

# Previsão de Vazões Diárias com Redes Neurais Artificiais e Impacto na Formação do Preço de Liquidação das Diferenças Horário

Elson Antonio Nunes Jr\*, Vitor Hugo Ferreira\*, André da Costa Pinho\*

\*Fluminense Federal University, PPGEET, Engineering School, Niteroi, RJ 22790-340, Brazil, (e-mail: elsonantonio@id.uff.br, vhferreira@id.uff.br, acpinho@id.uff.br).

---

**Abstract:** As the forecast of inflows to hydroelectric plants is one of the input information in the process of SIN operation programming, it is important that these forecasts are increasingly assertive so that the outputs of this process are more consistent with the real conditions. The main goal of this work is to model a daily inflow forecast using neural network technique whose outputs are incorporated into the very short-term hydrothermal dispatch optimization program in order to analyze the impact on the spot price in the electric energy market. The results regarding the flow forecast showed that the predictor proposed was equivalent or more assertive than the models officially used in the energy sector for a considerable part of the hydroelectric plants evaluated, especially for the first forecasted day. On the other hand, the results referring to price indicated the close tracking of the curve created to the official reference, following even the movements of higher volatility. At the end, a price curve referring to the application of the realized flows is adopted, providing a conclusion about the affluence used as input data for the forecaster.

**Resumo:** Como a previsão de vazões afluentes a hidrelétricas é uma das informações de entrada do processo de programação da operação do SIN, é importante que as previsões geradas sejam cada vez mais assertivas de modo que as saídas desse processo estejam cada vez mais condizentes com as reais condições do sistema. O objetivo deste trabalho é a modelagem de um previsor de afluições diárias com técnicas de redes neurais cujas saídas sejam incorporadas ao programa de otimização de despacho hidrotérmico de curtíssimo prazo, a fim de se analisar o impacto em uma das saídas desse modelo computacional: o preço spot do mercado de energia elétrica. Os resultados em relação à previsão de vazões mostraram que o previsor criado foi equivalente ou mais assertivo que os modelos utilizados oficialmente no setor para uma parte considerável das hidrelétricas avaliadas, sobretudo para o primeiro dia previsto, enquanto os resultados referentes ao preço indicaram o acompanhamento de perto da curva criada à referência oficial, seguindo movimentos de subida e descida de maior volatilidade. Ao final, adota-se curva de preço referente à aplicação das vazões realizadas, proporcionando conclusão acerca da afluição usada como dado de entrada do previsor.

**Keywords:** Artificial Neural Networks; Flow Forecast; Very Short-Term Hydrothermal Dispatch; Spot Price; DESSEM; PLD

**Palavras-chaves:** Redes Neurais Artificiais; Previsão de Vazões; Despacho Hidrotérmico de Curtíssimo Prazo; Preço Spot; DESSEM; PLD

---

## 1. INTRODUÇÃO

Apesar da expansão de fontes alternativas, usinas hidrelétricas seguem sendo a principal fonte de energia no Brasil. Quantificando tal informação, no ano de 2021, a fatia hidrelétrica correspondia a 62,3% de toda a geração do Sistema Interligado Nacional (SIN), quase três vezes o percentual da segunda colocada, a geração térmica, com 22,1% e mais de cinco vezes a terceira colocada, a crescente geração eólica, com 12% (ONS, 2022).

Diante da relevância da geração hidrelétrica para a matriz energética do país, o entendimento acerca das características desse tipo de geração é vital para a operação do SIN. Uma dessas características é a estocasticidade, uma vez que a

energia produzida por uma usina é dependente do montante da vazão turbinada e, antes disso, da vazão afluente a usina, informação futura que não pode ser definida com precisão. De fato, o agente responsável pelas atividades de planejamento e programação operativa no Brasil – o Operador Nacional do Sistema Elétrico (ONS) – conta com modelos computacionais utilizados para a definição do despacho hidrotérmico, sendo que cada um desses recebe dados de entrada referentes a dados hidrológicos futuros. Mais especificamente no modelo computacional de menor resolução temporal, que será abordado ao longo deste artigo, o Operador adota a previsão de vazões afluentes a hidrelétricas como dado de entrada, geradas a partir de diferentes modelos preditivos que tentam reduzir o erro inerente ao teor probabilístico da vazão em si (ONS, 2020a).

Assim, se a previsão é mais assertiva, a operação definida pelo modelo é mais adequada frente às reais condições do sistema. Raciocínio parecido pode ser adotado para a definição do preço spot de energia elétrica no Brasil, pois os mesmos modelos computacionais mencionados são utilizados para a definição do chamado Preço de Liquidação das Diferenças (PLD), sendo tal atividade exercida pela Câmara de Comercialização de Energia Elétrica (CCEE). Previsões mais assertivas podem gerar PLDs mais aderentes às reais condições do SIN (CCEE, 2021).

Com a finalidade de gerar previsões de vazões afluentes mais adequadas, estruturas computacionais desenvolvidas com base em inteligência artificial podem ser opções complementares aos métodos convencionais aplicados no setor, baseados, por exemplo, em cálculos autorregressivos. Considerando o histórico de vazões afluentes (sejam mensais, semanais ou diárias) como uma série temporal, é possível desenvolver um modelo com técnicas de redes neurais artificiais (RNAs), o que pode ser uma boa saída para lidar com o comportamento não linear das vazões afluentes utilizadas. Esta linha de pesquisa tem sido investigada por diversos autores, tais como Dias, Cataldi e Ferreira (2017), Ferreira e Da Silva (2017), Ferreira e Leocádio (2011), Ferreira e Leocádio (2012), Ferreira, Flores e Fortes (2017) e Ferreira e Flores (2018).

