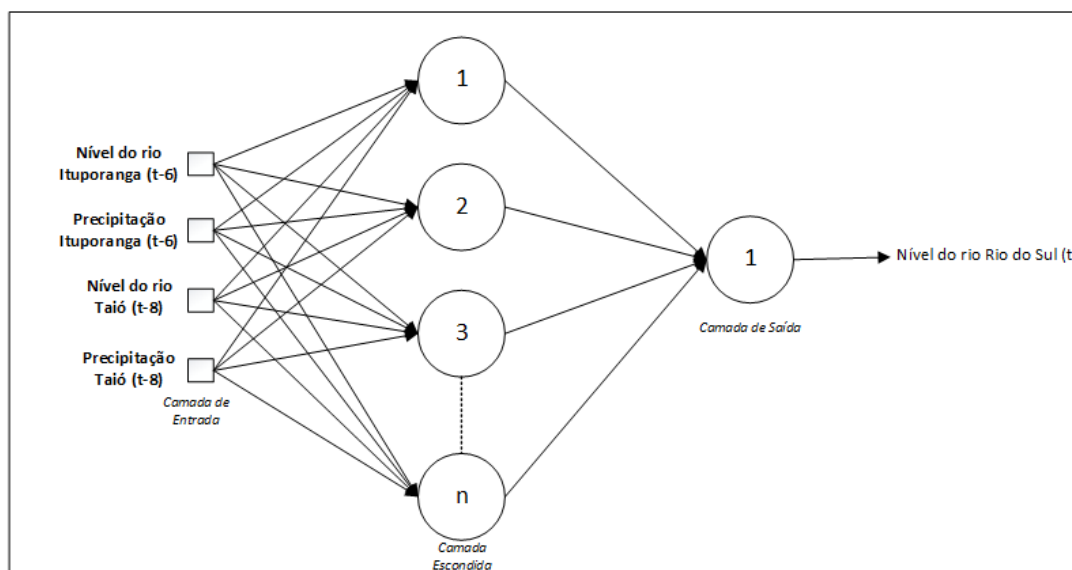


Figura 2. Modelo de RNA para previsão de cheias na área de estudo

As RNAs utilizadas nesta pesquisa foram construídas, treinadas e testadas utilizando-se a *toolbox* de Redes Neurais do software Matlab. As funções de ativação utilizadas na camada escondida das redes foram a TANSIG (sigmoide tangente hiperbólica) e LOGSIG (sigmoide logística). Na camada de saída foi utilizada a função purelin (linear). Os algoritmos de treinamento utilizados foram o TrainGDM (Gradiente Descendente com *momentum*), TrainLM (Levenberg-Marquardt) e TrainBR (Regularização Bayesiana).

### 3.4 Índices para Análise da Qualidade da Previsão

Para avaliar o desempenho de todas as RNAs utilizaram-se três estatísticas: Coeficiente de Eficiência de Nash e Sutcliffe (CE), RMSE (*Root Mean Square Error*) e MAPE (*Mean Absolute Percentage Error*).

- i) **Coeficiente de Eficiência de Nash e Sutcliffe:** Este índice é frequentemente utilizado para avaliar o poder preditivo de modelos hidrológicos, sendo o resultado produzido idêntico ao do coeficiente de determinação  $R^2$  usado na regressão linear. O CE pode variar de  $-\infty$  a 1. Uma eficiência de 1 ( $CE = 1$ ) corresponde a um ajuste perfeito entre as previsões produzidas pelo modelo e os dados observados, portanto, quanto mais próximo de 1 for o CE, mais preciso é o modelo. O CE é expresso pela Eq. 1.

$$CE = 1 - \frac{\sum_{i=1}^n (Qo_i - Qp_i)^2}{\sum_{i=1}^n (Qo_i - \overline{Qo})^2} \quad (1)$$

Onde  $Qo_i$  representa o valor observado,  $Qp_i$ , o valor previsto, e  $\overline{Qo}$  o valor médio dos valores observados.

