

Estratégias de Previsão de Vazão de Curto Prazo: um estudo de caso nas Bacias do Rio Grande e Rio Paranaíba

Cassia Akemi Castro Kuki*, Francisca Lanai Ribeiro Torres*, Victor Augusto Duraes de Faria**,
Anderson Rodrigo de Queiroz***, Luana Medeiros Marangon Lima****, José Wanderley Marangon Lima*****

* *Institute of Electrical and Energy Systems, Federal University of Itajubá, Itajubá, MG, Brazil*
(cassiakuki@unifei.edu.br; lanai.torres@unifei.edu.br)

** *Operations Research Graduate Program, North Carolina State University, Raleigh, NC, USA* (vaduraes@ncsu.edu)

*** *Department of Decision Sciences, North Carolina Central University, Durham, NC, USA* (adequeiroz@nccu.edu)

**** *Nicholas School of Environment, Duke University, Durham, NC, USA* (lmm89@duke.edu)

***** *Marangon Consulting and Engineering, Itajubá, MG, Brazil* (jose.marangon@marangonenergia.com.br)

Abstract: This paper proposes three different short-term water inflow forecasting techniques, using meteorological information as input data. Such information is essential for application in hydroelectric planning and operation problem in the Brazilian Interconnected Power System. These techniques were applied to all hydroelectric facilities located in the basins of the Grande and Paranaíba rivers. The use of these different techniques allowed us to observe the variabilities associated with the inflows, as well as to analyze their performances with respect to the data released by the Brazilian Independent System Operator. The results show that the water inflow forecasts techniques are able to reproduce the behaviour of the ONS forecasts, as well as the consistent inflows, being quite suitable for using by agents like traders, generators and consumers.

Resumo: Este estudo propõe três diferentes técnicas de modelos de previsão de vazões de curto prazo, utilizando como dados de entrada informações meteorológicas. Essas informações são essenciais para aplicação em problemas de planejamento e operação hidrelétricas no Sistema Interligado Brasileiro. Essas técnicas foram aplicadas em todos os aproveitamentos hidrelétricos localizados nas bacias dos rios Grande e Paranaíba. A utilização dessas diferentes técnicas permitiu observar as variabilidades associadas às entradas, bem como analisar suas performances em relação aos dados divulgados pelo Operador Nacional do Sistema Elétrico (ONS). Os resultados mostram que a previsão de vazões é capaz de reproduzir o comportamento das previsões do ONS, bem como as afluências consistidas, sendo bastante adequadas para uso de agentes comercializadores, geradores e consumidores.

Keywords: Precipitation Forecasts; Streamflow Forecasts; Artificial Neural Networks; Hydropower Generation, Spot Price Forecast.

Palavras-chaves: Previsão de Precipitação; Previsão de Vazões; Redes Neurais Artificiais (RNA); Geração Hidrelétrica; Previsão de Preços de Curto Prazo.

1. INTRODUÇÃO

A matriz energética brasileira é predominantemente hidrelétrica, representando aproximadamente 62% do total (ANEEL, 2020). Por isso, a geração de energia elétrica apresenta forte dependência das afluências, que sofrem influência de padrões climáticos (Lima et al., 2014). Além dessa característica, há outras particularidades que merecem ser destacadas e que diferem o Sistema Elétrico Brasileiro (SEB) de outros sistemas: elevado número de aproveitamentos hidrelétricos com acentuada sazonalidade e grau de incerteza, acoplamento entre as unidades geradoras localizadas em cascata ao longo de 16 bacias hidrográficas, e presença de usinas elevatórias com unidades de bombeamento e desvios que permitem a geração reduzida de energia elétrica (Zambelli, 2009).

Devido à essas características, é de extrema importância o planejamento e operação dos sistemas de geração e transmissão, uma vez que sua eficiência diminui os riscos de racionamento de energia elétrica, aumenta a segurança de suprimento e diminui custos operacionais (Bravo et al., 2008). Dentro desse contexto, destacam-se os trabalhos relacionados à operação de reservatórios (Fan et al., 2014, 2015), (Freire et al., 2019), e à análise do impacto das mudanças climáticas sobre as condições energéticas do SEB (de Queiroz et al., 2016, 2019).

Para o planejamento e operação do SEB, o ONS elabora o Programa Mensal da Operação (PMO), no qual a previsão de vazões é de curto prazo. Com isso, as semanas operativas ou revisões são planejadas para o período de sábado à sexta-feira, de modo que a previsão das vazões naturais semanais

para a próxima semana operativa é uma das principais variáveis do PMO e suas revisões (ONS, 2017a).

Nas revisões semanais do PMO, são consideradas as médias semanais das vazões. Como o método de previsão de vazões depende das vazões ocorridas e previstas, as semanas operativas são classificadas em: a) *semana atual ou estimada*, que representa a semana em curso, na qual as médias das vazões semanais são compostas por vazões observadas e previstas; b) *semana realizada*, que representa a semana operativa anterior à semana atual, onde todos os dias possuem dados de vazões observadas; c) *semana prevista*, que é a próxima semana referente à revisão do PMO, na qual a média semanal das vazões é calculada somente com as vazões previstas.

