

CENTRO UNIVERSITÁRIO SAGRADO CORAÇÃO

RODRIGO TEIXEIRA TAVARES

PREVISÃO DE VAZÕES AFLUENTES UTILIZANDO REDES NEURAIS

BAURU

2023

RODRIGO TEIXEIRA TAVARES

PREVISÃO DE VAZÕES AFLUENTES UTILIZANDO REDES NEURAIAS

Trabalho de Conclusão de Curso apresentado como parte dos requisitos para obtenção do título de bacharel em Engenharia Elétrica - Centro Universitário Sagrado Coração.

Orientador: Prof. Dr. Tiago Forti da Silva.

BAURU

2023

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

T231p

Tavares, Rodrigo Teixeira

Previsão de vazões afluentes utilizando redes neurais / Rodrigo Teixeira Tavares. -- 2023.
24f. : il.

Orientador: Prof. Dr. Tiago Forti da Silva

Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica)
- Centro Universitário Sagrado Coração - UNISAGRADO - Bauru - SP

1. Redes Neurais. 2. Vazão Afluente. 3. Geração De Energia Hidrelétrica. I. Silva, Tiago Forti da. II. Título.

RODRIGO TEIXEIRA TAVARES

PREVISÃO DE VAZÕES AFLUENTES UTILIZANDO REDES NEURAIS

Trabalho de Conclusão de Curso apresentado como parte dos requisitos para obtenção do título de bacharel em Engenharia Elétrica - Centro Universitário Sagrado Coração.

Aprovado em: ___/___/___.

Banca examinadora:

Prof. Dr. Tiago Forti da Silva (Orientador)
Centro Universitário Sagrado Coração

Titulação, Nome
Instituição

Titulação, Nome
Instituição

SUMÁRIO

1	INTRODUÇÃO	8
2	REVISÃO BIBLIOGRÁFICA	10
2.1	SISTEMA HÍDRICO	10
2.1.1	Geração de energia elétrica	11
2.1.1.1	<i>Previsão de Vazão de afluentes</i>	12
2.2	SÉRIES TEMPORAIS E TÉCNICAS DE PREVISÃO.....	14
2.2.1	Redes Neurais Artificiais	14
2.2.1.1	<i>Neurônio artificial e funções de ativação</i>	15
2.2.1.2	<i>Aprendizado e treinamento</i>	16
3	MATERIAL E MÉTODOS	17
4	RESULTADOS E DISCUSSÃO	18
5	CONCLUSÃO	20
	REFERÊNCIAS	21
	ANEXO 1	23

RESUMO

A capacidade de geração de energia hidrelétrica está vinculada com a disponibilidade de água nos reservatórios das usinas, tornando a capacidade de previsão da vazão afluente um aspecto relevante para a companhia geradora e para o setor elétrico. Dessa forma, esta pesquisa utilizou redes neurais artificiais do tipo perceptron multicamadas para estimar a vazão afluente da Usina Hidrelétrica de Água Vermelha. A partir dos dados reais disponibilizados pela Agência Nacional de Águas – ANA. Obteve-se previsões com erros percentuais dentro do aceitável indicando o potencial apresentado pelas redes perceptron multicamadas para a previsão de séries temporais de vazão de afluente.

Palavras-chave: Redes neurais; vazão afluente; geração de energia hidrelétrica.

ABSTRACT

The capacity to generate hydroelectric power is closely associated with the presence of water in power plant reservoirs, underscoring the significance of predicting inflow discharge for both the generating company and the broader electrical sector. Consequently, this study employed artificial neural networks of the multilayer perceptron variety to estimate the inflow discharge of the Água Vermelha Hydroelectric Plant. Utilizing authentic data supplied by the National Water Agency (ANA), the predictions yielded percentage errors within acceptable thresholds, thereby demonstrating the potential efficacy of multilayer perceptron networks in forecasting time series of inflow discharge

Keywords: Neural Networks; predicting inflow discharge; generate hydroelectric power.

1 INTRODUÇÃO

O parque gerador de energia elétrica no Brasil é predominantemente composto por usinas hidrelétricas, sendo que a sua operação possui grande impacto na operação do setor elétrico, garantindo a segurança do fornecimento de energia no balanço carga-frequência e na definição do preço horário da energia elétrica. Em Agosto de 2023 a matriz energética hidráulica foi responsável por gerar no país 39.621 MWmed de 75.409 MWmed, correspondendo a 52,54% da energia gerada total segundo o Operador Nacional do Sistema Elétrico (ONS, 2023), conforme mostra a Tabela 1.

Tabela 1 - Balanço de Energia Diário.

Sistema Interligado Nacional - SIN - MWmed		
Produção		
Hidro Nacional	39.621	52,54%
Itaipu Binacional	7.097	9,41%
Termo Nuclear	2.013	2,67%
Termo Convencional	7.673	10,18%
Eólica	12.797	16,97%
Solar	6.207	8,23%
Total SIN	75.409	100,00%

Fonte: ONS (2023).

O ONS utiliza técnicas de previsão de demanda de energia elétrica, antecipando assim a quantidade de energia necessária para atender a demanda dos consumidores, analisando mensalmente, semanalmente e diariamente, garantindo a eficiência do Sistema Interligado Nacional (SIN).