**ii) Raiz do Erro Quadrático Médio (RMSE):** O RMSE é um índice comumente utilizado das diferenças entre os valores previstos pelo modelo e os valores observados. Essas diferenças individuais são também chamadas de resíduos e o RMSE serve para agrega-los em uma única medida de qualidade da previsão. Tem valor sempre positivo e quanto mais próximo de zero, maior a qualidade dos valores previstos (HYNDMAN; KOEHLER, 2006). A Eq. 2 expressa o RMSE.

$$RMSE = \sqrt{\frac{\sum (Q_{obs} - Q_{cal})^2}{N}} \quad (2)$$

onde  $Q_{obs}$  representa o valor observada,  $Q_{cal}$ , o valor previsto pela rede e  $N$  o número de pontos utilizados no treinamento.

**iii) Erro Médio Percentual Absoluto (MAPE):** Este índice é uma das métricas mais frequentemente utilizadas para avaliar métodos de previsão. Segundo Lopes (2002), o erro médio percentual absoluto é a média de todos os erros absolutos percentuais, fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente do erro ser positivo ou negativo. O MAPE é expresso pela Eq. 3.

$$MAPE = \frac{\sum_{t=1}^n |EP_t|}{n} \quad (3)$$

Onde  $|EP_t|$  representa o módulo do erro médio percentual e  $n$  o número de pontos utilizados no treinamento.

#### 4. Resultados e Discussão

Um total de 416 alternativas de RNAs MLP foram construídas e testadas. Os parâmetros alterados em cada alternativa foram o número de neurônios na camada oculta, que foi entre três e dez, a função de ativação da camada oculta (TANSIG e LOGSIG) e o algoritmo de treinamento (TrainLM, TrainBR e TrainGDM). Alguns testes foram realizados com mais de dez neurônios na camada intermediária, no entanto, a rede não produzia melhoras significativas nos resultados, aumentando de maneira considerável o tempo de treinamento. Além disso, cada alternativa de RNA foi treinada 30 vezes, com o objetivo de minimizar os efeitos causados pela aleatoriedade das condições iniciais.

Do total de RNAs construídas, 16 foram treinadas com o algoritmo TrainLM, 16 com TrainBR e 384 com o TrainGDM. O ajuste dos pesos e *bias* durante o treinamento

foi realizado conforme a função de desempenho escolhida, que no caso deste trabalho, manteve a função padrão do Matlab o erro quadrático médio (MSE), calculado a partir da saída produzida pela rede e as saídas desejadas (*targets*).

Inicialmente 16 redes foram treinadas com o algoritmo TrainGDM, no entanto, estas redes produziram resultados com erros consideravelmente maiores quando comparadas com as RNAs treinadas com os outros algoritmos. Dessa forma, mais 368 novas RNAs foram treinadas com este método, modificando-se, dessa vez, a taxa de aprendizagem e o termo de *momentum*, que tinham sido deixados com os valores padrão do Matlab. Contudo, apesar do erro ter diminuído, quando comparadas com as redes treinadas com os outros algoritmos utilizados, as MLPs treinadas com o método TrainGDM apresentaram, no geral, resultados com maior erro.


Os resultados produzidos pelas três melhores redes quando apresentadas ao conjunto de testes são apresentados na Tabela 1. A configuração das RNAs é identificada na primeira coluna da tabela, por meio da seguinte definição de siglas:

- (i)N: RNA com “i” neurônios na camada oculta;
- Tan: função TANSIG na camada oculta;
- Log: função LOGSIG na camada oculta;
- LM, BR: algoritmos de treinamento TrainLM e TrainBR respectivamente.


