

ESTRATÉGIAS DE PREVISÃO DE VAZÃO PARA FORMAÇÃO DO PREÇO DE ENERGIA ELÉTRICA NO CURTO PRAZO

Cassia Akemi Castro Kuki

Instituto de Sistemas Elétricos e Energia, Universidade Federal de Itajubá
Avenida B P S, 1303, Itajubá, Minas Gerais, Brasil
e-mail (cassiakuki@unifei.edu.br)

Francisca Lanai Ribeiro Torres

Instituto de Sistemas Elétricos e Energia, Universidade Federal de Itajubá
Avenida B P S, 1303, Itajubá, Minas Gerais, Brasil
e-mail (lanai.torres@unifei.edu.br)

Victor Augusto Duraes de Faria

Operations Research Graduate Program, North Carolina State University
2500 Stinson Drive, Raleigh, North Carolina, USA
e-mail (vaduraes@ncsu.edu)

Anderson Rodrigo de Queiroz

Department of Decision Sciences, North Carolina Central University
1801 Fayetteville St., Durham, North Carolina, USA
e-mail (adequeiroz@nccu.edu)

Luana Medeiros Marangon Lima

Nicholas School of Environment, Duke University
9 Circuit Drive, Durham, North Carolina, USA
e-mail (Imm89@duke.edu)

José Wanderley Marangon Lima

Marangon Consultoria & Engenharia
Rua Sebastião Pereira Leite, 48, Itajubá, Minas Gerais, Brasil
e-mail (jose.marangon@marangonenergia.com.br)

RESUMO

A afluência aos reservatórios das usinas do sistema interligado nacional (SIN) é uma das principais variáveis que impactam na formação do Custo Marginal da Operação (CMO) do sistema elétrico brasileiro e, conseqüentemente, do Preço de Liquidação das Diferenças (PLD). Devido à quantidade de incertezas envolvidas no processo, o problema de previsão do PLD torna-se complexo, mas é essencial para a tomada de decisão quanto aos contratos de compra e venda de energia para comercializadoras. Este trabalho apresenta três diferentes técnicas de transformação de chuva em vazão para a formação do preço da energia no curto prazo. Com a aplicação dos critérios estatísticos, foi possível observar que a composição dessas tecnologias representa, em geral, um desempenho satisfatório na previsão do PLD, especialmente quando é utilizado o modelo climático GEFS com o modelo hidrológico.

PALAVRAS CHAVE. Previsão de Vazão. Geração Hidrelétrica. Previsão de Preços de Curto Prazo.

Tópicos: EN&PG – PO na Área de Energia, Petróleo e Gás; SIM – Simulação

ABSTRACT

The set of reservoir inflows at the hydro power plants of Interconnected Power System (SIN) is one of the main variable that impacts the Short-term Marginal Cost (CMO) of Brazilian Power System, which, in turn, affects the Clearance Price (PLD). Due to the amount of uncertainties, the PLD forecast problem is the key issue for the middle office of a energy trader. This paper deals with PLD forecasting and presents three different techniques of transforming precipitation into inflows. The application of the statistical criteria indicates that the use of these technologies represents, in general, a satisfactory performance in the PLD forecasts, especially when the GEFS climate model integrated with the hydrological model is used.

KEYWORDS. Streamflow Forecasts. Hydro Power Generation. Spot Price Forecasts.

Paper topics: EN&PG – OR in Energy, Oil and Gas; SIM – Simulation

1. Introdução

A matriz energética brasileira é predominantemente hidráulica, representando aproximadamente 63% do total [ANEEL 2020]. Por esse motivo, a geração de energia elétrica é fortemente dependente das aflúências que chegam aos reservatórios, de modo que a operação do sistema hidrotérmico é sensível às variações climáticas [Faria et al. 2018], [de Queiroz et al. 2019].

Por esse motivo, o Operador Nacional do Sistema Elétrico (ONS), ao realizar o planejamento e programação da operação do sistema hidrotérmico, considera o acoplamento de um conjunto de modelos computacionais, que possuem diferentes horizontes de planejamento, bem como objetivos e graus de detalhamento das características do sistema e incertezas associadas distintos [Lima 2010]. A metodologia que soluciona o problema do despacho hidrotérmico é baseada nos programas computacionais NEWAVE e DECOMP, desenvolvidos e aprimorados continuamente pelo Centro de Pesquisas de Energia Elétrica (CEPEL), que simulam a operação para diferentes cenários de aflúências, das quais através de seus registros históricos é possível construir séries sintéticas de energia natural afluyente (ENA) [CEPEL 2013a, 2013b].

