

Otimização Estocástica Implícita para Operação de Reservatório em Sergipe

Raul Fontes Santana¹ & Alcigeimes Batista Celeste²

RESUMO: O desenvolvimento e aplicação de técnicas que buscam melhorar a eficácia da operação de reservatórios é indispensável para solucionar deficiências no abastecimento de água. Este trabalho aplica o modelo de otimização estocástica implícita, refinado por uma estratégia de previsão de afluências médias de longo prazo e por aprendizado baseado em instâncias, incrementado por regressão localmente ponderada, denominado de OEI-LTF-kNN, aplicado a barragem do rio Poxim. Com o objetivo de avaliar a eficiência do modelo aplicado, o reservatório também foi operado por meio de otimização determinística sob previsão perfeita (ODPP), pela política de operação padrão (SOP) e pela otimização estocástica explícita (PDE) que foram comparados em termos da vulnerabilidade encontrada em cada um dos 100 cenários de validação perante os quais foram aplicados. O modelo OEI-LTF-kNN foi empregado frente aos horizontes de previsão 0, 1, 3, 6, 9, 12, 18 e 24 meses. As operações demonstraram que o modelo OEI-LTF-kNN com horizontes de previsão de três meses ou mais apresentou-se menos vulnerável do que os modelos SOP e PDE, e semelhantes ao modelo ODPP, revelando que é aplicável com eficiência em reservatórios.

Palavras-chave: Previsão de Afluências Médias de Longo Prazo, Aprendizado Baseado em Instâncias, Rio Poxim.

INTRODUÇÃO

Deficiências nas operações dos reservatórios de água têm promovido prejuízos no atendimento das demandas dos seus usuários. Ocasionalmente pelo aumento das demandas, redução da disponibilidade de água, falhas no gerenciamento dos reservatórios, priorização para geração de energia elétrica, entre outras fontes potencialmente prejudiciais a eficácia dos reservatórios. Para Harou et al. (2009) o valor econômico da água no tempo e no espaço motivará cada vez mais os esforços para enfrentar a escassez hídrica e diminuir conflitos entre usuários.

A operação dos reservatórios geralmente é realizada através das chamadas curvas-guia, as quais estabelecem requisitos sazonais de armazenamento e ações que devem ser tomadas em conformidade com o estado atual do reservatório. Estas curvas normalmente são originadas por modelos de simulação que oferecem respostas dos reservatórios a partir de políticas operacionais pré-definidas. Em razão de existir inúmeras políticas possíveis, as técnicas de otimização podem ajudar a determinar a melhor, pois examinam implicitamente todas as decisões viáveis em busca da solução ideal (AHMAD, 2014).

De uma maneira geral os modelos de otimização podem ser determinísticos, quando assumem condições hidrológicas conhecidas, ou estocásticos, quando consideram as incertezas de eventos aleatórios, uma vez que os recursos hídricos não podem ser previstos com exatidão. Os modelos de otimização estocástica podem ser classificados como: otimização estocástica explícita (OEE) e otimização estocástica implícita (OEI). A decisão sobre o método a ser utilizado depende do tipo de análise de problema para cada sistema de recursos hídricos (CELESTE & EL-SHAFIE, 2018).

Neste trabalho, o principal modelo a ser empregado será baseado em otimização estocástica implícita (OEI). O modelo é refinado por uma estratégia de previsão de afluências

¹ Mestrando do Curso de Pós-Graduação em Engenharia e Ciências Ambientais, Universidade Federal de Sergipe, Avenida Marechal Rondon, s/n, Jardim Rosa Elze, São Cristóvão, SE, CEP: 49100-000, eng.raulfs@gmail.com (apresentador do trabalho);

² Professor, Departamento de Engenharia Civil, Universidade Federal de Sergipe, Avenida Marechal Rondon, s/n, Jardim Rosa Elze, São Cristóvão, SE, CEP: 49100-000, geimes@yahoo.com.

médias de longo prazo (LTF: *long-term forecast*) e por aprendizado baseado em instâncias, especificamente, o algoritmo dos k vizinhos mais próximos (k NN: *k-nearest neighbor*), incrementado por regressão localmente ponderada (LWR: *locally weighted regression*), formando o modelo denominado de OEI-LTF- k NN. Tendo como estudo de caso a barragem construída no rio Poxim, localizada no estado de Sergipe. O desempenho das regras operacionais derivadas pelo OEI-LTF- k NN será comparado com o de vários outros modelos: otimização determinística sob previsão perfeita (ODPP), política de operação padrão (SOP: *standard operating policy*) e programação dinâmica estocástica (PDE), através do índice de vulnerabilidade, que mede a magnitude de uma falha.