O objetivo deste trabalho mostrado é o desenvolvimento de um modelo de previsão de vazões afluentes diárias baseado em redes neurais artificiais e com adoção de dados históricos de vazões e precipitação em diferentes regiões de bacias hidrográficas do Brasil. Com a aplicação deste modelo para a quase totalidade das usinas hidrelétricas (também chamadas de postos) consideradas na definição da operação, os resultados gerados foram utilizados como dado de entrada do modelo de despacho hidrotérmico de resolução temporal horária (DESSEM), afim de que fossem também produzidos valores de PLD. Em um segundo momento, foram avaliados os desempenhos tanto na questão hidrológica – com a comparação da assertividade da previsão de vazões do modelo proposto, da previsão oficial divulgada pelo ONS e de um terceiro modelo chamado de ingênuo – quanto no ponto da formação do PLD horário, também considerando os três casos. Ao final, uma última análise gráfica de preço spot foi feita, com a inclusão da curva referente ao caso em que as afluições realizadas foram adotadas como previsões.

A seção 2 deste artigo aborda a cadeia de modelos de otimização do despacho hidrotérmico, além do processo de previsão de vazões sob responsabilidade do ONS. A seção 3 apresenta exemplos de trabalhos que envolvem a aplicação de redes neurais artificiais em problemas de previsão. A seção 4 descreve o estudo de caso deste trabalho, com a descrição dos dados de entrada utilizados na RNA, além da modelagem do previsor e geração de PLDs previstos. A seção 5 ilustra os resultados obtidos no trabalho e, por fim, a seção 6 apresenta as conclusões obtidas.

## 2. FORMAÇÃO DO PLD

A execução dos modelos computacionais para a formação do despacho hidrotérmico, sejam eles do ONS ou da CCEE, resultam em valores de custos marginais, mas que são utilizados pelas entidades com diferentes funções. Para a ONS, o valor, chamado de Custo Marginal de Operação (CMO), tem caráter operativo, adotado, por exemplo, para a definição de quais usinas térmicas devem ser despachadas em um determinado momento com base no custo de operação delas. Para a CCEE, foco do trabalho deste artigo, o PLD é usado para liquidação financeira dos saldos positivos ou negativos dos balanços energéticos dos agentes cadastrados na CCEE, no mercado de curto prazo. Para o cálculo do CMO e PLD, o ONS e a CCEE contam com três modelos computacionais que funcionam de forma encadeada.

### 2.1 Modelos Computacionais Encadeados

Primeiro na cadeia de modelos encadeados, o NEWAVE é aquele com maior horizonte de estudo, geralmente 5 anos discretizados mensalmente (considerado médio prazo). Resumidamente, o programa funciona a partir da chamada Programação Dinâmica Dual Estocástica (PDDE), processo da geração de múltiplos cenários estocásticos hidrológicos que são escolhidos aleatoriamente através de iterações de simulações operativas. Nessas simulações, o propósito é a minimização da função objetivo, que é o custo total de operação por todo o horizonte de estudo, sendo tal custo formado pelas parcelas de custo imediato e futuro.

O DECOMP é o segundo modelo na cadeia encadeada. O encadeamento deste com o NEWAVE é feito através do arquivo que carrega a informação de custo futuro, que é utilizado como dado de entrada. O horizonte nessa etapa é menor em relação ao anterior, formado oficialmente por dois meses (prazo considerado como curto prazo), sendo o primeiro mês discretizado em semanas. O funcionamento do programa é semelhante ao de seu antecessor, porém com algumas diferenças. No caso do DECOMP, por exemplo, a primeira metade do horizonte é tratada de forma determinística, com a consideração de previsões de cargas, vazões e outros dados de entrada. Já o segundo mês de horizonte utiliza a abertura de cenários probabilísticos adotados no processamento da PDDE.

O terceiro e último modelo da cadeia é o DESSEM, que é encadeado ao seu antecessor através do arquivo de função de custo futuro do DECOMP, assim como ocorre a conexão deste com o NEWAVE. O DESSEM é aquele com o menor prazo de estudo, considerado como curtíssimo prazo: horizonte de até 2 semanas discretizado em períodos de meia hora no primeiro dia e em períodos correspondentes aos patamares de carga nos dias subsequentes (ONS, 2020c). O objetivo neste caso continua o mesmo, sendo a determinação do despacho hidrotérmico considerando a minimização do custo total de operação, porém a resolução do problema matemático não é feita através da aplicação da PDDE, mas por Programação Linear Inteira-Mista. Além da definição do despacho hidrotérmico, uma das saídas é o custo marginal de operação por submercado para todo o horizonte analisado,

valor que, como mencionado anteriormente, é adotado pela CCEE no âmbito financeiro.

Oficialmente, a Câmara de Comercialização executa os três modelos computacionais em diferentes periodicidades. Como o NEWAVE é o programa de mais longo prazo, ele é executado mensalmente, enquanto o DECOMP e DESSEM são rodados a cada semana e dia, respectivamente. Este último, a partir de 1º de janeiro de 2021, passou a ser adotado de forma oficial pela CCEE, passando a gerar o chamado PLD horário.

## 2.2 Previsão de Vazões

Focando no deck de entrada do DESSEM, os valores de vazões afluentes diárias previstas se encontram no arquivo dadvaz.dat. Este contém dados de 162 hidrelétricas do SIN e apresenta quantidade de dias variável, porém com horizonte sempre terminando na sexta-feira da semana em que se está executando o deck. Por exemplo, o arquivo da previsão de um sábado terá a previsão de 7 dias (contagem de dias do próprio sábado até a próxima sexta) para cada posto, enquanto o arquivo da previsão de uma sexta-feira conterá vazões previstas apenas do próprio dia. A Fig. 1 apresenta os dados presentes, além da vazão prevista, em um arquivo dadvaz.dat, como o código e nome de usinas e o dia da vazão prevista.