Prever a vazão de afluentes de forma confiável é importante para o sistema elétrico, uma vez que necessário determinar a quantidade de água que será transferida do período chuvoso para o seco. Uma previsão adequada também colabora para a escolha de melhores pontos de operação para as usinas permitindo gerar mais energia com a mesma quantidade de água turbinada.

Uma das técnicas utilizadas que podem ser utilizadas para a estimação de séries temporais são as Redes Neurais Artificiais (RNA), que são modelos matemáticos computacionais inspirados no cérebro humano, a fim de processar informações e aprender a reconhecer padrões (HAYKIN, 2001). Softwares com ferramentas preparadas para

processarem essas informações levantadas ao longo do tempo, como dados históricos de chuvas, podem ser utilizados para fornecerem um padrão adotado dessas vazões.

As redes neurais podem ser treinadas com dados históricos de vazão e variáveis meteorológicas para aprender padrões e relações complexas que influenciam as vazões.

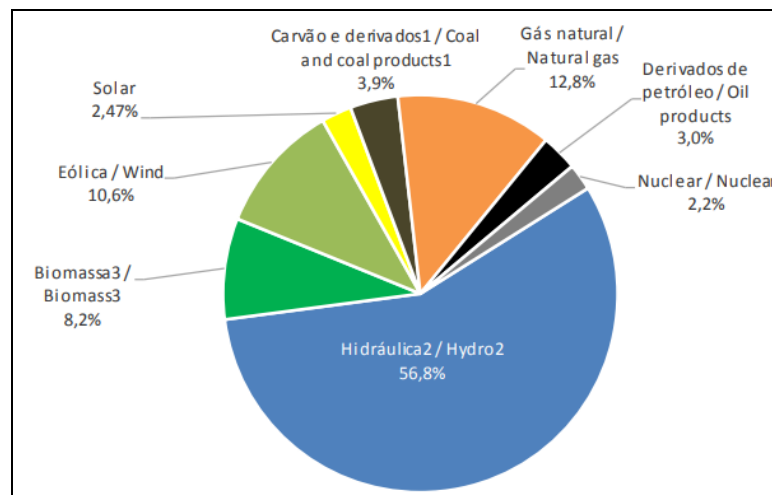
Este trabalho teve como objetivo avaliar a vazão afluente da Usina Hidrelétrica de Água Vermelha dos anos de 2010 a 2014, utilizando redes neurais do tipo perceptron multicamadas e dados hidrelétricos reais disponibilizados pela Agência Nacional das Águas – ANA.

2 REVISÃO BIBLIOGRÁFICA

2.1 SISTEMA HÍDRICO

No ano de 2021, 56,8% de toda energia elétrica produzida no Brasil foi resultado da geração hidráulica (EPE, 2022). Se comparado com o ano anterior, esse número teve uma redução percentual de 8,47%, porém não alterando o cenário da matriz energética brasileira, continuando predominantemente composta por usinas hidrelétricas (EPE, 2022) conforme mostra a Figura 1.

Figura 1 - Oferta Interna de Energia Elétrica por Fonte.



Fonte: BEN (2022).

As bacias hidrográficas consistem em uma grande área em que um rio principal é alimentado por outros rios ao seu redor, os afluentes. A principal força modeladora do setor é predominantemente hidráulica do sistema, referente a grande quantidade de reservatórios localizados ao longo das 12 bacias hidrográficas do território brasileiro (Figura 2). (Arenales, M. et al, H. 2015)

Figura 2 – Disposição das bacias hidrográficas



Fonte: ONS (2023). ADAPTADO

O uso da energia provinda das águas é uma tendência global para os próximos anos. Existe um esforço em âmbito mundial para a descarbonização de fontes de energia elétrica.

Segundo a BNEF (*Bloomberg New Energy Finance*) a energia solar e eólica até 2050, acompanhado por sistemas de armazenamento diversos, terá capacidade de cobrir aproximadamente metade da demanda energética do planeta, levando em consideração a redução de custos dessas tecnologias (NEO, 2019). No Brasil, a geração composta por energia hidrelétrica, solar e eólica permitirá um corte de mais de 80% nas emissões em 2050 (NEO, 2019).

Embora dos avanços, essas fontes não são despacháveis, ou seja, não possuem a capacidade de serem controladas em tempo real de acordo com a demanda de eletricidade. Dessa forma, a energia hidrelétrica representa uma fonte estratégica para a mitigação da emissão dos gases do efeito estufa, pois se trata de uma fonte renovável, de baixa emissão e despachável.

Com capacidade instalada superior a 150 GW e consumo anual em torno de 500 TWh por ano, o sistema hidrelétrico brasileiro é o maior da América Latina. O potencial hidrelétrico do Brasil é estimado em 172GW, dos quais mais de 60% já foram aproveitados (EPE, 2023). Estando o restante concentrado em locais de alto impacto ambiental, sobretudo na região norte.

2.1.1 Geração de energia elétrica

Com a interrupção do curso inicial de um rio, provocando a formação de um lago artificial denominado reservatório, é possível aproveitar o potencial hidrelétrico desse rio.