MATERIAL E MÉTODOS

Otimização estocástica implícita também é conhecida por otimização Monte Carlo e otimiza a operação do sistema perante uma série longa e contínua no tempo, de dados de afluência, obtida de registros históricos ou gerada sinteticamente, ou muitas sequências mais simples e equitativas. Assim, a maioria dos aspectos estocásticos do problema, incluindo correlações espaciais e temporais de afluências naturais, são implicitamente incluídos e métodos de otimização determinística podem ser aplicados diretamente (LABADIE, 2004).

A implementação da previsão da LTF na OEI modifica as variáveis de entrada (normalmente, níveis atuais de armazenamento e afluências esperada no mês), utilizando a previsão média das vazões em um intervalo de tempo futuro (horizonte de previsão), no lugar da previsão da vazão para cada mês. Este intervalo pode variar a depender da quantidade de meses considerados para cálculo da média que melhor se ajuste ao modelo, permitindo análise do intervalo que apresenta menor vulnerabilidade (MOREIRA & CELESTE, 2017).

Modelos típicos de OEI utilizam análises de regressão para correlacionar os dados. Diferentemente da maioria dos outros algoritmos de aprendizagem, que utilizam representações globais da função de destino, como é o caso da regressão linear ou não-linear, os algoritmos de aprendizado baseado em instâncias armazenam apenas alguns ou todos os exemplos de treinamento e adiam qualquer esforço de generalização até que uma nova instância seja classificada. Os processos de classificação k vizinhos mais próximos (k NN) são as formas mais populares de aprendizado baseado em instâncias (FUENTES & SOLORIO, 2004). Para aplicação em uma OEI, utilizam-se também os dados ótimos gerados pela calibração com um modelo determinístico (ODPP) para a construção de um banco de dados de treinamento.

Para a calibração, o modelo ODPP será operado frente aos cenários de 100 cenários sintéticos, cada um com 110 anos de afluências mensais gerados pelo programa Castalia, informações mais detalhadas do programa podem ser encontradas no trabalho de EFSTRATIADIS et al., (2014). A exclusão dos primeiros 5 anos é realizada para eliminar a influência do volume inicial cheio do reservatório, e a dos últimos 5 anos é para eliminar a influência das condições finais de armazenamento, totalizando 100 anos de horizonte de operação. Os resultados ótimos da operação do modelo ODPP serão utilizados para a construção dos bancos de dados contendo as alocações em cada mês t , $R(t)$, volume armazenado no início do mês, $S(t-1)$, e afluência média para os próximos H_{fcast} meses, $\bar{I}(t \rightarrow t + H_{fcast} - 1)$, incluindo o mês atual. Serão considerados horizontes de previsão $H_{fcast} = 0, 1, 3, 6, 9, 12, 18, \text{ e } 24$ meses. Enquanto isso, o modelo PDE é calibrado baseado na série histórica.

O reservatório de estudo está localizado na sub-bacia hidrográfica do rio Poxim, no estado de Sergipe. Foi inaugurado em maio de 2013 é chamado de Jaime Umbelino de Souza, estendendo-se por 1.125 m, com 5,2 km² de área e capacidade de armazenar 32 hm³ de água, tornando-se o maior reservatório do estado e contribuindo com cerca de 30% do abastecimento da capital sergipana (ROCHA et al., 2014).

Com o propósito de provocar muitas situações de falhas nos sistemas e analisar como os modelos irão lidar com elas, o reservatório será operado atendendo à descarga média de longo período (MLP). Com o intuito de simplificar as questões de múltiplos usos presentes no reservatório, será considerado a MLP como única demanda do reservatório, e esta será utilizada para todo o período de operação.

O modelo de otimização determinística utilizado tem como principal objetivo encontrar as melhores alocações do reservatório, satisfazendo da melhor forma possível a demanda sem comprometer o sistema. A política de operação padrão (SOP) produz a regra de operação mais simples e prioriza a liberação imediata de água até atingir o nível da demanda. E a PDE é, talvez, a técnica mais utilizada na prática para trabalhar com as incertezas nos dados de aflúências. Todavia, a necessidade de discretizar os dados de aflúências e armazenamentos do reservatório, promove uma das limitações do modelo.