VAZOES DIARIAS PARA CADA USINA (m3/s)							VAZAO		
NUM	NOME	itp	DI	HI	M	DF	HF	M	VAZAO
XXX	XXXXXXXXXXXX	X	XX	XX	XX	XX	XX	XX	XXXXXXXXXX
1	CAMARGOS	1	05					F	113
2	ITUTINGA	1	05					F	0
4	FUNIL-GRANDE	1	05					F	146
24	EMBORCACAO	1	05					F	311
27	CAPIM BRANC1	1	05					F	2
28	CAPIM BRANC2	1	05					F	4
25	NOVA PONTE	1	05					F	205
33	SAO SIMAO	1	05					F	1125
156	TRES MARIAS	1	05					F	671
134	SALTO GRANDE	1	05					F	302
10	IGARAPAVA	1	05					F	22
143	AIMORES	1	05					F	454
162	QUEIMADO	1	05					F	82

Fig. 1 Bloco de informações no arquivo dadvaz.dat (Fonte:ONS)

As vazões previstas do arquivo dadvaz.dat são produzidas pelo próprio ONS ou pelos próprios agentes de geração nos locais onde a entidade não disponha de modelo de previsão (ONS, 2020b). No caso das previsões oriundas do Operador, este conta com três modelos computacionais, além da opção pela média das últimas vazões diárias ou ainda a regressão com uso da previsão existente de outras hidrelétricas. Dentre os três modelos utilizados, o programa SMAP, que usa informação de vazão e precipitação como dados de entrada, é aquele adotado para a grande maioria dos postos. Este, em sua versão original, é baseado na utilização de reservatórios lineares hipotéticos representando as parcelas de solo e escoamentos superficial e subterrâneo (ONS, 2021). O segundo modelo mais utilizado é o PREVIVAZH, ferramenta computacional que gera previsões até 14 dias à frente e se baseia nos valores semanais de vazões desagregados com relação a tendência inferida das últimas aflúncias e a séries sintéticas diárias de vazões naturais de forma ponderada. Por fim, o programa CPINS é utilizado especificamente para a

previsão de vazões afluentes diárias ao posto de Sobradinho (ONS, 2020c).

## 3. REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE VAZÃO

Rede Neural Artificial é uma estrutura computacional que pode ser comparada ao cérebro biológico no que diz respeito ao processo de aprendizado existente que resulta em generalização de padrões. Paralelismo também pode ser estendido à conexão de sinapses através de dendritos e axônios (elementos do neurônio biológico) e a informação levada pela RNA ao longo de sua arquitetura. Quando comparada a modelos autorregressivos convencionais, a RNA apresenta algumas vantagens como a análise de comportamentos não lineares, adaptabilidade a mudanças repentinas no ambiente estudado e capacidade de identificação de sazonalidade, periodicidade e tendência de uma série temporal. Enquanto um modelo autorregressivo possui parâmetros a serem ajustados com intuito de melhoria de performance, a rede neural artificial apresenta configurações que impactam diretamente na análise de determinado meio. Tais configurações estão relacionadas ao tipo de arquitetura (número de camadas, número de neurônios em cada camada, funções de ativação, entre outras), ao processo de aprendizado (algoritmo de aprendizagem, amostras de treino, validação e teste, função de erro adotada, entre outras) e os dados de entrada utilizados (Haykin, 2009). Visando as vantagens listadas, estudos têm aplicado técnicas de RNAs para resolução de problemas de previsão que, tradicionalmente, seriam tratados com modelos autorregressivos.

Por exemplo, o trabalho desenvolvido por Ferreira e Leocádio (2011) apresenta um previsor de vazões mensais com a adoção de RNAs e Inferência Bayesiana. Tal combinação também é explorada por Ferreira e Da Silva (2017), com modelo testado utilizando dados de chuva de seis bacias hidrográficas do Brasil. Tratando de previsões diárias, Ferreira, Flores e Fortes (2017) projetaram rede neural do tipo chuva-vazão para aflúncias da pequena central hidrelétrica de Areal. Ferreira e Leocádio (2012) desenvolveram estrutura em RNAs para previsões de vazões diárias, com uso de variáveis binárias para indicação de períodos seco, úmido e transição. O trabalho desenvolvido por Dias, Cataldi e Ferreira (2017) culminou na criação de RNA para previsão diária de vazões afluentes da usina de Furnas, na bacia do Rio Grande, utilizando-se dados históricos de vazões e dados de precipitação corrigidos matematicamente. Os resultados obtidos nesses trabalhos foram considerados satisfatórios por seus autores. Outro exemplo de uso de técnicas de redes neurais artificiais é dado por Ferreira e Flores (2018), que desenvolveram modelo chuva-vazão para previsão no horizonte de 24 horas. O previsor foi projetado como um Multilayer Perceptron e treinado com dados do rio Preto. Os resultados foram satisfatórios, com performance maximizada a partir do uso de dados de precipitação.

A relação entre vazões e a formação de preço spot de energia elétrica foi explorada por Kuki et al. (2020) através de estudo

comparativo entre estruturas predictoras de aflúências. Entre essas, foram analisados os modelos SMAP e RNAs. Os resultados oriundos dos modelos propostos foram positivos quanto à previsão de PLD semanal comparada à referência divulgada pela CCEE.

Com a recente adoção pela CCEE do programa DESSEM como modelo final da cadeia de otimização do despacho hidrotérmico e, conseqüentemente, a implantação do PLD horário, a ligação entre a previsão de vazões e a formação do preço spot em resolução horária – tema deste artigo – ainda não foi diretamente estudada.