**Tabela 1. Desempenho das melhores configurações**

<b>Modelo</b>	<b>CE</b>	<b>RMSE</b>	<b>MAPE</b>
6N_Log_BR	0,9788	0,0202	5,8024
9N_Log_LM	0,9779	0,0201	5,7625
9N_Tan_BR	0,9776	0,0199	5,7982


O maior CE (0,9788) foi obtido pela configuração treinada com 6 neurônios na camada oculta, função de ativação LOGSIG e o algoritmo TrainBR. No entanto, nos outros índices utilizados duas RNAs com 9 neurônios na camada oculta obtiveram melhores resultados. A rede treinada com o algoritmo TrainLM e função de ativação LOGSIG obteve menor MAPE (5,7625), e a rede treinada com o algoritmo TrainBR e função TANSIG obteve o menor RMSE (0,0199). Excluindo o índice CE, as RNAs com 9 neurônios obtiveram melhores resultados em comparação com a rede de 6 neurônios nas outras duas métricas (RMSE e MAPE em ambas). Portanto levando-se em consideração os três índices utilizados, as redes com maior complexidade (com 9 neurônios na camada oculta) apresentaram melhores desempenhos e maior poder de generalização que a rede com menor CE e as redes de menor complexidade no geral.



**Figura 3. Gráfico do nível calculado e observado da MLP 6N\_Log\_BR que obteve o maior CE**



**Figura 4. Gráfico do nível calculado e observado da MLP 9N\_Tan\_BR que obteve o menor RMSE**



**Figura 5. Gráfico do nível calculado e observado da MLP 9N\_Log\_LM que obteve o menor MAPE**

Na Figura 3 são apresentados os níveis calculados e observados da rede que obteve o maior CE. As maiores diferenças ocorreram em alguns níveis calculados em torno de 4 metros, cujo modelo calculou valores menores que os observados. No entanto, o maior interesse deste trabalho são as previsões de nível de água alto que, no caso da região de estudo selecionada, são os níveis acima de 6,5 metros. Para esta faixa, os valores calculados e observados estão com, praticamente, nenhuma diferença.

Assim como a rede 6N\_Log\_BR, a rede 9N\_Tan\_BR, também produziu resultados muito parecidos com os níveis observados, conforme pode ser observado na Figura 4. A mesma imprecisão em alguns níveis calculados em torno de 4 e 5 metros também pode ser observada nesta rede. Entretanto, para valores de nível de água alto, os níveis calculado e observado estão muito próximos.

Na Figura 5 podem ser vistos os níveis calculados e observados da rede que obteve o menor MAPE (9N\_Log\_LM). Assim como nas duas outras RNAs que obtiveram os melhores CE e RMSE (Figura 3 e Figura 4), imprecisões para alguns níveis calculados no intervalo entre 4 e 5 metros também ocorreram, mas para os valores de nível de água alto, ponto de interesse deste trabalho, a diferença entre observado e calculado foi praticamente nenhuma.

Embora, no geral, as RNAs testadas apresentarem bons resultados, comparando as redes com os melhores desempenhos, as alternativas com 9 neurônios na camada oculta apontaram resultados ligeiramente superiores que a rede com 6 neurônios na camada oculta (6N\_Log\_BR). Na comparação entre as duas redes com 9 neurônios, a rede 9N\_Log\_LM obteve melhor CE (0,9779) e o menor MAPE (5,7628), enquanto que a rede 9N\_Tan\_BR obteve somente o melhor RMSE (0,0199). Dessa forma, a rede MLP que produziu os resultados com menores erros de acordo com as métricas utilizadas foi



a rede com 9 neurônios na camada oculta, função de ativação LOGSIG e algoritmo de treinamento TrainLM.

Os resultados apresentados pela rede 9N\_Log\_LM demonstram que é possível fazer a previsão de cheias em curto prazo na área de interesse, utilizando RNAs e somente dados de precipitação e nível do rio, conforme pode ser observado na análise dos resultados. No entanto, cabe salientar que, como toda modelagem matemática, a generalização dos resultados obtidos em um estudo de caso específico não pode ser utilizada diretamente para outros casos (outros rios, bacias, etc). Deve-se levar em consideração que os processos hidrológicos de cada região são únicos, principalmente para modelagem de eventos extremos, como as cheias, sendo a utilização do modelo construído neste trabalho restrita a área de estudo selecionada.

## 5. Conclusões

Esta pesquisa se propôs a realizar a previsão de cheias em curto prazo numa área específica, utilizando Redes Neurais Artificiais. A área de estudo escolhida foi o município de Rio do Sul, que possui um extenso histórico de cheias, inclusive recentes (2011 e 2013).