A água captada é conduzida até a casa de força através de canais e/ou dutos metálicos para passar através de turbinas hidráulicas e após isso, seguir ao leito natural do rio pelo canal de fuga (dos Reis, 2017). A energia hidráulica é transformada em energia mecânica quando a água passa pela turbina, girando-a, e, no gerador acoplado direto na turbina, a potência mecânica é transformada em potência elétrica. Após seguir através dos cabos até o transformador elevador, onde irá ocorrer a elevação da tensão para ser conduzida pelas linhas de transmissão até os centros de consumo. E por fim, através de transformadores abaixadores, a energia tem sua tensão rebaixada para ser utilizada pelos consumidores finais (ONS, 2023).

A geração de energia elétrica no Brasil é dependente da disponibilidade hídrica da região em que as usinas se encontram, distribuídas nas regiões Norte, Nordeste, Sul, Sudeste e Centro-Oeste com diferentes características de acúmulo pluviométrico. Segundo o ONS (2023), a geração hidrelétrica está associada à vazão do rio, isto é, à quantidade de água disponível em um determinado período de tempo e à altura de sua queda. Quanto maiores são a vazão e a altura de queda, maior é seu potencial de aproveitamento na geração de eletricidade.

De acordo com a ANEEL (Agência Nacional de Energia Elétrica) o Brasil possui 168 usinas de grande porte em operação espalhadas pelo país.

Devido ao grande impacto e representatividade no cenário brasileiro de energia elétrica (EPE, 2022), as usinas hidrelétricas devem ter seu funcionamento garantido com maior eficiência e confiabilidade (WOOD, 2002). O planejamento da operação das usinas depende do conhecimento antecipado do volume de água que se encontra disponível em seus reservatórios. Sabendo a quantidade de água que estará disponível é possível estimar a quantidade máxima de energia que pode ser gerada (Pereira, 1996).

Com intuito de atender a essa demanda e viabilizar esse planejamento são necessárias informações precisas sobre suas vazões de afluentes (BALLINI, 2000).

2.1.1.1 Previsão de Vazão de afluentes

A previsão em um sistema hídrico, consiste na estimativa do escoamento em um curso d'água, ou seja, a quantidade estimada de água que irá fluir em um rio, córrego ou canal específico em um determinado tempo no futuro. Sendo crucial para planejamento, gestão e tomada de decisão.

No Brasil, a previsão de vazão de afluentes é uma tarefa importante para garantir o suprimento de energia elétrica e o funcionamento adequado do Sistema Interligado Nacional

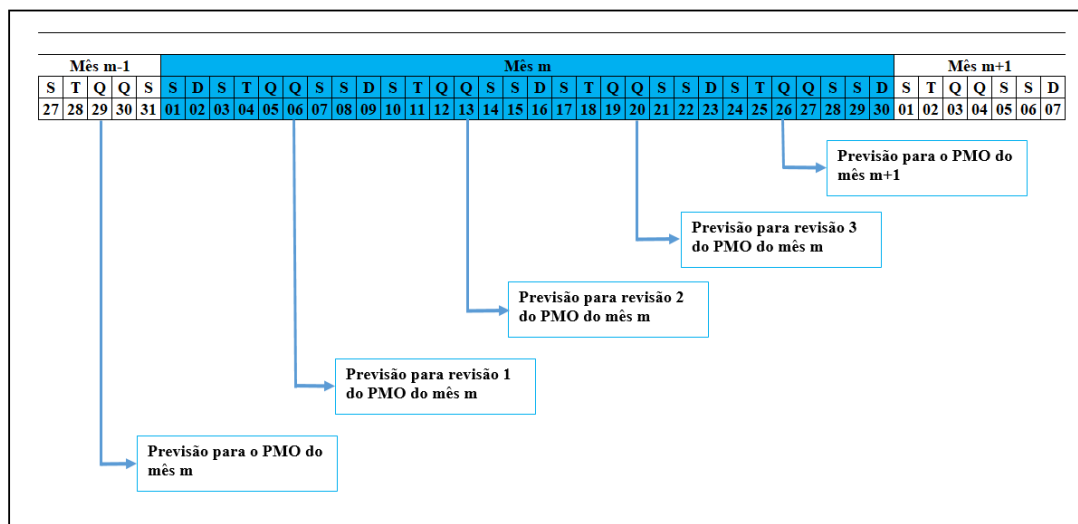
(SIN) e possui como órgão responsável por administrar e controlar a operação das instalações de geração e transmissão de energia no país, o Operador Nacional do Sistema Elétrico (ONS).

A previsão de vazão se torna um grande desafio para o gerenciamento dos recursos hídricos em uma bacia (MORAES, 1995,1996). Previsão de curto prazo é adotada quando se estima vazão em um trecho da bacia com horas ou dias de antecedência (TUCCI, 2001). Já a previsão de médio prazo é adotada para antecedência de um mês ou alguns meses, dependendo fortemente das condições climáticas da região. Por fim, a previsão de longo prazo é estimada, de modo estatístico geralmente adotando históricos anteriores das condições do local como por exemplo as chuvas (TUCCI, 2001).