Para validar e comparar os modelos, serão gerados outros 100 cenários, cada um consistindo de uma série de aflúências mensais de 110 anos, assim como no processo de calibração. Após definição das políticas de operação de todos os modelos, estas serão utilizadas para operar perante os novos cenários gerados. Para fins de comparação, os modelos ODPP, SOP e PDE também serão empregados perante tais cenários. O índice de vulnerabilidade, igual a média quadrática ao longo de todos os N meses de operação, será utilizado para comparar as diferentes abordagens.

RESULTADOS E DISCUSSÃO

O reservatório foi operado via ODPP, SOP, PDE e OEI-LTF-kNN ($H_{fcast} = 0, 1, 3, 6, 9, 12, 18,$ e 24 meses). O desempenho dos modelos foi comparado através do índice de vulnerabilidade. A **Figura 1** ilustra a vulnerabilidade média dos modelos perante os 100 cenários de validação.

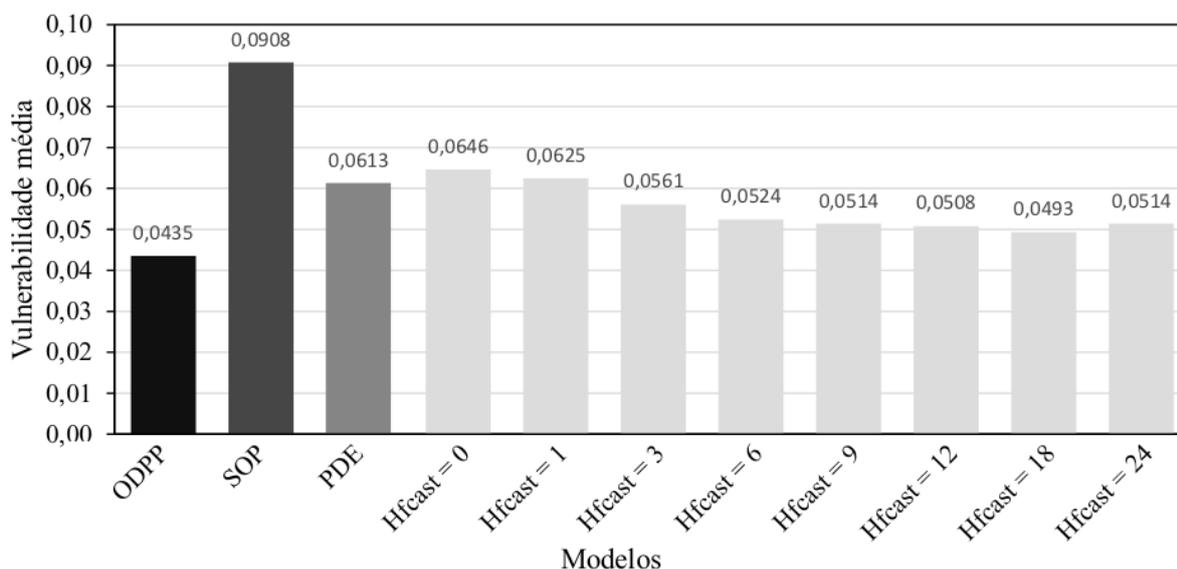


Figura 1. Comparação das vulnerabilidades médias da operação da barragem do rio Poxim para todos os modelos.

Os resultados do modelo ODPP foram utilizados somente como comparativo, visto sua metodologia considera o conhecimento de todo horizonte de operação, desde o início do processo. Trata-se de algo impraticável, mas seus resultados servem como referência para analisar o quanto os demais modelos estão próximos desse modelo idealizado.

As vulnerabilidades mostraram que, com exceção dos horizontes de previsão 0 e 1 meses, que responderam com resultados pouco superiores ao do modelo PDE, todos os demais horizontes do modelo OEI-LTF-kNN obtiveram vulnerabilidades inferiores a este. Porém, entre os horizontes de previsão média, o melhor resultado foi encontrado com $H_{fcast} = 18$ meses, com apenas 13,15% a mais de vulnerabilidade do que modelo ODPP. Por outro lado, o horizonte com maior vulnerabilidade foi com $H_{fcast} = 0$ meses, ou seja, sem previsão de aflúências futuras, com 48,40% a mais que à ODPP.