Dada a importância da previsão de vazões no planejamento e operação, este trabalho propõe a formação computacional de uma cadeia composta por diversos modelos interconectados para a avaliação e cálculo das aflúncias para o horizonte de curto prazo. Para isso, é utilizado o modelo climático GEFS, bem como três diferentes metodologias que transformam a precipitação em vazão dos principais rios onde estão as usinas hidrelétricas. Com as aflúncias obtidas através dos modelos hidroclimáticos, o processo para a obtenção das aflúncias para um período de até seis semanas segue o padrão definido pelo ONS, utilizando o modelo de planejamento energético PREVIVAZ, desenvolvido pelo Centro de Pesquisas de Energia Elétrica (CEPEL). Assim, os resultados de vazões previstas podem ser utilizados em diversos estudos operacionais dado a sua aderência com os modelos oficiais utilizados no setor elétrico.

O artigo está dividido em cinco seções. Na seção 2, são descritas as etapas para a previsão de vazões até a formação da energia natural afluyente (ENA). Na seção 3, é apresentado um estudo de caso para as bacias do rio Grande e rio Paranaíba, cujos resultados serão comparados e discutidos com os resultados oficiais divulgados pelo ONS na seção 4. Por fim, na seção 5, são apresentadas algumas considerações e perspectivas futuras de pesquisa.

2. METODOLOGIA

Devido ao impacto da precipitação nas vazões e dadas as características do SIN, a previsão de vazões consiste em duas grandes etapas. Mas, para a determinação das metas de geração dos aproveitamentos hidrelétricos para um horizonte de até seis semanas a frente, é necessária a aplicação do PREVIVAZ. Assim, o processo de definição das vazões previstas para esse horizonte temporal consiste em três etapas, conforme mostra a Fig. 1, que serão descritas a seguir.

2.1 Previsão de Precipitação

Na previsão de variáveis atmosféricas, são utilizados modelos climáticos, que podem ser globais ou regionais. Esses modelos simulam as condições, comportamentos atmosféricos e interações entre a atmosfera e as superfícies através de equações numéricas com o auxílio computacional (Kalnay, 2003), (Ynoue et al., 2017).

Para a previsão de variáveis atmosféricas, é necessária a distinção entre os tipos possíveis: a) *previsão de tempo*, cuja previsão está limitada em até 14 dias de antecedência, devido à natureza caótica da atmosfera; b) *previsão de clima*, que visa simular os fenômenos atmosféricos para horizontes de tempo futuros maiores (Ynoue et al., 2017).




Fig. 1 – Estrutura de integração de modelos hidroclimáticos e de planejamento energético para a previsão de vazão.

Independentemente do tipo de previsão, os procedimentos gerais incluem a coleta dos dados atmosféricos obtidos a partir de sensoriamento remoto e medição *in situ* (WMO, 2015), e realização de três etapas: análise, previsão e pós processamento (Ynoue et al., 2017).

Para alimentar os modelos hidrológicos, são utilizados dados fornecidos através da aplicação do modelo climático GEFS para a previsão de tempo. Para isso, é realizado o recorte de variáveis meteorológicas como: precipitação acumulada diária, radiação média diária, umidade relativa média e pressão diária média ao nível do mar para a América do Sul.

2.1.1 Modelo Climático GEFS

O modelo GEFS foi desenvolvido pelo *National Centers for Environmental Prediction* (NCEP) do *National Oceanic and Atmospheric Administration* (NOAA) e se tornou operacional em 1992 (Toth and Kalnay, 1997).

O GEFS é um modelo global que fornece a precipitação por conjunto (*ensemble*), cuja metodologia permite gerar perturbações nas condições iniciais, sendo possível realizar previsões meteorológicas probabilísticas e estimar suas incertezas (Toth and Kalnay, 1997). Contudo, devido aos erros sistemáticos dessas previsões, o NCEP implementou um algoritmo de correção de viés, que permite a recalibração das previsões meteorológicas do conjunto (Toth et al., 2010). Outras implementações também foram feitas, como a inserção do *Earth System Modeling Framework* (ESMF) em 2010, que permite a modelagem dos processos químicos, físicos, biológicos e dinâmicos da atmosfera e das superfícies terrestre e oceânica (Hill et al., 2004), (Toth et al., 2010).

Todas essas implementações são disponibilizadas pelo NCEP/NOAA, que podem apresentar 1° ou 2.5° de resolução e as previsões são fornecidas quatro vezes ao dia, às 00, 06, 12 e 18UTC (NOAA, 2020).

2.2 Previsão de Vazão

Conforme Collischonn et al. (2005) e Silva et al. (2006), a previsão de vazões pode ser realizada para diferentes horizontes de tempo: a) *previsão de curto prazo*, que apresenta antecedência de até 14 dias com base em modelos determinísticos, acompanhando fenômenos climático-hidrológicos; b) *previsão de longo prazo*, que apresenta antecedência de até 9 meses utilizando estatísticas de valores históricos, permitindo a previsão de valores baseada em intervalos probabilísticos e análises de tendência ou de cenários de mudanças climáticas. Para esse processo, podem ser adotados diferentes modelos de previsão, que podem ser classificados em modelos conceituais e empíricos (Silva et al., 2006).

Os modelos conceituais simulam os processos de balanço hídrico através das equações de *rainfall-runoff*, cujos parâmetros caracterizam o comportamento hidrológico da bacia em análise (Azevedo et al., 1993), (Silva et al., 2006). Neste trabalho, são considerados o Modelo Hidrológico de Grandes Bacias (MGB-IPH) e *Soil Moisture Accounting Procedure* (SMAP).