A produção energética das usinas depende da série de vazões afluentes do sistema. A série dos anos anteriores de um determinado local é comumente utilizada como dado de entrada para modelo de simulação ou até mesmo otimização

O ONS utiliza e elabora de forma periódica junto com os agentes de geração, as previsões de vazões naturais médias diárias, semanais e mensais, em todos os pontos com aproveitamento hidrelétrico do SIN elaborando assim o Programa Mensal de Operação Energética (PMO). Como de forma adotada, as previsões do PMO são elaboradas nas quartas-feiras da semana anterior ao mês e as previsões para as revisões, ocorrem às quintas-feiras da semana em operação anterior, conforme a Figura 3.

Figura 3 – Esquema de elaboração das previsões para O PMO.



Fonte: ONS (2010). ADAPTADO

2.2 SÉRIES TEMPORAIS E TÉCNICAS DE PREVISÃO

Uma série temporal constitui-se como um conjunto de dados organizados em conformidade com a progressão cronológica. Sua distinção de outras modalidades de análise de dados é devido a preeminência atribuída a sua sucessão temporal. Nesse contexto a ordenação dos eventos possui grande relevância devido ao que ocorre antes e depois ter de fato um peso significativo. Cada observação possui uma propriedade interdependente devido ao fato dos eventos precedentes condicionados e, de forma simultânea, com a capacidade de influenciar aquelas que sucedem. O Desafio está na capacidade de compreender e representar precisamente essa conexão entre as diferentes observações. (EHLERS, 2005).

Tendo como exemplo o processo de vazão relacionado às chuvas com características não lineares, foram iniciadas implantações e utilizações de Redes Neurais Artificiais (RNA) como alternativa para realizar tal previsão (FAYAL, 2008). Ao longo dos últimos anos, vários trabalhos vêm comprovando a eficácia das RNAs e seu bom desempenho em comparação com os métodos estatísticos (FLORES, 2017) (SOUZA, 2010).

Entre as principais razões para o estudo, conhecimento e a modelagem de séries temporais, pode-se destacar a previsão de valores futuros. Assim, é possível gerar sequências artificiais aceitáveis de forma probabilística (PEREIRA; PAIS; SALES, 1986).

2.2.1 Redes Neurais Artificiais


As Redes Neurais Artificiais (RNA) são técnicas computacionais que buscam simular o comportamento do cérebro humano, sendo possível realizar programações que fazem o reconhecimento de padrões e a resolução de problemas comuns (SPORL, 2011). As RNAs são compostas por um determinado número de neurônios dispostos em camadas de processamento (BIRIKUNDAVY., 2002). Devido a grande capacidade de aprendizado, as redes neurais são amplamente utilizadas em várias áreas incluindo engenharia e ciência (SILVA; SPATTI; FLAUZINO, 2010).

Entre várias características das RNAs, destacam-se: não-linearidade, ou seja, permite a resolução de problemas que não são possíveis ser separados de forma linear (em 2 grupos por exemplo); adaptabilidade aprendendo novamente de forma a adequar-se a um novo conjunto de exemplos; aprendizagem extraído por exemplos; modelagem de sistemas complexos e processamento paralelo, isso devido a capacidade de processamento com grande quantidade diversa de dados ao mesmo tempo e outros pontos. (VALÊNCIA, 2005).

2.2.1.1 Neurônio artificial e funções de ativação

O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Combinando diversos neurônios artificiais, pode-se formar o que é chamado de rede neural artificial (KOPILER, 2019). Para compreender o funcionamento das redes neurais, é importante entender o comportamento do neurônio biológico (Figura 4) para, assim, caracterizar o neurônio artificial (VALENCA; 2005).

Figura 4 - Comparativo entre um neurônio biológico e um neurônio artificial.



Fonte: Kopiler (2019).

Os neurônios de um RNA são organizados em camadas, sendo a primeira, denominada camada de entrada e a última, camada de saída. A quantidade de camada intermediária assim como a quantidade de neurônio em cada uma delas varia de acordo com a necessidade de processamento da rede, ou seja, a quantidade aumenta caso necessário um processamento mais refinado referente ao conjunto de dados fornecido, capturando assim características não lineares (BATISTA, 2009).

Os neurônios recebem as informações das entradas e propagam-nas por meio dos pesos w_i , $i = 1, \dots, m$, entre as camadas, simulando assim o processamento sináptico (BATISTA, 2009). Haykin (1994) certifica que os pesos sinápticos são parâmetros adaptáveis ajustados via processo de treinamento.

2.2.1.2 Aprendizagem e treinamento

Dentre as importantes e diversas características de similaridade das RNAs com o cérebro humano, está a capacidade de aprender. Assim sendo, existe uma forma de regra de aprendizagem para as redes neurais que são responsáveis pela modificação dos pesos sinápticos, em função dos exemplos de entrada que lhe são apresentados (VALENCA, 2005).

As Redes Neurais Artificiais fazem parte das estratégias dos Sistemas Inteligentes, tendo como base a observação do comportamento humano e da natureza. Essa abordagem deriva da análise da estrutura cerebral, especialmente dos neurônios. A ideia central se origina da forma como os neurônios biológicos operam, processando uma série de informações de entrada provenientes do corpo ou do ambiente circundante. Esses dados são então transformados em informações ou resultados de saída distintos (ALBANO; VALENCA; PORTO, 2007).