Um total de 416 configurações de RNAs MLP foram construídas. O melhor desempenho dentre todas as configurações foi o da rede 9N\_Log\_LM, com 9 neurônios na camada oculta, função de ativação logística e algoritmo de treinamento TrainLM. Esta rede produziu as previsões de melhor qualidade dentre todas as MLPs com CE, RMSE e MAPE de 0.9779, 0.0201 e 5.625, respectivamente.

Contudo, cabe destacar que apesar da rede 9N\_Log\_LM ter obtido o melhor desempenho, no geral, praticamente todas as alternativas apresentaram bons resultados com CE acima de 0.95 e MAPE abaixo de 6%, isso demonstrou a eficiência e a aplicabilidade das Redes Neurais neste tipo de problema, principalmente em regiões com poucos dados disponíveis, como é o caso da região de estudo deste trabalho, onde não é possível utilizar modelos mais sofisticados e que necessitam um elevado número de parâmetros para serem calibrados.

## Referências

- ADNAN, R., RUSLAN, F. A., SAMAD, A. M., ZAIN, Z. M. Artificial neural network modelling and flood water level prediction using extended Kalman filter. In: International Conference on Control System, Computing and Engineering, Penang, Malaysia. Proceedings... IEEE, 2012.
- CORDERO, A.; MOMO, M. R.; SEVERO, D. L. Previsão de cheia em tempo atual com um modelo armax, para a cidade de Rio do Sul-SC. In: XIX Simpósio Brasileiro de Recursos Hídricos Maceió - AL, 2011. Anais... Maceió, 2011.
- DORNELLES, F. Previsão contínua de níveis fluviais com redes neurais utilizando previsão de precipitação. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.
- FREITAS, M. C., SILVA, G. B. L. Estimativa de vazões diárias em rios a partir de vazões a montante usando Redes Neurais Artificiais. XIX Simpósio Brasileiro de Recursos Hídricos. Maceió, 2011.

- GOMES, L. F. C., MONTENEGRO, S. M. G. L., VALENÇA, M. J. S. Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco. *Revista Brasileira de Recursos Hídricos*, 15(1), 05-15, 2010.
- GOPAKUMAR, R.; TAKARA, K. Water Level Forecasting in the Vembanad Water System Using Artificial Neural Networks. In: *International Conference on Advances in Recent Technologies in Communication and Computing*, Washington, DC, USA. Proceedings... IEEE, 2009.
- HAYKIN, S. *Redes Neurais: princípios e prática*. 2ª ed. Porto Alegre: Bookman, 2001.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, no. 4, p. 679-688, 2006.
- LOPES, R. D. *Previsão de autopeças: Estudo de caso em uma concessionária de veículos*. Dissertação (Mestrado em Engenharia de Produção), Universidade Federal de Santa Catarina, Florianópolis, 2002.
- NAPOLITANO, G., SEE, L., CALVO, B., SAVI, F., HEPPENSTALL, A. A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome. *Physics and Chemistry of the Earth, Parts A/B/C*, v. 35, n. 3-5, p. 187-194, 2010.
- SHULT, I., RUDOLPHO, L. S., GHODDOSI, S. M., NOLL, J. F., BACK, C. C., KONDLATSCH, K. M. S. Planejamento Territorial e Recursos Hídricos: As Áreas Protegidas no Entorno de Corpos de Água na Bacia Hidrográfica do Rio Itajaí (SC). In: *XX Simpósio Brasileiro de Recursos Hídricos*, Bento Gonçalves – RS, 2013. Anais... Bento Gonçalves, 2013.
- SILVA, I.N., SPATTI, D., e FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático*. Artliber Editora Ltda, São Paulo, 2010.
- XIE, J. C., TIAN-PING, W., JIAN-LONG, Z., SHEN, Y. A Method of Flood Forecasting of Chaotic Radial Basis Function Neural Network. *Intelligent Systems and Applications (ISA)*, 2010.