#### 4. METODOLOGIA PROPOSTA

Com o intuito de elaborar uma alternativa aos métodos utilizados pelo ONS, este trabalho propõe o desenvolvimento de um predictor de vazões médias, diárias, aplicado a quase totalidade dos postos contemplados no arquivo *dadvaz.dat*, com a adoção de técnicas de redes neurais artificiais e uso de dados históricos de vazões e precipitação. Posteriormente, se propõe a formação de preço spot com a incorporação das aflúências previstas pelo novo modelo no deck de entrada do DESSEM, visando a análise de impacto da previsão de vazão no cálculo do PLD horário. Com exceção ao cálculo dos valores de PLD, feitos a partir da execução do programa DESSEM, todo o projeto foi desenvolvido em linguagem de programação Python. Mais especificamente no passo de desenvolvimento do predictor, foi utilizada a biblioteca *Keras* para a arquitetura, aprendizado e uso final da rede.

##### 4.1 Dados de Entrada do Modelo

A informação de cunho hidrológico aplicada no treinamento da rede neural desenvolvida é referente aos dados diários de vazões afluentes médias de postos hidrelétricos do SIN. Tais valores foram coletados a partir do relatório disponibilizado diariamente pelo ONS com a situação hidrológica nos reservatórios das hidrelétricas. No arquivo, são divulgados números realizados de vazões de diferentes tipos: natural total, artificial, incremental entre outras. Para efeito de treino e teste do modelo criado, foi escolhida a vazão incremental, mesmo tipo utilizado pela CCEE nas execuções oficiais do deck do DESSEM. Para compor os dados de entrada da rede, foi coletado histórico de aflúências diárias com início no dia 01 de janeiro de 2018, terminando no dia 02 de julho de 2021.

Outra informação utilizada como dado de entrada do predictor é o dado diário de precipitação observada em território brasileiro, obtido através de análise quantitativa de mapas de chuva divulgados diariamente pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE), como o exemplar mostrado na Fig. 2. Foram coletados dados de precipitação de 12 diferentes regiões de bacias hidrográficas no Brasil: Amazonas, Atlântico Leste, Atlântico Nordeste Ocidental, Atlântico Nordeste Oriental, Atlântico Sudeste, Atlântico Sul, Paraguai, Paraná, Parnaíba, São Francisco, Tocantins e Uruguai. Em cada mapa diário, foram contabilizadas as médias de chuva em mm (informação incorporada ao

predictor como dado de entrada) baseadas nas cores de todos os pixels em cada região estudada, considerando a escala de cores disponibilizada no próprio gráfico. O horizonte do histórico de precipitação foi o mesmo mencionado no caso dos dados de vazões afluentes coletados. Além das aflúências e da chuva observada, foram adotados como inputs da rede os números do ano, mês e dia de cada uma das datas consideradas no histórico.

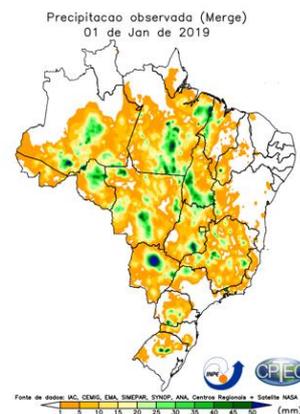


Fig. 2 Mapa de precipitação diária observada (Fonte: CPTEC/INPE)

##### 4.2 Modelagem da Rede e Formação de Preço Spot

A estrutura escolhida para o predictor foi uma rede neural artificial do tipo Multilayer Perceptron (MLP), mais precisamente com 3 camadas dispostas sequencialmente. Foram utilizados 10 neurônios na primeira camada da rede, o que coincide com o número de dados de entrada adotados: os números do ano, mês e dia de uma determinada data, a vazão e a precipitação referente a determinado posto nos últimos 3 dias, além da precipitação para a própria data da aflúência a ser prevista. O esforço de aumentar o histórico de aflúências e precipitação em estados de tempo passados é decorrente do estudo da correlação da vazão em dias anteriores em relação à vazão do dia corrente, como pode ser visto na Fig. 3. Nesse gráfico, são expostas distribuições de frequências dos valores de correlação para aflúências de todas as 144 usinas em análise, de 1 até 10 dias para trás. Com base em tais dados, foi escolhida a janela de 3 dias, uma vez que as opções t-1, t-2 e t-3 possuem maiores frequências em correlações mais próximas de 1.

Por conta da magnitude das variáveis usadas, os dados de entrada e saída foram normalizados entre 0 e 1, evitando que as operações matemáticas realizadas ao longo da arquitetura da RNA atingissem valores muito altos. Em relação a camada oculta do modelo, foram testadas diferentes quantidades de neurônios: 10, 20, 30, 40 e 50 unidades. A função de ativação aplicada nos mesmos corresponde ao tipo sigmoidal, função não linear cuja imagem varia entre 0 e 1. A terceira e última camada possui estrutura mais simples, com apenas um neurônio de ativação linear. A saída desse neurônio e, conseqüentemente, a saída da RNA é o valor de vazão afluente em uma determinada data.