Os treinamentos de um RNA podem ser classificados como treinamento supervisionado e treinamento não-supervisionado.

Haykin (2009) caracteriza treinamento supervisionado com a necessidade de haver conhecimento ou informação sobre um sistema, utilizando o padrão entrada-saída. Após a aplicação de um algoritmo de treinamento supervisionado, a RNA aprende de forma análogo, assim como os seres humanos e animais, ou seja, através de experiências e/ou exemplos e não possui informações prévias sobre ambiente. Com base nisso, nota-se uma situação particular e nova, a RNA pode vir apresentar generalização na modelagem e com isso diminuir seu desempenho devido a utilização apenas da dessas experiências fornecidas (ZUBEN, 1996).

3 MATERIAL E MÉTODOS

O levantamento diário de vazões da usina de Água Vermelha foi obtido através do site da Agência Nacional de Águas (ANA) (<http://sar.ana.gov.br/MedicaoSin>) nos anos de 1995 a 2014. Foram selecionados os 11 primeiros dias dos meses de Janeiro a Dezembro dos anos de 1996 a 2014.

Para realizar as simulações de projeção de vazão, obtenção das análises e a computação dos dados foi utilizado uma versão gratuita disponível da ferramenta MATLAB, disponível em (<https://la.mathworks.com/products/matlab.html>). Os valores de vazão dos 11 primeiros dias de todos os meses dos anos de 1995 a 2009 foram utilizados para treinamento da rede neural *feedforward*, totalizando 180 dados de entrada alimentando a RNA, sendo os 10 primeiros dias utilizados como dados para treinamento, e o 11º dia de cada mês como as respostas corretas para previsão da rede, ou seja, informando a saída desejada para treiná-la.

Após a validação do treinamento, os 10 primeiros dias de todos os meses dos anos de 2010 a 2014 foram utilizados para teste da RNA, com o objetivo de prever o 11º dia de cada mês nesse intervalo de anos, sem informar a RNA sobre a saída desejada, totalizando 60 dados de saída para serem comparados com os dados oficiais históricos.

O processo foi repetido 10 vezes para cada uma das seguintes combinações:

- 5 neurônios na camada oculta e nº de épocas igual a 1000;
- 10 neurônios na camada oculta e nº de épocas igual a 1000;
- 15 neurônios na camada oculta e nº de épocas igual a 1000;
- 20 neurônios na camada oculta e nº de épocas igual a 1000;
- 25 neurônios na camada oculta e nº de épocas igual a 1000;
- 30 neurônios na camada oculta e nº de épocas igual a 1000;

Na sequência, uma média aritmética foi obtida para cada uma das 6 combinações e analisada a combinação com melhor desempenho.

4 RESULTADOS E DISCUSSÃO

A partir da análise das 6 combinações, foram obtidos todos os erros de previsões dos anos de 2010 a 2014 e estão descritos na Tabela 3, disponível no Anexo 1.

A Tabela 2 apresenta as médias e os desvios padrão para comparação.

Tabela 2 – Resultados dos testes de previsão da RNA.

Nº de neurônios na camada oculta	Erro das previsões					
	5	10	15	20	25	30
Média	3,24%	2,49%	4,34%	4,07%	5,03%	4,16%
Desvio padrão	8,20%	3,11%	5,47%	6,01%	7,31%	5,55%

Fonte: elaborada pelo autor.

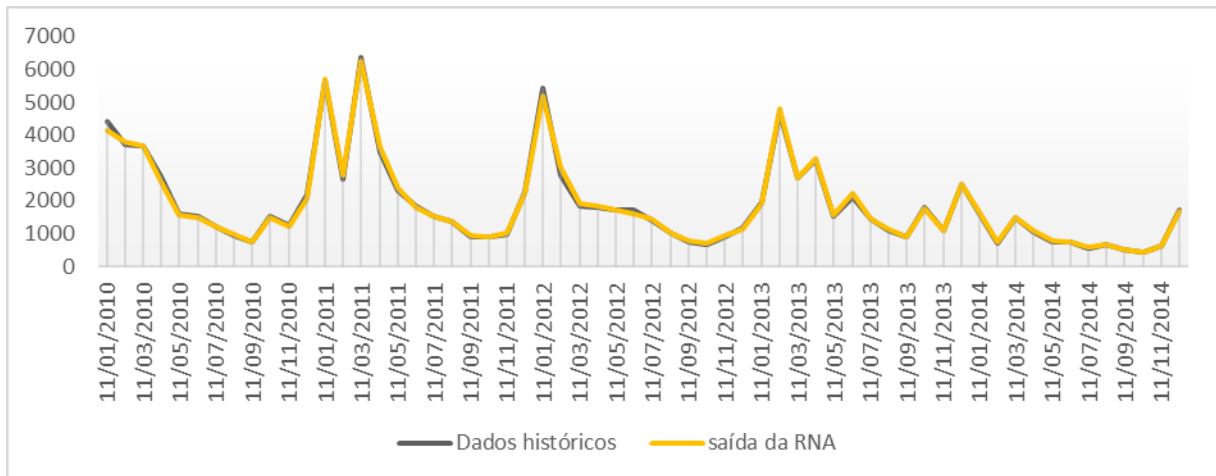
Com base nos resultados da Tabela 2, pode-se observar a combinação com 10 neurônios na camada oculta com o melhor resultado e desempenho, com uma média de erro da previsão de vazão para o 11º primeiro dia de cada mês dos anos de 2010 a 2014 com um valor final de 2,49%.

