



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE DESENVOLVIMENTO SUSTENTÁVEL DO SEMIÁRIDO  
UNIDADE ACADÊMICA DE TECNOLOGIA DO DESENVOLVIMENTO  
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO E REGULAÇÃO DE  
RECURSOS HÍDRICOS**

**ANTONIO RONDINELLY DA SILVA PINHEIRO**

**OPERAÇÃO DE RESERVATÓRIOS USANDO OTIMIZAÇÃO DE  
MONTE CARLO E FLORESTA ALEATÓRIA**

**SUMÉ - PB**

**2023**

**ANTONIO RONDINELLY DA SILVA PINHEIRO**

**OPERAÇÃO DE RESERVATÓRIOS USANDO OTIMIZAÇÃO DE  
MONTE CARLO E FLORESTA ALEATÓRIA**

**Dissertação apresentada Programa de Pós-Graduação em Gestão e Regulação de Recursos Hídricos, no Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Mestre em Gestão e Regulação de Recursos Hídricos.**

**Área de Concentração: Regulação e Governança de Recursos Hídricos.**

**Linha de Pesquisa: Planejamento e Gestão de Recursos Hídricos.**

**Orientador: Professor Dr. Camilo Allyson Simões de Farias.**

**Coorientador: Professor Dr. Celso Augusto Guimarães Santos.**

**SUMÉ - PB**

**2023**



P654o Pinheiro, Antonio Rondinelly da Silva.  
Operação de reservatórios usando Otimização de Monte Carlo e Floresta Aleatória. / Antonio Rondinelly da Silva Pinheiro. - 2023.

67 f.

Orientador: Professor Dr. Camilo Allyson Simões de Farias; Coorientador: Professor Dr. Celso Augusto Guimarães Santos.

Dissertação de Mestrado - Universidade Federal de Campina Grande; Centro de Desenvolvimento Sustentável do Semiárido; Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos - PROFÁGUA.

1. Operação de reservatórios. 2. Otimização de Monte Carlo. 3. Floresta Aleatória. 4. Árvores de decisão. 5. Política de operação de reservatório. 6. Otimização estocástica implícita. 7. Gestão de recursos hídricos. 8. Reservatório Epitácio Pessoa. I. Farias, Camilo Allyson Simões de. II. Santos, Celso Augusto Guimarães. III. Título.

CDU: 628.1(043.2)

**ANTONIO RONDINELLY DA SILVA PINHEIRO**

**OPERAÇÃO DE RESERVATÓRIOS USANDO OTIMIZAÇÃO DE  
MONTE CARLO E FLORESTA ALEATÓRIA**

Dissertação apresentada Programa de Pós-Graduação em Gestão e Regulação de Recursos Hídricos, no Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Mestre em Gestão e Regulação de Recursos Hídricos.

**BANCA EXAMINADORA:**

---

**Professor Dr. Camilo Allyson Simões de Farias**  
Orientador – CCTA/UFCG

---

**Professor Dr. Celso Augusto Guimarães Santos.**  
Coorientador – UFPB

---

**Professor Dr. Cícero Fellipe Diniz de Santana.**  
Examinador Externo – CCTA/UFCG

---

**Professor Dr. Paulo da Costa Medeiros.**  
Examinador Interno – UATEC/CDSA/UFCG

**Trabalho aprovado em: 16 de março de 2023.**

**SUMÉ – PB**

Dedico este trabalho à toda minha família,  
aos meus amigos e a todos que já foram  
meus professores.

## AGRADECIMENTOS

Aos meus pais, Francisca Elisângela e Francisco Pinheiro, pelo imensurável apoio ao longo de toda minha vida. Obrigado por acreditarem na minha capacidade e por orgulharem-se do filho que sou.

Aos meus avós maternos Maria Jácome (*in memoriam*) e José Francisco por toda ajuda e ensinamentos durante a minha vida.

Ao meu amigo, Wamon Salomão, pela amizade desenvolvida desde a época da graduação. Obrigado por todo o incentivo durante a pesquisa.

Ao meu orientador, Camilo Allyson Simões de Farias, por transmitir conhecimentos e me orientar de forma magistral, sempre com atenção, confiança e incentivo, contribuindo imensamente para minha formação acadêmica e profissional.

Ao meu coorientador, Celso Augusto Guimarães Santos, pelas contribuições substanciais propostas ao trabalho.

Aos professores, Cícero Fellipe Diniz de Santana e Paulo da Costa Medeiros, por contribuírem de forma relevante para com este trabalho.

Ao coordenador local do programa, Hugo Morais de Alcântara, sempre disponível, prezando para que os discentes usufríssem da melhor experiência enquanto alunos de um programa de mestrado.

A todos os professores que fazem parte do ProfÁgua na Universidade Federal de Campina Grande - UFCG.

A todos os colegas do curso, que tornaram esta experiência mais rica, sempre gerando debates sobre a água durante as aulas.

A todos que já foram meus professores, pelas importantes contribuições para minha formação pessoal e acadêmica.

Ao apoio para realização deste trabalho por meio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Ao Programa de Pós-Graduação em Rede Nacional em Gestão e Regulação de Recursos Hídricos - ProfÁgua, em nível de Mestrado, na Categoria Profissional, Projeto CAPES/ANA AUXPE N°. 2717/2015, pelo apoio técnico científico aportado até o momento.