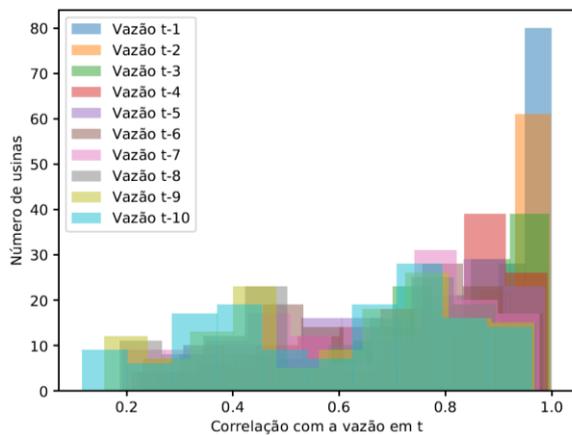


Fig. 3 Distribuições de frequências da correlação entre a vazão em t e a vazão em t-n, com  $n = 1, 2, \dots, 10$

No processo de aprendizagem e avaliação da rede, o conjunto de dados entrada/saída disponível foi dividido para etapas de treino e teste, sendo os primeiros 70% da informação separada para a primeira parte (com todos os valores dessa porção utilizados a cada época) e o restante para testar o modelo. Para a etapa de treino, foi adotada uma variação do algoritmo de back-propagation, denominada de otimizador Adam, que utiliza a técnica de descida do gradiente, mas com redução da taxa de aprendizado ao longo das iterações do processo de aprendizagem do modelo. O otimizador também utiliza um termo, chamado de momento, que serve para evitar que a taxa de aprendizado caia de forma exagerada (Ruder, 2016). Junto a essa opção de algoritmo de aprendizagem, foi escolhida a opção pela minimização do erro quadrático. Outras informações acerca da etapa de treino do modelo merecem menção, tais como o número de épocas usadas, o batch size e a taxa de aprendizado inicial, com valores de 100, 64 e 0,001, respectivamente. Após o treino da RNA, foram utilizadas as amostras de teste para a decisão da melhor estrutura - dentre as opções de redes com diferentes quantidades de neurônios na camada oculta - a partir da análise da mesma função de erro do passo de aprendizagem.

Com a escolha do melhor modelo para uma determinada usina e dia previsto, este é adotado para a previsão final, que é feita para um passo, isto é, uma data. Dois pontos importantes devem ser levantados: a possibilidade que o arquivo *dadvaz.dat* tem de apresentar aflúências previstas para a janela de 7 dias à frente e o fato de que, por exemplo, para que seja prevista a vazão de amanhã, deve-se fazer a previsão do dia de hoje, pois a vazão do dia atual ainda não é realizada. Nessa lógica, de forma operacional, a previsão feita em uma sexta-feira para o dia de sábado, que tem o arquivo *dadvaz.dat* com horizonte de 7 dias à frente, na verdade foi feita com janela total de 8 dias previstos e a vazão do primeiro dia previsto presente no *dadvaz.dat*, na verdade, é o valor referente ao segundo dia previsto no processo de previsão total. Seguindo essa ideia, o modelo criado gerou previsões para dias à frente através de passos recursivos da etapa final, ou seja, a previsão de um dia é executada, o valor gerado é incorporado ao histórico de vazões como se tivesse sido realizado, é gerada outra previsão de aflúência e assim por diante, até que todo o horizonte de dias seja preenchido.

Após a fase de geração de aflúências previstas, os valores produzidos foram incorporados ao deck de entrada do programa DESSEM, através do arquivo *dadvaz.dat*. Com a execução do programa, foram coletados valores de PLD. Vale destacar que a única diferença em relação ao deck oficial executado pela CCEE é a informação de vazões afluentes dos postos, ou seja, a variação entre as curvas de preço spot apresentadas na próxima seção é causada unicamente pela diferença entre as aflúências. Como forma de avaliação do impacto de tal informação hidrológica na formação do PLD, foi criado um segundo modelo de previsão de vazões, chamado neste trabalho de ingênuo, baseado na média dos valores de aflúências para cada posto ao longo do histórico utilizado nas etapas de treino e teste da rede neural montada (01 de janeiro de 2018 a 02 de julho de 2021). Por fim, uma segunda análise do efeito da vazão no preço é feita a partir da produção de PLDs gerados da aplicação de aflúências realizadas, criando-se, assim, o caso no qual as previsões são exatas.

## 5. RESULTADOS

Dentre as 162 hidrelétricas presentes no arquivo *dadvaz.dat*, 144 foram contempladas neste estudo, através de previsões feitas para todos os dias dos meses de março, abril e junho de 2021. Levando em conta que a CCEE, para atribuição de níveis de patamares de carga, divide os meses como períodos de verão (novembro a março), inverno (maio a agosto) e transição (abril, setembro e outubro), os meses contemplados neste estudo são de períodos diferentes. O primeiro resultado obtido diz respeito à arquitetura do predictor. Nas 13.104 vezes em que a rede foi modelada (projeções de 91 dias para cada uma das 144 usinas), a opção pelo número de 50 neurônios na camada oculta foi adotada em 5.788 ocasiões, correspondendo a 44,2% do total. Dentre as outras opções, 40, 30, 20 e 10 neurônios na camada oculta ficaram com 4.033 (30,8%), 2.254 (17,2%), 822 (6,3%) e 207 (1,6%) casos, respectivamente, mostrando a tendência de escolha pelo maior número de unidades na segunda camada da rede.

Como forma de avaliar a eficiência dos modelos, as previsões feitas pelo ONS, RNA e modelo ingênuo foram comparadas às aflúências realizadas nos mesmos dias, utilizando-se o erro absoluto percentual na avaliação de cada posto. Após essa etapa, os modelos foram comparados entre si a partir dos erros calculados previamente aplicados em testes de hipóteses do tipo T-pareado unilateral à direita com 5% de significância. Dessa forma, foi possível determinar, com o nível de certeza utilizado, se a média dos erros gerados era menor em algum dos modelos ou, se o resultado fosse inconclusivo, se o desempenho entre eles era equivalente. As quantidades de postos em que cada modelo foi melhor considerando o número do dia previsto podem ser vistas na Tabela 1 e Tabela 2 para os casos ONS-RNA e ONS-Modelo Ingênuo, respectivamente. De tais dados expostos, primeiramente, é possível ver o melhor desempenho do predictor construído em relação ao modelo ingênuo, mostrando que apenas o cálculo da média histórica de aflúências das hidrelétricas não é suficiente para a produção de vazões previstas mais assertivas. Comparando ao modelo do Operador, os resultados mostram que, para o 1º dia

previsto, o desempenho da RNA é igual ou melhor em praticamente metade dos postos, o que pode ser considerado parcela considerável do total de hidrelétricas. Adicionalmente, pode-se verificar que, aumentando o número do dia previsto, a eficiência do predictor modelado reduz frente às previsões do ONS, o que já era esperado, uma vez que o processo recursivo de previsão da RNA alavanca o erro entre valores previstos e reais.