Somado a isso, observa-se o menor valor de desvio padrão entre os valores máximos e os valores mínimos dos erros das previsões obtidos durante os 10 testes realizados sequencialmente para cada uma das 6 combinações testadas, com um valor final igual a 3,11%.

Em comparação com a combinação de 10 neurônios na camada oculta, as combinações de 25 neurônios e 30 neurônios apresentaram aumento na média dos erros de previsão, sendo os valores 5,03% e 4,16%, respectivamente. Nota-se também um aumento no valor do desvio padrão com resultado de 7,31% para a combinação de 25 neurônios e de 5,55% para a combinação de 30 neurônios. Esses valores podem ser resultado da memorização do treinamento, chamado *overfitting*, ao invés da extração das características gerais para generalização, isso quando a rede possui um número elevado de neurônios na camada oculta.

No gráfico apresentado na Figura 5 pode-se observar a comparação entre os valores dos meses de 1 a 12 (Janeiro a Dezembro) dos anos de 2010 a 2014, referente aos resultados da previsão da RNA com 10 neurônios na camada oculta.

Figura 5 – Comparação entre a previsão de vazão e os dados históricos dos anos 2010 à 2014.



Fonte: elaborada pelo autor.

Os valores obtidos das previsões foram muito próximos dos valores dos dados históricos. O maior erro da previsão diária foi igual a +8,14% (referente ao dia 11 de Outubro de 2012), em que a rede previu 717m³ e a vazão foi de 663m³, ao passo que o menor erro diário foi a igual a -6,88% (referente ao dia 11 de Junho de 2012), em que a rede previu 1.611m³ e a vazão foi de 1.730m³. Esses dados indicam a alta confiabilidade da rede neural artificial aplicada para o conceito de vazão de afluentes.

5 CONCLUSÃO

Este trabalho analisou a aplicabilidade de uma rede neural artificial do tipo perceptron multicamadas para realizar a previsão das vazões afluentes da Usina da Água Vermelha, utilizando como informações de entrada os dados reais disponibilizados pela Agência Nacional de Águas - ANA.

Nos testes realizados a rede obteve uma média de erro nas previsões de 2,49% para a topologia com dez neurônios na camada oculta, com desvio-padrão de 3,11%, valores que podem ser considerados compatíveis com sua utilização em situações reais para planejamento das companhias hidrelétricas.

Dessa forma, conclui-se que foi possível demonstrar a viabilidade da utilização das redes perceptron multicamadas para previsão de séries temporais de vazão afluente, servindo como uma ferramenta de auxílio ao processo de tomada de decisão para usinas hidrelétricas.

Tópicos para pesquisas futuras incluem a simulação com séries temporais maiores, testes para outras usinas do sistema elétrico nacional e a comparação com outras arquiteturas de redes neurais e outros tipos de técnicas de previsão, como ferramentas estatísticas e técnicas de *deep learning*.

REFERÊNCIAS

ALBANO, G. D.; VALENCA, M. J. S.; PORTO, R. L. L. **Previsão de vazões médias mensais afluentes com o uso de redes neurais construtivas — alternativa de planejamento operacional de represas.** Anais do XVII Simpósio Brasileiro de Recursos Hídricos, São Paulo - SP, 2007.

ANA - **AGÊNCIA NACIONAL DE ÁGUAS (BRASIL)** - Programa produtor de água: manual operativo. Brasília: ANA, 2009. 67 p.

ARENALES, M. ARMEANTO, V. MORABITO, R. YANASSE, H. **Pesquisa Operacional BALLINI, R. Análise e previsões de vazões utilizando modelos de series temporais, redes neurais e redes neurais nebulosas.** 2000. 169 f. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual de Campinas, Campinas, 2000

BATISTA, A. L. F. **Modelos de series temporais e redes neurais artificiais na previsão de vazão.** Universidade Federal de Lavras. 2009. 89p

BIRIKUNDAVYI, S.; LABIB, R.; TRUNG, H.T.; ROUSSELLE, J. 2002. **Performance of neural networks in daily streamflow forecasting.** J. of Hydrol. Eng., v 7, n 5, p 392-398.

Dos REIS. **Geração de energia elétrica.** Editora Manole (12 novembro 2016) 2017.536p.

EHLERS, R. S. **Análise de séries temporais.** 3. ed. Curitiba: Departamento de Estatística, UFPR, 2005. Disponível em: . Acesso em: 14 jun. 2017.