Tanto o ONS quanto a Câmara de Comercialização de Energia Elétrica (CCEE) utilizam esses algoritmos para o planejamento da operação e prospecção de preços de energia elétrica, porém com finalidades distintas. O ONS visa definir diretrizes de operação do setor elétrico brasileiro (SEB) para atendimento da demanda pelo menor custo energético, no qual é estabelecido o Custo Marginal da Operação (CMO) por subsistema. A CCEE, ao retirar restrições conjunturais de transmissão internas dos subsistemas e restrições de usinas em teste, visa a determinação do Preço de Liquidação das Diferenças (PLD), que é utilizado na liquidação e contabilização do mercado de curto prazo [Lima 2010].

O presente trabalho propõe a construção de uma cadeia computacional composta por diferentes modelos interconectados para a avaliação e cálculo do PLD para o horizonte de curto prazo. Para isso, são utilizados os modelos climáticos ETA40 e GEFS, bem como três diferentes metodologias que transformam chuva em vazão. Com as aflúências obtidas por esses modelos hidroclimáticos, o processo para a obtenção do PLD segue o padrão definido pelo ONS e CCEE. A aplicação de diferentes técnicas de previsão de aflúências para a simulação do PLD resulta em produtos atrativos que permitem analisar as incertezas associadas às vazões dos reservatórios de usinas, ampliando a visão dos comercializadores, e auxiliando na tomada de decisão de compra e venda de energia elétrica.

O artigo está dividido em cinco seções, incluindo a presente introdução. Na seção 2, são descritas as etapas para a previsão do PLD. Na seção 3, é apresentado um estudo de caso no qual os resultados de ENA e PLD dos modelos elaborados são comparados aos resultados oficiais de ENA e PLD, divulgados pelo ONS e CCEE, respectivamente. A seção 4 expõe a discussão dos

resultados. Por fim, na seção 5 são apresentadas algumas considerações e perspectivas futuras de pesquisa.

2. Metodologia

Dadas às características e peculiaridades do SIN, com predominância de usinas hidrelétricas, o PLD é definido através de uma cadeia de programas, onde uma das principais variáveis de influência em sua formação é a vazão, que é diretamente impactada pela precipitação. Por isso, para a previsão do PLD, são consideradas neste trabalho três grandes etapas, cujo detalhamento é apresentado nas subseções seguintes.

2.1. Previsão de Precipitação

Na previsão de variáveis atmosféricas, são utilizados modelos climáticos, que simulam as condições e comportamentos atmosféricos e interações entre a atmosfera e as superfícies terrestre e oceânicas através de diferentes equações numéricas [Ynoue et al. 2017].

Para a previsão dessas variáveis, é necessária a distinção entre os dois tipos possíveis: a) *previsão de tempo*, cuja previsão está limitada em até 14 dias de antecedência, uma vez que a confiabilidade dos resultados decai com o tempo; b) *previsão de clima*, que visa simular os fenômenos atmosféricos para períodos futuros maiores, normalmente meses [Ynoue et al. 2017]. Independentemente do tipo de previsão, é necessária a observação e a coleta dos dados atmosféricos a partir de sensoriamento remoto e medição *in situ* [WMO 2015], para, posteriormente, realizar as etapas de análise, previsão, e pós processamento [Ynoue et al. 2017].

Para alimentar os modelos de previsão de vazão no curto prazo, são utilizados dados fornecidos através dos resultados obtidos pelos modelos ETA40 e GEFS para a previsão de tempo. Para isso, é realizado o recorte de variáveis meteorológicas para a área da América do Sul.

2.1.2. Modelo Climático ETA40

O modelo ETA foi desenvolvido na Sérvia, antiga Iugoslávia, e se tornou operacional no *National Centers for Environmental Prediction* (NCEP) do *National Oceanic and Atmospheric Administration* (NOAA) em 1993 [Black 1994], sendo utilizado em diversos países. No Brasil, o modelo foi instalado no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), do Instituto Nacional de Pesquisas Espaciais (INPE).

O ETA é um modelo regional que representa os processos físicos e dinâmicos da atmosfera em pontos de grade [Black 1994]. Diversas melhorias e implementações no código do modelo foram realizadas ao longo dos anos, trazendo diversos benefícios às previsões [Mesinger et al. 2012]. As implementações nas versões do ETA também são disponibilizadas pelo CPTEC, cuja resolução horizontal é de 40 km com 38 camadas verticais, cobrindo a América do Sul e parte dos oceanos adjacentes [Chou et al. 2005], e as previsões do modelo são fornecidas duas vezes ao dia, às 00 e 12 UTC.