Tabela 1. Resultado de testes: modelos ONS e RNA

N.º de Postos	ONS	Equivalente (A)	RNA (B)	A+B
1º dia previsto	74	30	40	70
2º dia previsto	91	27	26	53
3º dia previsto	95	31	18	49
4º dia previsto	100	28	16	44
5º dia previsto	104	29	11	40
6º dia previsto	103	33	8	41
7º dia previsto	98	41	5	46

Tabela 2. Resultado de testes: modelos ONS e Ingênuo

N.º de Postos	ONS	Equivalente (A)	Ingênuo (B)	A+B
1º dia previsto	135	5	4	9
2º dia previsto	135	5	4	9
3º dia previsto	137	3	4	7
4º dia previsto	136	4	4	8
5º dia previsto	136	4	4	8
6º dia previsto	134	6	4	10
7º dia previsto	125	15	4	19

No passo de execução do programa de despacho hidrotérmico de curtíssimo prazo considerando os valores de afluências gerados no estudo, foram montados decks de entrada do DESSEM das sextas-feiras dos meses de abril, maio e junho, também adotados na etapa de previsão de vazões. A escolha por tal dia da semana se deve pelo menor tempo de execução do modelo quando comparado aos outros dias. Os valores gerados de PLD da RNA e do modelo ingênuo foram comparados com os valores oficiais oriundos dos decks originais da CCEE através do cálculo do erro absoluto, sendo tais números expostos nos gráficos de boxplot para os submercados Sudeste/Centro-Oeste (SE/CO) e Nordeste (NE), apresentados em Fig. 4 e Fig. 5 (os resultados para o submercado Sul são equivalentes aos valores do

Sudeste/Centro-Oeste, enquanto as conclusões do Norte se aproximam às do Nordeste).

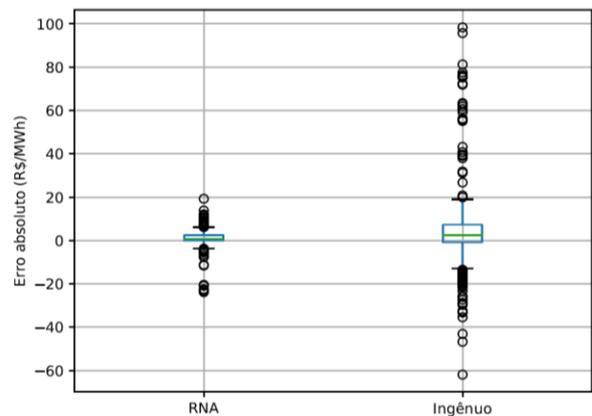


Fig. 4 Boxplot do erro de previsão do PLD no Sudeste/Centro-Oeste

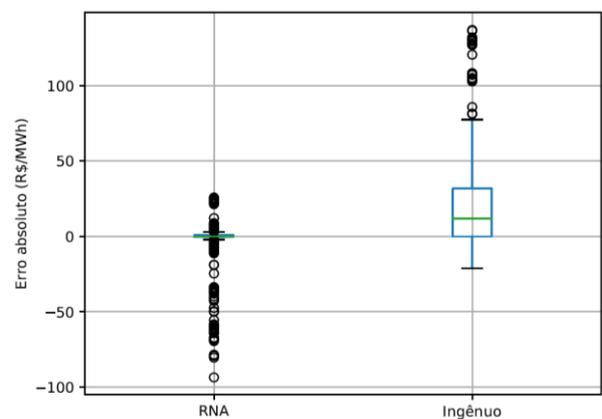


Fig. 5 Boxplot do erro de previsão do PLD no Nordeste

Ademais, os próprios valores de PLD foram confrontados graficamente nos gráficos de linhas para os mesmos submercados, expostos em Fig. 6 e Fig. 7. Nestes gráficos, foram utilizados 624 estágios de tempo, formados por intervalos de 30 minutos (48 estágios em um único dia) de 13 sextas-feiras diferentes. Em relação aos gráficos de boxplot, os resultados mostram que, novamente, as previsões oriundas da rede neural foram mais assertivas em relação ao modelo ingênuo, com distribuição de erros mais achatadas e próximas de zero. Tratando especificamente da RNA, os erros dos PLDs gerados para o submercado Sudeste/Centro-Oeste tiveram outliers menos espaçados ao zero, enquanto o submercado Nordeste apresentou outliers mais afastados no eixo negativo de seu gráfico, mostrando PLDs mais baixos em relação aos números oficiais em alguns estágios. As impressões tiradas dos boxplots podem ser transmitidas para os gráficos de linhas, mostrando que, em ambos os submercados, a linha referente à previsão da rede neural, em relação à linha do modelo ingênuo, segue mais de perto a curva de números da CCEE, acompanhando movimentos de subida e descida com maior volatilidade. Apenas no caso do Nordeste, mais especificamente na primeira metade do período estudado, ocorrem maiores desgarramentos entre as

linhas da RNA e da CCEE, o que reflete nos outliers mais espaçados no boxplot do submercado.