Já os modelos empíricos relacionam as variáveis através de técnicas matemáticas sem considerar os processos de balanço hídrico (Silva et al., 2006). Dentre esses modelos, destacam-se as Redes Neurais Artificiais (RNAs), as quais as funções matemáticas explícitas e os parâmetros locais detalhados não são necessários (Silva et al., 2006), (Bravo et al., 2009), (Hong and Fan, 2016).

2.2.1 MGB-IPH

O modelo MGB-IPH permite a simulação dos processos de transformação de chuva em vazão em grandes bacias, especialmente aquelas com área superior a 10.000 km² (Collischonn et al., 2007). Como características marcantes do modelo, têm-se a representação do processo de evapotranspiração baseado na equação de Penman-Monteith que representa diferentes tipos de vegetação, e também a rotina de calibração automática através da otimização multiobjetivo (Collischonn and Tucci, 2003).

O modelo simula os processos hidrológicos na superfície terrestre, os quais são divididos em quatro módulos: balanço hídrico no solo; balanço de energia e evapotranspiração; interceptação, geração e propagação de escoamentos superficial, subsuperficial e subterrâneo; e propagação de vazão na rede de drenagem (Collischonn and Tucci, 2001).

Para a representação física da bacia hidrográfica, o modelo trabalha com a discretização em mini bacias, as quais são subdivididas em Unidades de Respostas Hidrológicas (URH), que são regiões que possuem características similares de atributos geológicos e tipo de solo, bem como parâmetros de

modelagem do comportamento hidrológico (Collischonn et al., 2007), (Medeiros et al., 2018).

Já para a aplicação do modelo, além do geoprocessamento das informações espaciais, são necessários os dados de entrada, que consistem em informações hidrológicas e climatológicas, bem como a calibração dos parâmetros de vegetação e solo da bacia simulada (Medeiros et al., 2018).

Neste trabalho, o MGB-IPH foi calibrado manualmente e, complementarmente, com o algoritmo de calibração automática, utilizando dados históricos de 2001 a 2015, com exceção da bacia do Rio Xingu na usina hidrelétrica de Belo Monte, que foi calibrada com dados a partir de 1995. Foram utilizados dados de vazões diárias naturais aferidas nos postos fluviométricos da rede hidrométrica da Agência Nacional de Águas (ANA) e em aproveitamentos sob o controle do ONS. Com relação às variáveis climáticas, os dados foram provenientes de estações pertencentes à ANA e ao *Servicio Nacional de Meteorologia e Hidrologia da Bolívia* (SENAMHI) para a bacia do Madeira.

2.2.2 SMAP

O modelo SMAP representa os processos hidrológicos que ocorrem em uma bacia hidrográfica através da modelagem de três reservatórios: reservatório do solo, reservatório subterrâneo, e reservatório da superfície, com processos internos e interativos entre si (Azevedo et al., 1993). Porém, algumas modificações foram realizadas a fim de adaptar o modelo às características das diversas bacias hidrográficas brasileiras, tais como a criação do reservatório de planície e aprimoramento metodológicos relacionados à precipitação, evapotranspiração e escoamento superficial (ONS, 2018).

Para sua aplicação, são necessários dados hidrológicos e climatológicos, que consistem nas vazões médias diárias observadas, precipitação observada e prevista e totais climatológicos diários de evapotranspiração (ONS, 2018).

Devido ao desempenho do SMAP na previsão das vazões, o ONS adotou esse modelo como o principal na previsão de vazões e, por isso, sua aplicação abrange majoritariamente as bacias hidrográficas localizadas nas regiões Sul e Sudeste do Brasil.

O SMAP é executado diariamente pelo ONS e nas bacias que contêm uma versão calibrada, foram utilizadas bases de dados com diferentes períodos tanto para a precipitação quanto para as vazões naturais e incrementais de acordo com a disponibilidade dos dados nos postos pluviométricos e fluviométricos, respectivamente. Mas para o processo de calibração, o período escolhido foi aquele capaz de abranger o maior número de situações hidrológicas (ONS, 2017b). Por exemplo, nas bacias do Grande e Alto Paranaíba, o período de calibração foi de 1995 a 2001 (ONS, 2011, 2012).

Para a previsão de vazões, o SMAP considera como dados de entrada os totais diários de precipitação previstos e observados, totais climatológicos diários de evapotranspiração e as vazões médias diárias observadas (ONS, 2020a). Quanto a precipitação futura, o SMAP utiliza

como entrada o resultado da combinação das previsões do GEFS com as do ETA40, o que origina a previsão de precipitação por conjunto (ONS, 2019).

Como o ONS ainda não possui a versão calibrada do SMAP para todas as bacias hidrográficas brasileiras, é necessário simular as vazões dos aproveitamentos restantes através de um modelo complementar. Neste estudo, optou-se por utilizar uma combinação com o MGB-IPH em associação ao GEFS. Isso origina, portanto, uma cadeia de modelo chuva-vazão oriunda da combinação do SMAP e do MGB-IPH.

2.2.3 Redes Neurais Artificiais (RNA)

As RNAs são técnicas computacionais que utilizam modelos matemáticos inspirados no sistema nervoso central capazes de adquirirem conhecimento e experiência a partir de exemplos utilizados em seu treinamento.