2.1.2. Modelo Climático GEFS

O GEFS é um modelo global, desenvolvido pelo NCEP/NOAA [Toth e Kalnay 1997], que fornece a precipitação por conjunto, também conhecido como *ensemble*. Essa metodologia permite gerar perturbações nas condições iniciais, sendo possível realizar previsões meteorológicas probabilísticas e estimar suas incertezas [Toth e Kalnay 1997]. Contudo, devido aos erros sistemáticos das previsões, foi implementado em 2006 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 [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

A previsão de vazão consiste na estimativa de escoamento com antecedência para diferentes horizontes de tempo, e tem como objetivo o gerenciamento de recursos hídricos. A *previsão de curto prazo* apresenta antecedência de até 14 dias, enquanto a *previsão de longo prazo* apresenta antecedência de até nove meses [Silva et al. 2006].

Para isso, são utilizados os modelos hidrológicos, que simulam os processos físicos do balanço hídrico que ocorrem em uma bacia hidrográfica, transformando a precipitação em vazão [Silva et al. 2006]. Para este trabalho, foram utilizados o Modelo Hidrológico de Grandes Bacias (MGB-IPH), *Soil Moisture Accounting Procedure* (SMAP), e Redes Neurais Artificiais (RNAs).

2.2.1. MGB-IPH

O modelo MGB-IPH simula os processos de transformação de chuva em vazão em grandes bacias, especialmente aquelas com área superior a 10.000 km², e tem como diferencial a representação do processo de evapotranspiração baseado na equação de Penman-Monteith que representa diferentes tipos de vegetação [Collischonn e Tucci 2001, 2007].

Os processos hidrológicos na superfície terrestre são simulados através das equações de *rainfall-runoff* e ocorre em quatro módulos: balanço hídrico no solo; evapotranspiração; escoamentos superficial, subsuperficial e subterrâneo nos elementos de discretização da bacia hidrográfica; e propagação de vazão na rede de drenagem [Collischonn e Tucci 2001].

Para a representação física da bacia hidrográfica, o modelo trabalha com a discretização em minibacias, as quais são divididas em Unidades de Respostas Hidrológicas (URH), que são áreas de comportamento hidrológico similares definidas pela combinação dos mapas de cobertura e tipo de solo [Collischonn et al. 2007].

Já para a aplicação do modelo, além do geoprocessamento das informações espaciais, são necessárias informações hidrológicas e climatológicas e calibração dos parâmetros de vegetação e solo da bacia simulada [Collischonn e Tucci 2001], [Collischonn et al. 2007].

Neste trabalho, o MGB-IPH foi calibrado manualmente e, complementarmente, com o algoritmo de calibração automática, pois a calibração manual permite o pré-ajuste dos parâmetros considerando o conhecimento hidrológico sobre o modelo e suas influências sobre o comportamento da bacia, enquanto a calibração automática auxilia o ajuste fino desses parâmetros de forma mais rápida. Para essa calibração foram utilizados 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 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 das equações de *rainfall-runoff*, aplicadas a quatro reservatórios (reservatório do solo, reservatório subterrâneo, reservatório da superfície e reservatório de planície), com processos internos e interativos [ONS 2018].

Para a aplicação do modelo, 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]. Com relação à 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].

Devido ao seu desempenho na previsão das vazões, o ONS adotou o SMAP como principal técnica. Sua aplicação abrange majoritariamente as bacias hidrográficas localizadas nas regiões Sul e Sudeste do Brasil. Para essas bacias, foram utilizadas bases de dados com diferentes períodos de precipitação e vazões naturais e incrementais de acordo com a disponibilidade dos dados nos postos pluviométricos e fluviométricos, respectivamente. Para o processo de calibração, o período escolhido foi aquele capaz de abranger o maior número de situações hidrológicas, que varia conforme a bacia em análise [ONS 2011, 2012].

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 por meio de um modelo complementar. Neste estudo, optou-se por utilizar o MGB-IPH. Em uma versão, a combinação entre esses modelos é alimentada pelo ETA40 e, em outra, pelo GEFS.

2.2.3. Redes Neurais Artificiais (RNA)

Redes neurais são modelos matemáticos inspirados no sistema nervoso central capazes de aprender com base em exemplos utilizados em seu treinamento.

Para este trabalho, foi utilizada a arquitetura *Multilayer Perceptron* (MLP). Nessa rede a *input layer* é responsável por receber as variáveis de entrada do modelo, que para este trabalho são: chuva passada, chuva futura e vazões passadas. A informação recebida na *input layer* é transferida para as *hidden layers*, nas quais são aplicadas combinações lineares em cada neurônio e, ao final, aplica-se uma função de ativação, que para este trabalho foi escolhida a unidade linear retificada (ReLU) [Goodfellow et al. 2016]. Esse processo se repete para todas as *hidden layers* até a *output layer* onde uma combinação linear final é aplicada a fim de obter uma dada previsão.