O modelo SOP prioriza a liberação da demanda, mesmo que isso comprometa os meses seguintes e, assim, o modelo colocou-se em último lugar, com 0,1687 de vulnerabilidade,

108,46% mais vulnerável que o modelo ODPP.

A operação pelo modelo PDE tem como função objetivo minimizar a taxa de vulnerabilidade, mas mesmo assim conseguiu somente a sétima posição da classificação da vulnerabilidade média), com 0,1278 de vulnerabilidade, 40,80% maior que a do modelo ODPP.

Enquanto outros trabalhos (CELESTE & BILLIB, 2012; MOREIRA & CELESTE, 2017; CELESTE & EL-SHAFIE, 2018) buscaram horizontes de previsão que obtivessem as menores vulnerabilidades. Este trabalho encontrou o horizonte de 18 meses como aquele que obteve as menores vulnerabilidades, mas, talvez mais importante que o horizonte ótimo, seja o fato de que com o horizonte de previsão igual a três meses ou mais, este modelo obtém os melhores resultados, comparados com a tradicional política de operação padrão (SOP) e modelos estocásticos explícitos (PDE), além de se aproximar do modelo determinístico (ODPP).

CONCLUSÕES

1. A OEI-LTF-RNA com $H_{forecast} = 18$ obteve os menores percentuais em relação à ODPP;
2. O modelo OEI-LTF-kNN, atingiu as menores vulnerabilidades em relação a todos outros modelos comparados, em todos os horizontes de previsão a partir dos três meses;
3. O modelo SOP apresentou as maiores vulnerabilidades entre todos modelos;
4. A PDE possui uma metodologia complexa e seus resultados neste trabalho mostraram que modelo mais simples e possivelmente de maior aceitabilidade, como o caso da OEI-LTF-kNN pode ser excelente alternativa na escolha do modelo adotado pelos gestores.

AGRADECIMENTOS

Os autores agradecem à Fundação de Apoio à Pesquisa e à Inovação Tecnológica do Estado de Sergipe (FAPITEC/SE) pelo apoio financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMAD, A.; EL-SHAFIE, A.; Razali, S.F.M. & Mohamad, Z.S., Reservoir optimization in water resources: a review. *Water Resour Manag*, 28:3391–3405, 2014.

CELESTE, A.B. & BILLIB, M. Improving implicit stochastic reservoir optimization models with long-term mean inflow forecast. *Water Resour Manag*, 26:2443–2451, 2012.

CELESTE, A.B. & EL-SHAFIE, A. Assessment of stochastic operation optimization for reservoirs of contrasting scales. *Water Resour Manag*, 32:1-13, 2018.

EFSTRATIADIS, A.; DIALYNAS, Y.G.; KOZANIS, S. & KOUTSOYIANNIS, D. A multivariate stochastic model for the generation of synthetic time series at multiple time scales reproducing long-term persistence. *Environmental Modelling & Software*, Elsevier BV, 62:139–152, 2014.

FUENTES, O. & SOLORIO, T. An optimization algorithm based on active and instance-based learning. In: MONROY, R. et al. (Ed.). *MICAI: Advances in Artificial Intelligence*. Berlin, Heidelberg: Springer, 2972:242–251, 2004.

HAROU, J.J.; PULIDO-VELAZQUEZ, M.; ROSENBERG, D.E.; MEDELLÍN-AZUARA, J.; LUND, J.R. & HOWITT, R.E. Hydro-economic models: Concepts, design, applications, and future prospects. *Journal of Hydrology*, Elsevier BV, 375:627–643, 2009.

LABADIE, J.W. Optimal operation of multireservoir systems: State-of-the-art review. *J Water Resour Plan Manag*, 30:93–111, 2004.

MOREIRA, R.M. de S. & CELESTE, A.B. Performance evaluation of implicit stochastic reservoir operation optimization supported by long-term mean inflow forecast. *Stoch Environ Res Risk Assess*, Springer Nature, 31:2357–2364, 2017.

ROCHA, R.M.; LUCAS, A.A.T.; ALMEIDA, C.A.P. de; MENEZES NETO, E.L. & AGUIAR NETTO, A. de O. Caracterização morfométrica da sub-bacia do rio Poxim-Açu, Sergipe, Brasil. *Ambiente e Água - An Interdisciplinary Journal of Applied Science*, 9:276–287, 2014.