Para este trabalho, foi escolhida uma arquitetura típica de RNA, chamada *Multi-layer Perceptron* (MLP), que vem sendo amplamente utilizada na literatura para fins de previsão (Yonaba et al., 2010).

A MLP é formada tipicamente por três tipos de camadas. A camada de entrada (*input layer*) é responsável por receber as variáveis de entrada da rede, que para este trabalho são: chuva passada, chuva futura e vazões passadas. A seleção dessas variáveis é extrema importância no desempenho do modelo de RNA, pois a presença de entradas irrelevantes adiciona ruídos no processo de otimização (Taormina and Chau, 2015). Posteriormente, as informações recebidas na *input layer* são transferidas para as camadas ocultas (*hidden layers*), nas quais são aplicadas combinações lineares em cada neurônio e, ao final da combinação linear, é aplicada uma não linearidade, chamada de função de ativação, que para este trabalho foi escolhida a unidade linear retificada (ReLU) (Goodfellow et al., 2016). Finalmente, o processo mencionado se repete para todas as *hidden layers* até a camada de saída ou *output layer*, na qual é aplicada uma combinação linear final para obtenção da previsão (Goodfellow et al., 2016).

O processo de aprendizagem da RNA tem como objetivo a calibração dos parâmetros, w (*weights*) e b (*biases*), responsáveis pelas combinações lineares a fim de minimizar o erro da previsão a partir de um dado conjunto de exemplos históricos (i, y), que consistem em um conjunto de variáveis de entrada (i) que podem ser utilizadas para prever os valores da variável de saída (y).

Além do treinamento, há outras duas etapas que devem ser consideradas: desenvolvimento e teste. Na etapa de desenvolvimento, a otimização dos *hyperparameters* da rede é realizada, e na etapa de teste um novo conjunto de dados ainda não simulado é usado para a validação dos resultados.

Para evitar que a RNA perca sua capacidade de generalização para condições diferentes do conjunto de treinamento, isto é, sofra *overfitting*, aplicam-se técnicas de regularização de dados. Neste trabalho, foi aplicada a técnica de *dropout*, na qual os neurônios da RNA são aleatoriamente desativados a

fim de definir a probabilidade com que cada neurônio será desativado ou ativado em uma determinada simulação (Glorot et al., 2014). Essa probabilidade é um dos *hyperparameters* que devem ser otimizados durante a etapa de desenvolvimento.

Neste trabalho, foi utilizado um histórico de 2000 a 2018 para o desenvolvimento da RNA, de modo que 2000-2013 foi utilizado para treinamento, 2014-2016 para desenvolvimento e 2017-2018 para teste. Os dados históricos de precipitação foram obtidos através do modelo MERGE desenvolvido pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC); os dados futuros de precipitação (previsões retroativas) foram obtidos através do projeto GEFS *Reforecast* (NOAA, 2020); enquanto os dados de vazão natural foram obtidos com o ONS. As RNAs foram construídas individualmente para cada usina hidrelétrica do SIN para a previsão de vazão com horizonte de até 15 dias.

2.3 Modelo PREVIVAZ e geração do PREVS

A partir da aplicação integrada dos modelos hidroclimáticos, apresentada e descrita em Silva et al. (2006), foram criadas as cadeias RNA-GEFS, MGB-GEFS e SMAP-GEFS. As afluições obtidas através dessas cadeias apresentam periodicidade diária. A partir desses dados, é possível utilizar gerar uma série de vazões para um horizonte de seis semanas através do PREVIVAZ e gerar o arquivo PREVS.

O PREVIVAZ é um predictor de vazões semanais baseado na modelagem de séries temporais (Box and Jenkins, 1976). Esse modelo predictor faz as estimativas com base na série histórica das vazões através de um conjunto de modelos autorregressivos. Após a avaliação desses modelos, aquele que apresenta o melhor desempenho é utilizado para a previsão de vazões das próximas seis semanas (CEPEL, 2020)

O PREVS é um arquivo que possui dados de vazões semanais verificadas e previstas para 164 postos hidrológicos do SIN. Portanto, para a montagem desse arquivo, é necessário realizar a previsão de vazões semanais para o horizonte de seis semanas.

Esse processo difere entre os postos, uma vez que 84 utilizam apenas o PREVIVAZ, enquanto os demais são obtidos através de regressão ou são estabelecidos através de equações ou regras compostas com outros postos.

A previsão de vazões semanais utilizando o PREVIVAZ considera a vazão prevista pelo modelo chuva-vazão da cadeia simulada (RNA-GEFS, MGB-GEFS ou SMAP-GEFS) e essa informação deve ser acrescentada ao histórico de vazões do posto. Semanalmente o ONS libera os arquivos de entrada do programa atualizados para cada posto em seu sítio de forma controlada através do portal de Cadastro de Dados para Relacionamento Externo (CDRE). Cabe destacar que dependendo da semana, será necessário descartar as últimas semanas do PREVIVAZ.

Para a montagem do arquivo PREVS semanal, como há cadeias com diferentes metodologias de previsão de vazões,

cada cadeia também origina um PREVS, um arquivo texto que possui oito colunas. A primeira coluna é um contador, a segunda é referente ao código dos postos, enquanto a terceira até a oitava coluna são as vazões verificadas ou previstas para as próximas seis semanas.