No processo de aprendizagem de uma RNA, calibram-se os parâmetros w (*weights*) e b (*biases*), responsáveis pelas combinações lineares, a fim de minimizar o erro da previsão, cujo processo também é chamado de treinamento. Além do treinamento, há outras duas etapas que devem ser consideradas: desenvolvimento e teste. A etapa de desenvolvimento é responsável pela otimização dos *hyperparameters* da rede, que são parâmetros definidos antes de se otimizar os parâmetros w e b mencionados anteriormente. Dentre os *hyperparameters* otimizados, pode-se citar: número de neurônios por camada, número de camadas, coeficientes de regularização, *learning rate* α e número de *epochs* [Glorot et al. 2014], [Goodfellow et al. 2016].

Concluída a otimização dos parâmetros mencionados, é realizada a etapa de teste do modelo, onde um conjunto de dados não utilizados nas etapas de treinamento e desenvolvimento é aplicado na validação dos resultados. Nessa etapa, o modelo realiza as previsões de vazão para esse conjunto de dados históricos e a precisão do modelo é aferida. Como o conjunto de treinamento e desenvolvimento foram utilizados em cima de um processo de otimização, é comum que os erros computados para esses dois conjuntos sejam inferiores ao que seria observado na prática. Por isso tem-se a necessidade do conjunto de teste que, por não ter participado do processo de otimização, representa mais fielmente o comportamento do modelo em uma condição de previsão real.

Neste trabalho foi utilizado nos modelos de RNAs um histórico de dados de 2000 a 2018, no qual o período de 2000-2013 foi utilizado para o conjunto de treinamento, 2014-2016 para desenvolvimento e 2017-2018 para teste. Os dados históricos de chuva foram obtidos pelo modelo MERGE/CPTEC, os dados de vazão naturais foram obtidos diretamente com o ONS, e as previsões retroativas de chuva foram obtidas por meio do projeto GEFS *Reforecast* [NOAA, 2020]. Foram construídas RNAs individualizadas para cada usina hidrelétrica do SIN e previsões de vazão futura foram realizadas para até 15 dias.

2.3. Cadeia de Simulação e Programação da Operação

A partir da aplicação integrada dos modelos de previsão de clima e vazão, neste trabalho foram criadas as cadeias RNA-GEFS, MGB-ETA40, MGB-GEFS, SMAP-ETA40 e SMAP-GEFS. Com as aflúncias diárias obtidas por essas cadeias, é possível realizar o processo para a obtenção

do PLD, no qual se utilizam os modelos de planejamento da operação energética desenvolvidos pelo CEPEL: PREVIVAZ, GEVAZP, NEWAVE e DECOMP.

Para o planejamento da operação, o ONS elabora o Programa Mensal da Operação (PMO), que possui referência mensal e com revisões semanais e tem como objetivo determinar as metas de geração das usinas hidrelétricas, termelétricas e nucleares do SIN, metas de intercâmbio entre subsistemas e outras diretrizes operativas [ONS 2017].

Como o PMO apresenta revisões semanais, as afluências diárias previstas pelos modelos de chuva-vazão são utilizadas para determinar as afluências médias da próxima semana operativa. Essas afluências são previstas para um horizonte de seis semanas pelo PREVIVAZ [CEPEL, 2020a], que gera a previsão para 84 aproveitamentos. Após esta previsão, o modelo GEVAZP gera a árvore de vazões armazenada em formato binário no arquivo com os cenários de vazão para cada aproveitamento e estágio do horizonte de planejamento [CEPEL 2020b]. O modelo DECOMP tem como dados de entrada um conjunto de arquivos gerados pelo GEVAZP semanalmente, e os arquivos de cortes de *Benders* gerados pelo NEWAVE mensalmente [CEPEL 2013a, 2013b].

Com a execução do DECOMP, é apresentada uma síntese estratégica da operação definida para cada usina e subsistema, assim como os CMOs associados a cada estágio e cenário de vazão [CEPEL 2013a]. Para isso, esses custos são comparados ao teto e ao piso definido para o ano [ANEEL 2019]. Caso o CMO de um determinado subsistema assuma um valor menor (ou maior) que o limite inferior (ou superior) pré-definido pela ANEEL, o PLD será valorado conforme o piso (ou o teto). Em circunstância contrária, o PLD será igual ao CMO.