Por fim, foram geradas curvas de PLD horário no submercado Sudeste/Centro-Oeste, retratadas em Fig. 8 e Fig. 9, com a inclusão do caso hipotético em que as vazões realizadas foram utilizadas como previsões. Tais gráficos representam os preços spots de duas das sextas-feiras usadas anteriormente (26 de março de 2021 e 30 de abril de 2021), escolhidas nessa última etapa por apresentarem comportamentos distintos: na Fig. 8, a referência da CCEE acompanha a linha da vazão realizada de mais perto em relação a curva oriunda do processo da rede neural, cenário que se inverte na Fig. 9.

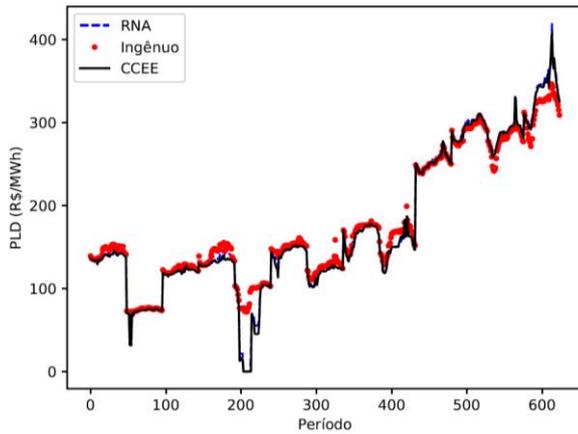


Fig. 6 Curvas de PLD para o submercado SE/CO

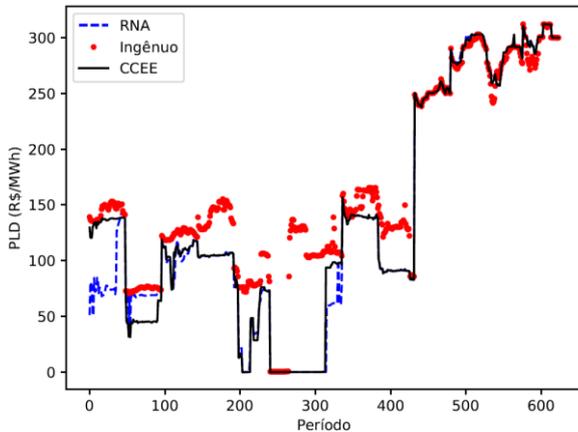


Fig. 7 Curvas de PLD para o submercado NE

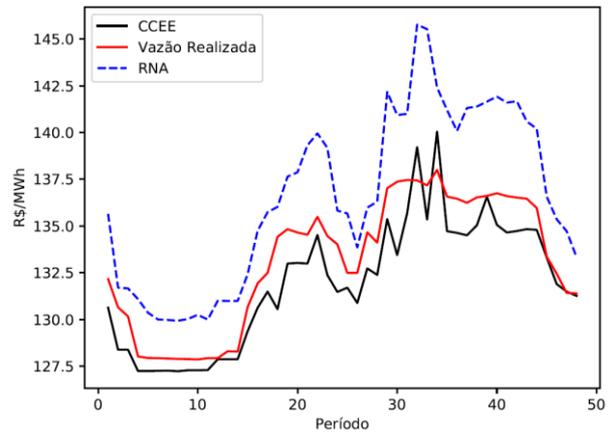


Fig. 8 Curvas de PLD para o SE/CO no dia 26/03/2021

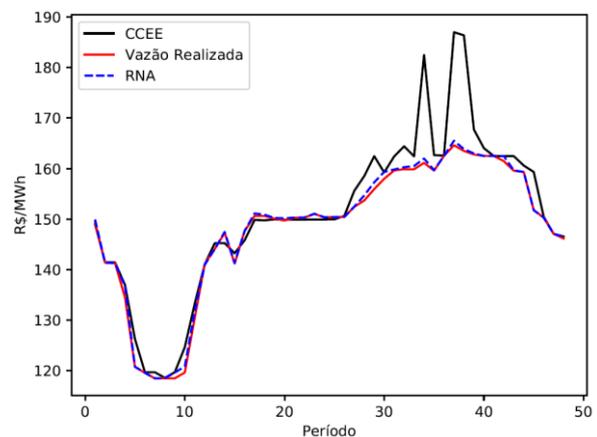


Fig. 9 Curvas de PLD para o SE/CO no dia 30/04/2021

## 6. CONCLUSÕES

A previsão de vazões afluentes de postos hidrelétricos do SIN é um dado de entrada do processo de otimização do despacho hidrotérmico realizado pelo ONS. Assim, é desejável que os valores previstos de afluências sejam mais assertivos de forma que as saídas dos modelos de despacho – sendo o PLD uma dessas saídas – sejam cada vez mais próximas às reais condições do sistema.

O trabalho descrito apresentou um previsor arquitetado segundo noções de técnicas de redes neurais artificiais como alternativa ao conjunto de modelos adotados pelo Operador para a geração de afluências previstas. Analisando os resultados para 144 de 162 hidrelétricas contempladas no deck do programa DESSEM, os valores obtidos mostraram que a RNA criada obteve performance equivalente ou melhor do que o ONS para parcela considerável dos postos, considerando o horizonte do 1º dia previsto. A adoção de uma terceira alternativa de previsão, chamada neste estudo de modelo ingênuo, serviu como validação do desempenho da RNA, mostrando que uma métrica simples de previsão – no caso, a média histórica das vazões das usinas – não é suficiente para a geração de cenários de afluências mais próximos dos valores reais. Vale ressaltar que o objetivo da modelagem do previsor deste artigo não é a substituição dos modelos utilizados pelo ONS, mas sim a demonstração do

potencial de melhora no desempenho do processo de previsão de vazões no âmbito da programação diária da operação do SIN. Tratando da geração de valores de PLD a partir das afluições previstas, os resultados foram satisfatórios, mostrando que as curvas de preço oriundas do processo da rede neural acompanharam mais de perto as referências oficiais da CCEE, seguindo movimentos de subida e descida com maior volatilidade. Em relação aos PLDs da rede neural por submercado, a região Sudeste/Centro-Oeste obteve menores desvios, com Nordeste apresentando outliers mais espaçados, principalmente na primeira metade do período analisado. Adicionalmente, as linhas de preço originadas do modelo ingênuo apresentaram maiores desvios, evidenciando a relevância da previsão de vazões na formação do preço spot de energia.