3. ESTUDO DE CASO

O estudo de caso é focado na previsão de aflúências das usinas hidrelétricas existentes nas bacias do rio Grande e rio Paranaíba, que compõem a região hidrográfica do Paraná e estão localizadas no subsistema Sudeste/Centro-Oeste, representando aproximadamente 64% da sua capacidade de armazenamento (ONS, 2020b). Na bacia do Grande há 15 usinas hidrelétricas, dentre as quais se destacam Furnas, Marimondo e Água Vermelha, enquanto no Paranaíba há 19 aproveitamentos, com destaque para Emborcação, Itumbiara e São Simão (ONS, 2020b, 2020c), como mostra a Fig. 2.




Fig. 2 – Esquema de usinas hidrelétricas nas bacias do Grande e Paranaíba.

Os resultados de vazões estimadas para cada uma das cadeias posteriormente serão convertidos em energia natural afluente (ENA) através da multiplicação entre as vazões e as produtibilidades das usinas.

Como o ONS divulga semanalmente às quintas feiras os resultados de ENA para a semana seguinte, as cadeias também foram simuladas nesse dia. Para avaliar o desempenho das previsões de cada cadeia e da previsão divulgada pelo ONS em relação ENA consistida pelo relatório de Acompanhamento das Condições Hidroenergéticas (ACOMPH) nessas bacias, durante o período de maio de 2019 até maio de 2020, foram utilizados o erro percentual absoluto médio, em inglês, *mean absolute percentage error* (MAPE) (Montgomery et al., 2015), e coeficiente de eficiência de Nash-Sutcliffe (NS) (Nash and Sutcliffe, 1970), que são calculados através das equações (1) e (2), respectivamente.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t(t-1)}{y_t} \right| \quad (1)$$

$$NS = 1 - \frac{\sum_{t=1}^n (y_t - \hat{y}_t(t-1))^2}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (2)$$

Onde n é o número de amostras analisado; t , o período; y_t , o valor real; $\hat{y}_t(t-1)$, a previsão de y_t realizada no período anterior; \bar{y} , a média dos valores reais.

O MAPE expressa a magnitude do erro ou precisão da previsão em relação aos dados oficiais em termos percentuais, de modo que, quanto menor seu valor, melhor a previsão (Montgomery et al., 2015).

O NS compara a similaridade entre a previsão e os dados, de modo que o índice varia entre $-\infty$ e 1, sendo melhor quanto mais próximo a 1 (Nash and Sutcliffe, 1970).

4. RESULTADOS

Nesta seção, os resultados das previsões semanais de vazões das cadeias RNA-GEFS, MGB-GEFS e SMAP-GEFS são validadas mediante apresentação gráfica e parâmetros estatísticos calculados em relação aos dados divulgados pelo ONS no período de maio/2019 a maio/2020 (Fig. 3 e Fig. 4).




Fig. 3 – Histórico de ENA prevista (RNA-GEFS, MGB-GEFS, SMAP-GEFS e ONS) e consolidada para a bacia do Grande.




Fig. 4 – Histórico de ENA prevista (RNA-GEFS, MGB-GEFS, SMAP-GEFS e ONS) e consolidada para a bacia do Paranaíba.

De forma geral, as previsões das cadeias conseguem reproduzir o comportamento tanto das previsões do ONS quanto dos dados consolidados pelo ACOMPH em ambas as bacias (Fig. 3 e Fig. 4). Na bacia do Grande (Fig. 3), o ano de 2019 apresentou baixas aflúências em relação à 2020, o que pode ser justificado pelas anomalias negativas de precipitação na região, enquanto os maiores valores de ENA ocorreram em fevereiro/2020, devido ao grande volume de chuvas verificado, com resultados positivos de anomalia. Na bacia do Paranaíba (Fig. 4), a ENA também apresenta os menores valores durante 2019 e maiores no mês de fevereiro/2020.

Para a bacia do Grande (Fig. 3), ainda é possível observar que as previsões das cadeias e do ONS não conseguiram capturar com tanta sensibilidade as mudanças em magnitude nas aflúências, embora indicassem, em geral, a tendência de aumento ou redução. Porém, para a bacia do Paranaíba (Fig. 4), as previsões de aflúências das cadeias e do ONS foram representadas satisfatoriamente, especialmente em tendência e magnitude durante abril/2019 a outubro/2019. Em ambos os casos, essas variações são justificadas pelos modelos climático e hidrológicos.

A fim de comparar as previsões do ONS e das cadeias (RNA-GEFS, MGB-GEFS e SMAP-GEFS) com os dados consolidados, as medidas estatísticas foram calculadas em três etapas:

- Previsão de ENA e ENA consolidada no período de maio/2019 até maio/2020: para essa análise, foram utilizadas as séries temporais de previsão da RNA-GEFS e ONS em relação ao ACOMPH;
- Previsão de ENA e ENA consolidada no período de julho/2019 até maio/2020: essa análise permite a inclusão do MGB-GEFS.
- Previsão de ENA e ENA consolidada no período de novembro/2019 até maio/2020: essa análise permite a inclusão do SMAP-GEFS.