3. Estudo de Caso

O SIN é composto por quatro subsistemas: Sudeste/Centro-Oeste, Sul, Nordeste e Norte, que possuem características climáticas e geográficas próprias. Esses subsistemas possuem diversas bacias hidrográficas, com características particulares e diversos aproveitamentos hidrelétricos distribuídos ao longo da cascata [ONS 2020].

Com a simulação do NEWAVE e DECOMP, obtém-se a ENA e o PLD por subsistema para cada uma das cadeias. Para avaliação dos resultados dessas variáveis, foi considerado o período de julho de 2019 até maio de 2020. As simulações dos modelos de previsão são realizadas semanalmente, uma vez que os dados de previsão de ENA são liberados às quintas feiras pelo ONS e o valor do PLD vigente para a semana seguinte, às sextas feiras pela CCEE.

Para avaliar o desempenho de cada modelo de simulação com relação à ENA e ao PLD divulgado pelo ONS e CCEE, respectivamente, foram utilizados o erro percentual absoluto médio (MAPE) [Montgomery et al. 2015] e coeficiente de eficiência de Nash-Sutcliffe (NS) [Nash e Sutcliffe 1970], que são calculados através das equações (1) e (2), respectivamente.

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

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

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 mais próximo de zero, 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 e Sutcliffe 1970].

4. Resultados

Nessa seção, os resultados das previsões de ENA e PLD dos modelos RNA-GEFS, MGB-ETA40, MGB-GEFS, SMAP-ETA40 e SMAP-GEFS são validados mediante apresentação gráfica e parâmetros estatísticos calculados em relação aos dados divulgados pelo ONS e CCEE no período de julho/2019 até maio/2020 (Figura 1 e Figura 2).




Figura 1 – Série histórica de ENA prevista pelo ONS e pelas cadeias (RNA-GEFS, MGB-ETA40, MGB-GEFS, SMAP-ETA40 e SMAP-GEFS) por subsistema entre julho/2019 e maio/2020.




Figura 2 – Série histórica de PLD divulgado pela CCEE e PLD previsto pelas cadeias (RNA-GEFS, MGB-ETA40, MGB-GEFS, SMAP-ETA40 e SMAP-GEFS) por subsistema entre julho/2019 e maio/2020.

Na Figura 1, observa-se que o período de análise de 2019 abrangeu basicamente o período seco (julho-novembro), no qual ocorreu os menores valores de ENA nos subsistemas Sudeste/Centro-Oeste, Nordeste e Norte. Em contrapartida, no subsistema Sul, os maiores valores de ENA ocorreram nesse mesmo período. Ambos os casos podem ser justificados pela atuação de sistemas atmosféricos sobre as regiões, que dificultaram ou favoreceram a ocorrência de precipitação sobre as bacias hidrográficas. Com a entrada do período úmido, houve melhora nas condições de ENA nos subsistemas Sudeste/Centro-Oeste, Nordeste e Norte, enquanto no Sul houve redução, também justificadas pelas condições meteorológicas.

Simultaneamente, na Figura 2, observa-se a elevação do PLD durante os meses de 2019 em todos os subsistemas à medida que a ENA reduziu. Já no começo de 2020, apesar da sinalização de elevação da ENA, mantiveram-se as condições de aflúências abaixo da média histórica em todos os subsistemas, e, conseqüentemente, elevação do PLD. Contudo, essa situação se reverteu na virada de janeiro para fevereiro em todos os subsistemas, uma vez que aumentaram os volumes de chuva, especialmente sobre as bacias hidrográficas do Sudeste/Centro-Oeste. Mas, em março, o PLD aumentou novamente no Sudeste/Centro-Oeste e Sul em decorrência da redução das aflúências, impactada pelo volume de precipitação abaixo da média histórica. Já de março/2020 em diante, a redução do PLD foi justificada pelas medidas de isolamento implantadas em decorrência da Covid-19, que impactaram diretamente na carga em todos os setores da economia. Por fim, a elevação do PLD no mês de maio/2020 no Sudeste/Centro-Oeste e Sul, apesar da carga reduzida nesses subsistemas, foi justificada redução das aflúências, que ficaram abaixo da média histórica, e deplecionamento dos reservatórios.

De forma geral, durante o período de análise apresentado nas Figura 1 e Figura 2, as cadeias conseguiram reproduzir o comportamento das previsões de ENA do ONS e dos resultados oficiais de PLD da CCEE.