EPE (**Empresa de Pesquisa Energética**) disponível em: <https://www.epe.gov.br/pt>

FAYAL, M. A. de A., **Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet.** Dissertação de M.Sc., PUC-Rio, RJ, Brasil, 2008

FLORES, G. F., FERREIRA, V. H., ZAMBOTI, M., **"Modelo Chuva-vazão para Previsão de Vazão Afluente Diária Utilizando Redes Neurais Artificiais"**. XIII Simpósio Brasileiro de Automação Inteligente, Brasil, Outubro 2017.

HAYKIN, S. **Redes neurais: principios e prática.** 2. ed. Porto Alegre: Bookman, 2001. ISBN 978-85-7307-718-6

HAYKIN. S, **“Redes Neurais: Princípios e Prática”**, Bookman, 2001.

KOPIER. Alberto A. NAVARRO .Victor A. L. da Silva, LUIZ ANTÔNIO A. de Oliveira, LINDEN .Ricardo, SILVA . Luis Renato A. de A., FONSECA . Bruno L. da C. **“Redes Neurais Artificiais e suas aplicações no setor elétrico”**. Revista de Engenharias da Faculdade Salesiana n. 9 (2019) pp. 27-33. Disponível em< www.fsma.edu.br/RESA/Edicao9/FSMA_RESA_2019_1_04.pdf>. Acesso 29 Marc. 2022

MORAES, J. M., GENOVEZ, A.M., MORTATTI, J., PELLEGRINO, G., BALLESTER, M.V., MARTINELLI, L. A, 1996. **Análises e Modelagem de uma Série Temporal de Vazão sob a Influência de Ações Naturais e Antrópicas.** In Anais do XVII Congresso Latino Americano de Hidráulica.

MORAES, J. M., PELLEGRINO, G., BALLESTER, M. V., MARTINELLI, L. A., VICTORIA, R. L., 1995. **Hydrological Parameters of a Southern Brazilian Watershed and its Relation to Human Induced Changes.** In *Annales of 20th General Assembly of the European Geophysical Society*, v13: 506-507.

ONS (**Operador Nacional do Sistema Elétrico**) disponível em: <https://www.ons.org.br/> para cursos de engenharia. LTC, 2015.

PEREIRA, B. B.; PAIS, M. B. Z.; SALES, P. R. H. **Análise espectral de séries temporais - uma introdução para engenharia, economia e estatística.** Rio de Janeiro: Arte Final Leasing Editora Ltda, 1986.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas - curso pratico.** 1. ed. São Paulo: ARTLIBER, 2010. ISBN 978-85-88098-53-4

SOUSA, W. dos S., SOUSA, F. de A. S. **"Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó"**, Revista Brasileira de Engenharia Agrícola e Ambiental v.14, n.2, p.173–180, 2010.

SPATTI, D. H. **Automatização de Processos de Detecção de Faltas em Linhas de Distribuição Utilizando Sistemas Especialistas Híbridos.** 2011. 208 f. Tese (Doutorado em Engenharia Elétrica). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil. 2011.

SPÖRL, C.; CASTRO, E. G.; LUCHIARI, A. **Aplicação de Redes Neurais Artificiais na construção de modelos de fragilidade ambiental.** Revista do Departamento de Geografia, v. 21, n.1, p. 113-135, 2011.

TUCCI, C. E. M., BRUN, G., 2001. Previsão em tempo real do volume afluente ao reservatório de Ernestina. In *Revista Brasileira de Recursos Hídricos*. V.6, n.2, p.73 – 79.
VALENCA, M. J. S. **Aplicando Redes Neurais: um guia completo.** Editora livro rápido – elógica. 1. Olinda – PE: v.800, 2005. 284p.

VALENCA, M. J. S.; A. **Modelagem do processo chuva x vazão e vazão x vazão utilizando redes neurais.** Anais do XVI Simpósio Brasileiro de Recursos Hídricos, João Pessoa - PB, 2005.

WOOD, A.W., MAURER, E.P., KUMAR, A., & D.P. LETTENMAIER (2002). **Long range experimental hydrologic forecasting for the eastern U.S.** *Journal of Geophysical Research*, vol. 36, pp. 70-86.

ZUBEN, F. V. **Modelos paramétricos e não paramétricos de redes neurais artificiais e aplicações.** 244 p. Tese (Doutorado em Engenharia Elétrica) — Universidade Estadual de Campinas, Campinas, 1996.

ANEXO 1

Tabela 3 - Comparação entre os erros das previsões dos anos 2010 à 2014.