4.1 Comparação Semanal: Maio/2019-Maio/2020

As diferenças entre as previsões e os dados de ENA consolidados para o período de análise são melhores descritas e visualizadas através das medidas estatísticas. Assim, a Tabela 1 mostra o MAPE e NS.

Os resultados obtidos para o MAPE indicam que as previsões do ONS apresentam melhor precisão que a RNA-GEFS em ambas as bacias.

Com relação ao NS, ambas as previsões (realizadas pelo ONS e pela RNA-GEFS) apresentam bom desempenho no comportamento e representação dos dados oficiais consolidados pelo ACOMPH ($NS > 0,80$) nas duas bacias. No entanto, a previsão do ONS possui melhores resultados ($NS > 0,90$), estando de acordo com análise do MAPE.

Algo que merece ser destacado é a melhor precisão e desempenho na representação das previsões em relação às aflúências consistidas na bacia do Paranaíba em relação ao Grande.

Tabela 1 - Estatísticas para avaliação de desempenho do ONS e da RNA-GEFS na previsão de ENA em relação aos dados consistidos pelo ACOMPH.

BACIA	CADEIA	MAPE (%)	NS
Grande	RNA-GEFS	15,84	0,81
	ONS	10,69	0,92
Paranaíba	RNA-GEFS	11,06	0,85
	ONS	7,45	0,96

4.2 Comparação Semanal: Julho/2019-Maio/2020

Com o intuito de avaliar as previsões realizadas pelo ONS e pelas cadeias (RNA-GEFS e MGB-GEFS), foram calculadas as estatísticas mostradas na Tabela 2.

O MAPE indica que a previsão do ONS possui melhor precisão do que os modelos RNA-GEFS e MGB-GEFS em ambas as bacias, especialmente no Paranaíba.

Com relação ao NS, todas as previsões apresentam bom desempenho na representação dos dados consolidados pelo ACOMPH ($NS > 0,80$). Mas, assim como verificado para o MAPE, o ONS se destaca positivamente em relação às cadeias desenvolvidas ($NS > 0,90$).

Em relação às duas cadeias, a qualidade das previsões é, em geral, melhor na bacia do Paranaíba do que no Grande, assim como observado para as previsões do ONS. Outra observação consiste no melhor desempenho do MGB-GEFS em relação à RNA-GEFS na representação dos dados consolidados.

Tabela 2 - Estatísticas para avaliação de desempenho do ONS e das cadeias (RNA-GEFS e MGB-GEFS) na previsão de ENA em relação aos dados consistidos pelo ACOMPH.

BACIA	CADEIA	MAPE (%)	NS
Grande	RNA-GEFS	15,96	0,81
	MGB-GEFS	13,36	0,90
	ONS	11,42	0,92
Paranaíba	RNA-GEFS	11,80	0,85
	MGB-GEFS	16,27	0,91
	ONS	7,87	0,96

4.3 Comparação Semanal: Novembro/2019-Maio/2020

Com o objetivo de analisar o desempenho das previsões ao longo dos últimos sete meses, foram calculadas as estatísticas apresentadas na Tabela 3.

O MAPE indica que, para a bacia do Grande, as cadeias RNA-GEFS e MGB-GEFS exibem melhor desempenho que o ONS na previsão das aflúências. Em contrapartida, no Paranaíba, o ONS continua exibindo um resultado melhor que as cadeias desenvolvidas.

O NS indica que todas as previsões continuam exibindo bom desempenho na representação das aflúências consistidas em ambas as bacias ($NS > 0,70$), especialmente o ONS.

Tabela 3 - Estatísticas para avaliação de desempenho do ONS e das cadeias (RNA-GEFS, MGB-GEFS e SMAP-GEFS) na previsão de ENA em relação aos dados consistidos pelo ACOMPH.

BACIA	CADEIA	MAPE (%)	NS
Grande	RNA-GEFS	12,93	0,74
	MGB-GEFS	11,71	0,86
	SMAP-GEFS	19,45	0,78
	ONS	14,95	0,89
Paranaíba	RNA-GEFS	13,02	0,76
	MGB-GEFS	18,59	0,86
	SMAP-GEFS	13,32	0,86
	ONS	9,86	0,94

Alguns comentários devem ser feitos após essas análises temporais individuais:

- a. O período de calibração de cada cadeia desenvolvida (RNA, MGB, SMAP) é diferente daquele adotado pelo ONS na construção do SMAP. Isso impacta diretamente na qualidade da previsão das cadeias;
- b. O ONS utiliza dados de precipitação por conjunto (GEFS e ETA40), enquanto as cadeias utilizam apenas as previsões do GEFS. A mudança no tratamento desses dados também impacta as previsões, uma vez que há diversas incertezas que se propagam ao longo da cadeia de simulação;
- c. Em determinados momentos no período de análise, as cadeias apresentaram resultados tão bons ou melhores que o ONS, especialmente no período entre novembro/2019 e maio/2020.

5. CONCLUSÃO

Este trabalho apresentou em uma plataforma computacional integrada três técnicas de previsão de vazões, duas baseadas nas equações de *rainfall-runoff* e uma, em redes neurais, com o propósito de auxiliar no planejamento e operação do SIN, bem como indicar o comportamento das vazões e ENA aos agentes de comercialização de energia.