Como o as cadeias foram desenvolvidas e tiveram seus dados disponibilizados em períodos distintos, as medidas estatísticas MAPE e NS foram calculadas em três etapas:

- 1) Previsão de ENA e PLD no período de julho/2020 até maio/2020: nessa análise foram utilizadas as séries temporais de previsão das cadeias RNA-GEFS, MGB-ETA40 e MGB-GEFS;
- 2) Previsão de ENA e PLD no período de novembro/2019 até maio/2020: essa análise permite a inclusão do SMAP-GEFS;
- 3) Previsão de ENA e PLD no período de janeiro/2020 até maio/2020: essa análise permite a inclusão do SMAP-ETA40.

4.1. Comparação semanal: Julho/2019-Maio/2020

A Tabela 1 mostra que resultados obtidos para o MAPE indicam que as previsões de ENA são melhores no subsistema Sudeste/Centro-Oeste, enquanto para o PLD, a melhor precisão é no Nordeste e Sul. Com relação às cadeias, aquela que apresenta melhor precisão na maioria dos subsistemas para as duas variáveis analisadas é o MGB-GEFS, seguida pelo MGB-ETA40.

Já os resultados obtidos para o NS, também descritos na Tabela 1, indicam bom desempenho e representação da ENA prevista pelo ONS e dos dados oficiais de PLD da CCEE em todos os subsistemas para todas as cadeias ($NS > 0,75$). Dentre as cadeias, aquela que melhor representa os resultados é o MGB-GEFS, seguida pelo MGB-ETA40. Estando de acordo com os resultados obtidos para o MAPE.

4.2. Comparação semanal: Novembro/2019-Maio/2020

A Tabela 2 mostra que os resultados obtidos para o MAPE indicam que as previsões de ENA são melhores nos subsistemas Sudeste/Centro-Oeste e Norte, enquanto para a variável do PLD, a melhor precisão é no Sul. Dentre as cadeias, aquela que representa com mais precisão os dados do ONS e CCEE é o SMAP-GEFS e MGB-GEFS, respectivamente.

Já os resultados obtidos para o NS, também descritos na Tabela 2, indicam bom desempenho e representação da ENA prevista pelo ONS e dos dados oficiais de PLD da CCEE em todos os subsistemas para todas as cadeias ($NS > 0,90$). Dentre as cadeias, destacam-se o SMAP-GEFS para ambas as variáveis.

4.3. Comparação semanal: Janeiro/2020-Maio/2020

Na Tabela 3, os resultados do MAPE indicam que as previsões de ENA são melhores nos subsistemas Sudeste/Centro-Oeste e Norte, enquanto para o PLD, no Sul. A análise entre as cadeias permite observar que as combinações entre os modelos SMAP e MGB, independentemente do

modelo climático, geram previsões mais precisas de ENA. Já para o PLD, as melhores cadeias são aquelas que utilizam o MGB.

Já os resultados obtidos para o NS, também descritos na Tabela 3, indicam bom desempenho e representação da ENA prevista pelo ONS e dos dados oficiais de PLD da CCEE em todos os subsistemas para todas as cadeias ($NS > 0,90$), com exceção da RNA-GEFS no Sul. Ao se analisar os resultados das variáveis ENA e PLD, é possível observar que as previsões das cadeias SMAP-MGB se ajustam melhor às informações do ONS e CCEE, independentemente do modelo climático.

Algo que merece ser destacado nesta análise quando comparada aos demais períodos é a elevação do MAPE e a redução do NS para a variável PLD. Isso quer dizer que a qualidade das previsões decaiu neste período, pois a variação da carga impactou mais o PLD do que as aflúncias.

Uma outra observação que deve ser feita é a diferença dos resultados de MAPE e NS para as variáveis de ENA e PLD, independente do período de análise. Isso acontece porque outras variáveis, além da ENA, também impactam o PLD, tais como armazenamento, intercâmbio de energia entre subsistemas e carga, que não foram consideradas neste trabalho.

Tabela 1 - Estatísticas de desempenho das cadeias (RNA-GEFS, MGB-ETA40 e MGB-GEFS) na previsão de ENA e PLD em relação aos dados divulgados pelo ONS e CCEE, respectivamente.

SUBSISTEMA	CADEIA	ENA		PLD	
		MAPE (%)	NS	MAPE (%)	NS
SUDESTE/ CENTRO-OESTE	RNA-GEFS	9,57	0,96	13,14	0,90
	MGB-ETA40	7,85	0,96	12,54	0,90
	MGB-GEFS	6,48	0,96	11,12	0,91
SUL	RNA-GEFS	22,07	0,75	12,73	0,90
	MGB-ETA40	18,91	0,88	12,48	0,87
	MGB-GEFS	13,43	0,92	11,23	0,88
NORDESTE	RNA-GEFS	32,95	0,93	12,81	0,91
	MGB-ETA40	16,92	0,87	10,11	0,93
	MGB-GEFS	20,30	0,87	11,05	0,93
NORTE	RNA-GEFS	11,96	0,96	20,29	0,90
	MGB-ETA40	22,29	0,98	10,68	0,93
	MGB-GEFS	6,52	0,99	9,86	0,94

Tabela 2 - Estatísticas calculadas para avaliação de desempenho das cadeias (RNA-GEFS, MGB-ETA40, MGB-GEFS e SMAP-GEFS) na previsão de ENA e PLD em relação aos dados divulgados pelo ONS e CCEE, respectivamente.