Na perspectiva de uma empresa comercializadora de energia elétrica, que tenta antecipar o valor do preço de mercado com base na previsão de dados do setor de energia, a redução à zero do erro da previsão de vazões não tem importância alguma se esta não levar à minimização do erro de previsão do preço spot. Assim, pode-se inferir que o mais importante não é acertar os valores realizados de vazões, mas sim as previsões de afluições feitas pelo ONS. Exemplo que ajuda a ilustrar tal raciocínio foi apresentado no último gráfico, onde o PLD referente à rede neural (processo em que tentou-se reduzir o erro de previsão em relação a afluições realizadas) esteve mais próximo da curva feita com base em afluições realizadas do que a referência da CCEE, projetada a partir de vazões previstas pelo ONS. Nessa ótica, um caminho para desdobramentos futuros deste trabalho poderia ser a adoção da previsão feita pelo ONS como dado de entrada da rede neural ao invés de afluições realizadas. Adicionalmente, levando em consideração, por exemplo, que o ONS utiliza informação meteorológica com maior nível de detalhamento quando comparada aos dados de precipitação que foram incorporados na rede neural, pode-se dizer que esta possui margem de progresso em passos futuros do estudo, com a aplicação, por exemplo, de dados de precipitação históricos e previstos discretizados por coordenadas geográficas. Outros pontos possíveis para trabalhos futuros são a avaliação de configurações diferentes em RNAs (arquitetura da rede, algoritmo de aprendizado, função de erro, entre outras) e a execução do programa DESSEM considerando decks de todos os dias da semana.

## REFERÊNCIAS

- CCEE (2021). *Conceitos de Preço*. Disponível em: <https://www.ccee.org.br/web/guest/precos/conceitos-precos> (acessado em 30 de dezembro de 2021).
- Dias, T. L., Cataldi, M e Ferreira, V. H. (2017). Aplicação de Técnicas de Redes Neurais e Modelagem Atmosférica para Elaboração de Previsão de Vazão na Bacia do Rio Grande (MG). *Engenharia Sanitária e Ambiental*, Vol. 22, n. 01, pp. 169-178.
- Ferreira, V. H. e Da Silva, A. P. A. (2017). A Non-Parametric Approach for River Flow Forecasting based on Autonomous Neural Network Models. In: Mohamed E. El-Hawary. (Org.). *Advances in Electric Power and Energy Systems: Load and Price Forecasting*. 1ed.: Wiley-IEEE Press, 2017, v. 1, pp. 285-296.
- Ferreira, V. H. e Leocádio, C. M. (2011). Autonomous Neural Models Applied to Medium-Term Water Inflow Forecasting. *16<sup>th</sup> International Conference on Intelligent System Applications to Power Systems*, pp. 1-6.
- Ferreira, V. H. e Leocádio, C. M. (2012). Inferência Bayesiana no Desenvolvimento de Previsores Neurais de Vazão Diária Utilizando Informações de Precipitação. *Learning and Nonlinear Models*, Vol. 10, n. 03, pp. 157-165.
- Ferreira, V. H., Flores, G. e Fortes, M. Z. (2017). Modelo Chuva-Vazão para Previsão de Vazão Afluente Diária Utilizando Redes Neurais Artificiais. *XIII Simpósio Brasileiro de Automação Inteligente*. Porto Alegre, RS, 1-4 outubro.
- Ferreira, V. H. e Flores, G. (2018). A Rain-Streamflow Model for Prediction of Limnometric Behavior of Reservoirs Using Artificial Neural Networks. *Simpósio Brasileiro de Sistemas Elétricos*, pp. 1-6.
- Haykin, S. (2009), *Neural Networks and Learning Machines*, 3<sup>rd</sup> ed., Pearson Education, EUA.
- Kuki, C. A. C., Torres, F. L. R., de Faria, V. A. D. et al. (2020). Estratégias de Previsão de Vazão para Formação do Preço de Energia Elétrica no Curto Prazo, *Simpósio Brasileiro de Pesquisa Operacional*. João Pessoa, 3-5 novembro.
- ONS (2020a). *Submódulo 4.5 – Programação Diária da Operação*. ONS, Rio de Janeiro.
- ONS (2020b). *Submódulo 4.6 – Análise e Tratamento dos Dados Hidroenergéticos e Previsão e Geração de Cenários de Vazões*. ONS, Rio de Janeiro.
- ONS (2020c). *Submódulo 18.2 – Relação dos Sistemas e Modelos Computacionais*. ONS, Rio de Janeiro.
- ONS (2021). *Aplicação do Modelo SMAP/ONS para Previsão de Vazões no Âmbito do SIN*. ONS, Rio de Janeiro.
- ONS (2022). *Histórico da Operação. Geração de Energia*. Disponível em: [www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao\\_energia.aspx](http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx) (acessado em 06 de janeiro de 2022).
- Ruder, S. (2022), *An Overview of Gradient Descent Optimization Algorithms*, Disponível em: <https://arxiv.org/abs/1609.04747> (acessado em 14 de dezembro de 2019).