Como foi observado, esse é um problema complexo, uma vez que envolve diversas incertezas que se propagam ao longo da cadeia de simulação energética. Por isso, as análises das previsões e constantes melhorias nas metodologias adotadas para esse processo são extremamente importantes no desafio do planejamento e operação do SIN.

Nessa perspectiva, a performance das previsões das três técnicas abordadas neste trabalho (RNA-GEFS, MGB-GEFS e SMAP-GEFS), bem como a divulgada pelo ONS, foram avaliadas em relação às ENAs consistidas pelo ACOMPH em um estudo de caso para as bacias do rio Grande e Paranaíba através de parâmetros estatísticos (MAPE e NS). Essas estatísticas mostraram que as três cadeias conseguem, em geral, reproduzir o comportamento tanto das previsões do ONS quanto dos dados consistidos em ambas as bacias. Contudo, ao avaliar o desempenho na reprodução dos dados do ACOMPH, o destaque positivo é para as previsões divulgadas pelo ONS. Mas, cabe ressaltar que há ocasiões que tanto as cadeias quanto as previsões realizadas pelo ONS não conseguem acompanhar com tamanha sensibilidade as mudanças bruscas no comportamento das aflúncias, o que é justificado pelas incertezas inerentes ao processo de previsão de vazões integrado às previsões de precipitação.

Por fim, para estudos futuros, têm-se como proposta analisar as previsões de aflúncias a partir dessas técnicas para outras bacias hidrográficas de interesse do SIN. Adicionalmente, é possível testar outras metodologias de RNAs e desenvolver uma metodologia baseada em técnicas de inferência bayesiana para a previsão de aflúncias a partir do conjunto de vazões previstas pelos modelos RNA, MGB e SMAP.

AGRADECIMENTOS

Os autores expressam agradecimento a AES Tietê pelo suporte financeiro ao projeto estratégico de P&D da ANEEL 0064-1052/2017 e à Comercializadora Prime Energy, cujo apoio permitiu o desenvolvimento e aprimoramento das técnicas adotadas neste trabalho.

REFERÊNCIAS

- ANEEL. Agência Nacional de Energia Elétrica. (2020). *Sistema de Informações de Geração da ANEEL - SIGA*. Web page: <<http://www.aneel.gov.br/siga>>.
- Azevedo, L. G., Fontane, D. G., Porto, R. L. (1993). Expert System for the calibration of SMAP. *Water International*, 18 (2), 103-109.
- Box, G.E.P. and Jenkins, G. M. (1976). *Time series analysis: forecasting and control*. Holden-Day, Ann Arbor.
- Bravo, J. M., Collischonn, W., Tucci, C. E. M., Pilar, J. V., Silva, B. C. (2008). Avaliação dos benefícios de previsões de vazão na operação de reservatórios. *Revista Brasileira de Recursos Hídricos*. 13 (1), 197-213.
- Bravo, J. M., Collischonn, W., Tucci, C. E. M. (2009). Verificação da eficiência e eficácia de um algoritmo evolucionário multi-objetivo na calibração automática do modelo hidrológico IPH II. *Revista Brasileira de Recursos Hídricos*, 14 (3), 37-50.
- CEPEL. Centro de Pesquisas de Energia Elétrica. (2020). *PREVIVAZ - Modelos computacionais para previsão de aflúncias diárias, semanais e mensais*. Web page: <http://www.cepel.br/pt_br/produtos/previvaz-modelos-computacionais-para-previsao-de-afluencias-diarias-semanais-e-mensais.htm>.
- Collischonn, W. e Tucci, C. E. M. (2001). Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*, 6 (1), 73-79.
- Collischonn, W. e Tucci, C. E. M. (2003). Ajuste multiobjetivo dos parâmetros de um modelo hidrológico. *Revista Brasileira de Recursos Hídricos*, 8 (3), 27-39.
- Collischonn, W., Tucci, C. E. M., Clarke, R. T., Dias, P. L. S., Oliveira, G. S. (2005). Previsão sazonal de vazão na bacia do rio Uruguai 2: Previsão climática-hidrológica. *Revista Brasileira de Recursos Hídricos*. 10 (4), 61-72.
- Collischonn, W., Allasia, D. G., Silva, B. C., Tucci, C. E. M. (2007). The MGB-IPH model for large scale rainfall-runoff modeling. *Hydrological Sciences Journal*, 52 (5), 878-895.
- de Queiroz, A. R., Lima, L. M. M., Lima, J. W. M., da Silva, B. C., Scianni, L. A. (2016). Climate change impacts in the energy supply of the Brazilian hydro-dominant power system. *Renewable Energy*, 99, 379-389.
- de Queiroz, A. R., Faria, V. A., Lima, L. M., & Lima, J. W. (2019). Hydropower revenues under the threat of climate change in Brazil. *Renewable energy*, 133, 873-882.
- Fan, F. M., Collischonn, W., Meller, A., Botelho, L. C. M. (2014). Ensemble streamflow forecasting experiments in a tropical basin: The São Francisco River case study. *Journal of Hydrology*, 519, 2906-2919.