SUBSISTEMA	CADEIA	ENA		PLD	
		MAPE (%)	NS	MAPE (%)	NS
SUDESTE/ CENTRO-OESTE	RNA-GEFS	9,26	0,93	15,45	0,92
	MGB-ETA40	7,82	0,93	16,04	0,90
	MGB-GEFS	7,15	0,93	13,46	0,92
	SMAP-GEFS	3,70	0,99	13,62	0,94
SUL	RNA-GEFS	22,62	0,82	14,81	0,91
	MGB-ETA40	17,49	0,91	15,94	0,87
	MGB-GEFS	15,41	0,90	13,63	0,90
	SMAP-GEFS	3,38	1,00	12,09	0,94
NORDESTE	RNA-GEFS	14,93	0,91	15,60	0,92
	MGB-ETA40	19,80	0,80	12,50	0,93
	MGB-GEFS	21,10	0,80	13,92	0,94
	SMAP-GEFS	19,89	0,80	15,59	0,94
NORTE	RNA-GEFS	10,53	0,94	27,18	0,90
	MGB-ETA40	6,68	0,99	13,38	0,93
	MGB-GEFS	6,43	0,99	12,08	0,94
	SMAP-GEFS	7,63	0,99	15,71	0,93

Tabela 3 - Estatísticas calculadas para avaliação de desempenho das cadeias (RNA-GEFS, MGB-ETA40, MGB-GEFS, SMAP-GEFS e SMAP-ETA40) na previsão de ENA e PLD em relação aos dados divulgados pelo ONS e CCEE, respectivamente.

SUBSISTEMA	CADEIA	ENA		PLD	
		MAPE (%)	NS	MAPE (%)	NS
SUDESTE/ CENTRO-OESTE	RNA-GEFS	8,67	0,87	18,15	0,90
	MGB-ETA40	7,09	0,90	17,70	0,91
	MGB-GEFS	8,31	0,86	15,28	0,91
	SMAP-ETA40	3,37	0,98	16,38	0,93
	SMAP-GEFS	3,49	0,97	15,18	0,94
SUL	RNA-GEFS	24,26	0,35	17,10	0,92
	MGB-ETA40	21,24	0,67	17,54	0,86
	MGB-GEFS	17,94	0,77	15,55	0,89
	SMAP-ETA40	3,86	0,99	14,37	0,95
	SMAP-GEFS	3,88	0,99	12,69	0,96
NORDESTE	RNA-GEFS	13,74	0,85	17,79	0,90
	MGB-ETA40	17,35	0,61	13,07	0,93
	MGB-GEFS	18,04	0,61	16,98	0,91
	SMAP-ETA40	17,75	0,60	19,54	0,92
	SMAP-GEFS	17,71	0,62	19,00	0,92
NORTE	RNA-GEFS	12,72	0,78	36,68	0,84
	MGB-ETA40	5,35	0,96	14,51	0,91
	MGB-GEFS	5,18	0,97	13,97	0,92
	SMAP-ETA40	5,58	0,96	19,52	0,89
	SMAP-GEFS	5,69	0,95	19,21	0,90

5. Conclusão

A previsão de aflúncias é fundamental no planejamento e operação do SEB, por isso, este artigo apresentou três diferentes técnicas para a previsão de aflúncias, cujos resultados impactaram diretamente no PLD.

Durante o processo de obtenção das trajetórias do PLD, foi possível observar as incertezas associadas às previsões de tempo e de vazão e também na própria cadeia de simulação com os modelos energéticos, que se propagaram para as fases seguintes.

Apesar dos diferentes períodos de calibração, a comparação dos resultados obtidos através de análises estatísticas mostra que a performance das previsões obtidas com os modelos hidrológicos (RNA, MGB e SMAP) integrados aos modelos climáticos (ETA40 e GEFS) em relação às previsões de ENA do ONS e aos dados oficiais de PLD da CCEE foi, em geral, satisfatória. O destaque principal é para a qualidade dos resultados quando da utilização do modelo climático GEFS, independente do modelo hidrológico escolhido ser MGB ou SMAP combinado ao MGB.