N° de neurônios na camada oculta	Erro das previsões					
	5	10	15	20	25	30
11/01/2010	-0,32%	-5,60%	-1,84%	-2,13%	-7,92%	-9,10%
11/02/2010	1,40%	1,78%	-3,91%	3,59%	-3,13%	4,42%
11/03/2010	-2,12%	-0,14%	-1,30%	-2,09%	-2,69%	-1,27%
11/04/2010	-6,64%	-5,88%	-8,78%	-12,99%	-4,57%	10,34%
11/05/2010	-1,19%	-1,07%	-0,25%	-3,57%	0,00%	-0,75%
11/06/2010	-1,32%	-0,86%	1,46%	-2,12%	1,92%	0,99%
11/07/2010	-0,50%	0,92%	1,17%	-3,18%	1,67%	1,17%
11/08/2010	1,27%	2,86%	4,34%	-0,11%	4,66%	3,60%
11/09/2010	-1,45%	0,53%	3,69%	0,53%	3,96%	0,79%
11/10/2010	-1,58%	-1,19%	-0,13%	-4,82%	-1,25%	-1,06%
11/11/2010	57,23%	-3,30%	-1,61%	-6,35%	-3,22%	-1,77%
11/12/2010	-5,98%	-5,43%	-5,07%	-9,22%	-7,71%	-8,35%
11/01/2011	-0,85%	1,03%	-6,20%	-0,44%	-2,21%	1,35%
11/02/2011	2,29%	4,01%	5,78%	6,23%	4,16%	1,80%
11/03/2011	-8,55%	-1,73%	-9,81%	3,25%	-5,79%	-16,13%
11/04/2011	2,58%	4,85%	5,86%	3,22%	4,14%	5,34%
11/05/2011	2,42%	2,86%	3,64%	3,20%	3,42%	5,54%
11/06/2011	-0,44%	-0,82%	0,33%	-4,01%	-0,77%	-0,71%
11/07/2011	0,33%	0,20%	2,08%	-2,15%	1,56%	1,30%
11/08/2011	-1,70%	0,07%	1,26%	-3,62%	1,33%	2,14%
11/09/2011	0,11%	2,66%	4,22%	-0,22%	4,99%	2,55%
11/10/2011	-1,77%	0,44%	1,11%	-3,10%	2,21%	-1,55%
11/11/2011	0,91%	4,04%	5,76%	-0,61%	6,26%	7,47%
11/12/2011	-1,38%	-1,86%	0,98%	-5,19%	-2,44%	-1,73%
11/01/2012	16,77%	-4,00%	-5,83%	-4,00%	-0,57%	-2,31%
11/02/2012	2,65%	7,63%	9,46%	6,41%	6,98%	8,88%
11/03/2012	3,56%	2,96%	3,66%	0,65%	2,75%	3,39%
11/04/2012	0,22%	1,55%	1,00%	-1,83%	1,55%	1,00%
11/05/2012	-0,99%	-0,23%	2,26%	-0,29%	1,68%	0,41%
11/06/2012	-5,90%	-6,88%	-1,62%	-4,05%	-1,85%	-2,49%
11/07/2012	2,61%	2,05%	5,51%	3,32%	6,01%	7,84%
11/08/2012	0,30%	1,98%	3,17%	-1,58%	3,76%	2,67%
11/09/2012	0,79%	2,38%	6,35%	2,78%	5,82%	4,23%
11/10/2012	3,02%	8,14%	9,80%	4,83%	9,95%	1,81%
11/11/2012	0,89%	4,58%	1,67%	-1,00%	4,58%	-4,24%
11/12/2012	0,43%	-2,25%	-1,56%	-3,63%	-2,16%	-6,05%
11/01/2013	-2,81%	-2,35%	-1,79%	-7,16%	-2,92%	-2,76%
11/02/2013	1,53%	2,71%	-2,83%	0,47%	-0,36%	1,45%
11/03/2013	-1,56%	0,67%	0,41%	-2,86%	-37,78%	-0,07%
11/04/2013	0,77%	1,98%	3,28%	2,85%	3,34%	4,49%
11/05/2013	0,13%	0,13%	0,97%	-2,14%	1,17%	0,71%
11/06/2013	0,95%	5,20%	4,87%	0,71%	10,97%	14,04%

11/07/2013	1,68%	0,98%	2,94%	-0,98%	2,59%	2,24%
11/08/2013	1,18%	4,73%	1,55%	-0,09%	3,64%	0,18%
11/09/2013	-0,67%	-0,11%	1,79%	-2,02%	1,23%	-0,34%
11/10/2013	-2,80%	-1,68%	-3,70%	-10,93%	-4,54%	-4,37%
11/11/2013	-7,02%	0,27%	-7,20%	-14,94%	-9,36%	-9,36%
11/12/2013	-2,59%	-0,52%	-3,26%	-8,32%	-3,38%	-1,23%
11/01/2014	0,63%	2,13%	1,57%	-0,19%	2,19%	0,44%
11/02/2014	4,73%	6,12%	11,54%	1,39%	9,18%	8,07%
11/03/2014	-1,50%	0,27%	4,08%	-2,92%	3,33%	5,85%
11/04/2014	0,00%	3,35%	3,83%	-0,67%	5,55%	3,44%
11/05/2014	2,68%	3,49%	7,79%	2,28%	6,85%	4,70%
11/06/2014	0,82%	0,27%	4,53%	2,61%	4,12%	0,55%
11/07/2014	1,58%	1,06%	9,86%	9,15%	8,45%	6,16%
11/08/2014	2,46%	2,31%	8,00%	7,69%	7,23%	3,69%
11/09/2014	2,35%	3,14%	15,49%	13,14%	13,92%	11,57%
11/10/2014	4,98%	3,55%	21,56%	25,59%	18,96%	16,35%
11/11/2014	-6,41%	-1,12%	1,12%	-0,48%	5,93%	-2,24%
11/12/2014	-0,12%	-2,44%	4,07%	4,07%	5,35%	9,01%

Fonte: elaborada pelo autor.