- Fan, F. M., Collischonn, W., Quiroz, K. J., Sorribas, M. V., Buarque, D. C., Siqueira, V. A. (2015). Flood forecasting on the Tocantins river using ensemble rainfall forecasts and real-time satellite rainfall estimates. *Journal of Flood Risk Management*, 9 (3), 278-288.
- Freire, P. K. M. M., Santos, C. A. G., Silva, G. B. L. (2019). Analysis of the use of discrete wavelet transforms coupled with ANN for short-term streamflow forecasting. *Applied Soft Computing Journal*, 80, 494-505.
- Géron, A. (2017). Hands-on Machine Learning with Scikit-Learn and Tensorflow. OREILLY.
- Glorot, X., Bordes, A., and Benigo, Y. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15:1929-1958.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). Deep Learning. MIT Press, Cambridge
- Hill, C., DeLuca, C., Balaji, M., Silva, A. (2004). The architecture of the Earth System Modeling Framework. *Computing in Science & Engineering*, 6 (1), 18-28.
- Hong, T. and Fan, S. (2016). Probabilistic electric load forecasting: A review. *International Journal of Forecasting*, 32 (3), 914-938.
- Kalnay, E. (2003). *Atmospheric modeling, data assimilation and predictability*. Cambridge University, Cambridge.
- Lima, J. W. M., Colischonn, W., Marengo, J. A. (2014). *Efeito das mudanças climáticas na geração de energia elétrica*. Hunter Books, São Paulo.
- Medeiros, M. S., Fleischmann, A. S., Oliveira, A. M., Corati, B. K., Fan, F. M., Martinbiancho, G. K., Jardim, P. F., Correa, S. W., Siqueira, V. A., Collischonn, W. (2018). *Manual de exemplo de aplicação do modelo MGB 2018 utilizando o IPH-Hydro Tools*. Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul.
- Montgomery, D. C., Jennings, C. L., Kulahci, M. (2015). *Time series analysis and forecasting*. John Wiley & Sons, New Jersey.
- Nash, J. E. and Stouffle, J. V. (1970). River flow forecasting through conceptual models part I – A discussion of principles. *Journal of Hydrology*, 10 (3), 282-290.
- NOAA. National Oceanic and Atmospheric Administration. (2020). *Global Ensemble Forecast System (GEFS)*. Web page: <<https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-ensemble-forecast-system-gefs>>.
- ONS. Operador Nacional do Sistema Elétrico. (2012). Aplicação de modelos de previsão de vazões a curto prazo na sub-bacia do Alto Rio Paranaíba – Relatório Final. Rio de Janeiro: ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2011). Aplicação de modelos de previsão de vazões a curto prazo na sub-bacia do Baixo Rio Grande – Relatório Final. Rio de Janeiro: ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2017a). Submódulo 7.3: Programação mensal da operação energética. Procedimentos de Rede. Rio de Janeiro: ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2017b). Recalibração do modelo SMAP para previsão de vazões a curto prazo na bacia do rio Paranapanema. Rio de Janeiro: ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2018). Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN. NT 0097/2018-RV1. Rio de Janeiro: ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2019). Metodologia de Previsão de Precipitação por Conjunto e Remoção de Viés com Histórico de Curto Prazo. NT 0053/2019, ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2020a). Programação da Operação. Web page: <<http://www.ons.org.br/paginas/energia-no-futuro/programacao-da-operacao>>.
- ONS. Operador Nacional do Sistema Elétrico. (2020b). Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN. NT 0097/2018-RV4, ONS.
- ONS. Operador Nacional do Sistema Elétrico. (2020c). Programação da Operação. Web page: <<http://www.ons.org.br/paginas/energia-agora/reservatorios>>.
- Silva, B. C., Tucci, C. E. M., Collischonn, W (2006). Previsão de vazão com modelos hidroclimáticos. *Revista Brasileira de Recursos Hídricos*, 11 (3), 15-29.
- Silva, P. M. O., Mello, C. R., Silva, A. M., Coelho, G. (2008). Modelagem da hidrografia de cheia emu na bacia hidrográfica da região Alto Rio Grande. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 12 (3), 258-265.
- Taormina, R. e Chau, K. (2015). Data-driven input variable selection for rainfall-runoff modeling using binary-coded particle swarm optimization and Extreme Learning. *Journal of Hydrology*, 529 (3), 1617-1631.
- Toth, Z. and Kalnay, E. (1997). Previsão de conjuntos no NCEP e o método de melhoramento. *Monthly Weather Review*, 125, 3297-3319.
- Toth, Z, Zhu, Y., Wobus R. (2010). *NCEP Global Ensemble Implementation News*. Web page: <http://www.emc.ncep.noaa.gov/gmb/ens/ens_imp_news.html>.
- WMO. World Meteorological Organization. (2015). *Climate observation. Status of the Global Observing System for climate*. Geneva: WMO.
- Ynoue, R. Y., Reboita, M. S., Ambrizzi, T., Silva, G. A. M. (2017). *Meteorologia: Noções básicas*. Oficina de Textos, São Paulo.
- Yonaba, H., Ancil, F., Fortin, V. (2010). Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. *Journal of Hydrologic Engineering*, 15 (4), 275-283.
- Zambelli, M. S. (2009). *Planejamento da operação energética do sistema interligado nacional baseado em modelo de controle preditivo*. Universidade Estadual de Campinas, UNICAMP. Faculdade de Engenharia Elétrica e de Computação (Doutorado). Campinas.
- Zealand C. M., Burn, D. H., Simonovic, S. P. (1999). Short term streamflow forecasting using artificial neural networks. *Journal of Hydrology*, 214:32-48.