Além disso, as melhorias constantes nas cadeias fizeram com que suas previsões apresentassem melhores desempenhos na representação da ENA e do PLD. Porém, no período entre janeiro/2020-maio/2020, a melhora dos resultados foi perceptível apenas na ENA, uma vez que, em decorrência das condições isolamento implantadas devido à Covid-19, houve redução brusca da carga, impactando o PLD mais do que a ENA.

Diante do conjunto de resultados de PLD para as cadeias, é perceptível a dificuldade dos agentes de comercialização na avaliação e escolha de qual conjunto de dados confiar e utilizar, por isso, para estudos futuros, recomenda-se desenvolver uma nova cadeia baseada em técnicas de *ensemble* para previsão de aflúncias, considerando o conjunto de resultados obtidos com as cadeias de RNA, MGB e SMAP. Outra sugestão consiste na avaliação do PLD considerando o impacto da previsão de outras variáveis, como a carga, que pode ser prevista através de RNAs.

Referências

- ANEEL. Agência Nacional de Energia Elétrica. (2019). Resolução Normativa. RN 858-2019, ANEEL.
- ANEEL. Agência Nacional de Energia Elétrica. (2020). Banco de Informações de Geração – BIG. Web page: <<https://www2.aneel.gov.br/aplicacoes/capacidadebrasil/Combustivel.cfm>>. Acesso: 2020-05-20
- Black, T. L. (1994). NMC notes. The new NMC mesoscale ETA model: Description and forecast examples. *Weather Analysis and Forecasting*, 9:256-278.
- CEPEL. Centro de Pesquisas de Energia Elétrica. (2013a). Modelo Decomp – Determinação da coordenação da operação a curto prazo. Manual do usuário. CEPEL.
- CEPEL. Centro de Pesquisas de Energia Elétrica. (2013b). Projeto Newave – Modelo estratégico de geração hidrotérmica a subsistemas equivalentes. Manual do usuário. CEPEL.
- CEPEL. Centro de Pesquisas de Energia Elétrica. (2020a). Previvaz – Modelos computacionais para previsão de aflúências 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. Acesso: 2020-05-20.
- CEPEL. Centro de Pesquisas de Energia Elétrica. (2020b). Gevazp – Modelo de geração de cenários de energias e vazões. Web page http://www.cepel.br/pt_br/produtos/gevazp-geracao-de-series-sinteticas-de-energias-e-vazoes-periodicas.htm. Acesso: 2020-05-20.
- Chou, S. C., Bustamante, J. F., Gomes, J. L. (2005). Evaluation of ETA model seasonal precipitation over South America. *Nonlinear Processes in Geophysics*, 12:537-555.
- Collischonn, W. e Tucci, C. E. M. (2001). Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*, 6:73-79.
- 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*, 52:878–895.
- 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.
- Faria, V. A. D., de Queiroz, A. R., Lima, L. M. M., Lima, J. W. M. (2018). Cooperative game theory and last addition method in the allocation of firm energy rights. *Applied Energy*, 226:905-915.
- Glorot, X., Bordes, A., 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.
- Lima, J. W. M. (2010). Economia do Setor Eletro-Energético. Universidade Federal de Itajubá, UNIFEI. Itajubá.

Mesinger, F., Chou, S. C., Gomes, J. L., Jovic, D., Bastos, P., Bustamante, J. F., Lazic, L., Lyra, A. A., Morelli, S., Ristic, I., Veljovic, K. (2012). An upgrade version of the Eta model. *Meteorological and Atmospheric Physics*, 116:63-79.

Montgomery, D. C., Jennings, C. L., Kulahci, M. (2015). Time series analysis and forecasting. 2nd edition. John Wiley & Sons, New Jersey.

Nash, J. E. e Stedinger, J. V. (1970). River flow forecasting through conceptual models part I – A discussion of principles. *Journal of Hydrology*, 10:282-290.

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>. Acessado em: 2020-05-20.

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. (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. (2017). Submódulo 7.3: Programação mensal da operação energética. Procedimentos de Rede, ONS.

ONS. Operador Nacional do Sistema Elétrico. (2018). Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN. NT 0097/2018-RV4, 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. (2020). Hidrolétricas do SIN – 2020-2024. Web page. <http://www.ons.org.br/paginas/sobre-o-sin/mapas>. Acessado: 2020-05-20.

Silva, B. C., Tucci, C. E. M., Coolischonn, W. (2006). Previsão de vazão com modelos hidroclimáticos. *Revista Brasileira de Recursos Hídricos*. 11:15-29.

Toth, Z. e 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. Acessado: 2020-05-20

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.