“Você fica sabendo muito sobre um país pelo  
jeito como este administra a água.”

Eng. Shimon Tal

## RESUMO

Os sistemas hídricos são susceptíveis a diversos problemas associados ao excesso e à escassez de água. O uso de regras práticas de operação para o gerenciamento adequado dos recursos hídricos surge como alternativa para mitigar tais dificuldades. No presente trabalho, aplicou-se uma regra de proteção baseada em Otimização de Monte Carlo e Floresta Aleatória (OMC-FA) para operação mensal de reservatórios. Para obtenção da regra, foram seguidas as seguintes etapas: (1) geração de vazões sintéticas pelo Método dos Fragmentos; (2) aplicação de um modelo determinístico (DET) para otimização a operação do sistema, minimizando a vulnerabilidade; e (3) associação das alocações e disponibilidades hídricas ótimas para gerar a regra OMC-FA. Para fins de validação, a metodologia foi aplicada ao reservatório Epitácio Pessoa, localizado na Bacia Hidrográfica do Rio Paraíba, Brasil. A regra gerada foi avaliada considerando séries independentes de vazões. O modelo OMC-FA mostrou-se promissor, definindo um comportamento de alocações semelhante ao produzido pelo modelo DET sob previsão perfeita das vazões. A regra OMC-FA também se mostrou prática, necessitando apenas da disponibilidade hídrica no mês corrente para determinar a alocação.

**Palavras-chave:** Árvores de Decisão; Política de Operação; Otimização Estocástica Implícita; Semiárido; Gestão de Recursos Hídricos.



PINHEIRO, Antonio Rondinely da Silva. **Reservoir Operation Using Monte Carlo Optimization and Random Forest**. 2023. 67f. Master Thesis (Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos) - Centro de Desenvolvimento Sustentável do Semiárido, Universidade Federal de Campina Grande – Campus de Sumé – Paraíba, Brazil, 2023.

## **ABSTRACT**

Water systems are susceptible to a variety of challenges, such as problems associated with water excess and scarcity. The use of practical operation rules for proper water resources management emerges as an alternative to mitigate such difficulties. In this study, a protection rule based on Monte Carlo Optimization with Random Forest (MCO-RF) was applied for the monthly operation of reservoirs. To obtain the rule, the following steps were followed: (1) generation of synthetic inflows by the Fragment Method; (2) application of a deterministic model (DET) to optimize the system operation, minimizing its vulnerability; and (3) association of the optimal water allocations and availabilities to generate the MCO-RF rule. We validated the methodology by applying the procedure to the Eptácio Pessoa reservoir in Brazil. The generated rule was evaluated by using independent inflow series. The MCO-RF model proved to be promising, defining an allocation behavior similar to that produced by the DET model under perfect inflow prediction. The MCO-RF rule is also practical, requiring only the current month's water availability to determine the allocation.

**Keywords:** Decision Trees; Reservoir Operating Policies; Implicit Stochastic Optimization; Semiarid. Water Resources Management.

## LISTA DE FIGURAS

Figura 1 - Política de Operação Padrão .....	22
Figura 2 - Árvore de decisão genérica .....	26
Figura 3 – Estrutura genérica de floresta aleatória para classificação .....	29
Figura 4 - Fluxograma metodológico .....	32
Figura 5 - Modelo de previsão da Floresta Aleatória.....	37
Figura 6 - Localização do Epitácio Pessoa .....	39
Figura 7 - Comparação entre as propriedades estatísticas mensais.....	45
Figura 8 - Vulnerabilidade média mensal para os modelos aplicados no reservatório Epitácio Pessoa.....	46
Figura 9 - Vulnerabilidades.....	47
Figura 10 - Volume do reservatório na Simulação nº 74 .....	49
Figura 11 - Alocação de água na Simulação nº 74 .....	49
Figura 12 - Volume do reservatório na Simulação nº 98 .....	50
Figura 13 - Alocação de água na Simulação nº 98 .....	51
Figura 14 - Volume do reservatório na Simulação nº 21 .....	52
Figura 15 - Alocação de água na Simulação nº 21 .....	53
Figura 16 - Volume do reservatório na Simulação nº 63 .....	54
Figura 17 - Alocação de água na Simulação nº 63 .....	55

## LISTA DE TABELAS

Tabela 1 - CAV do Epitácio Pessoa .....	40
Tabela 2 - Lâmina perdida.....	41
Tabela 3 - Demandas mensais para o reservatório.....	42
Tabela 4 - Valores mínimos, médios e máximos de vulnerabilidade mensal para todas as séries de vazões geradas.....	47

## LISTA DE ABREVIATURAS

<b>AESA</b>	Agência Estadual Executiva das Águas do Estado da Paraíba
<b>ANA</b>	Agência Nacional de Águas e Saneamento Básico
<b>CAV</b>	Cota-Área-Volume
<b>CAGEPA</b>	Companhia de Águas e Esgoto da Paraíba
<b>CBH</b>	Comitê de Bacias Hidrográficas
<b>DET</b>	Modelo Determinístico
<b>DNOCS</b>	Departamento Nacional de Obras Contra a Seca
<b>IBGE</b>	Instituto Brasileiro de Geografia e Estatística
<b>FA</b>	Floresta Aleatória
<b>MF</b>	Método dos Fragmentos
<b>NSE</b>	Coefficiente de Eficiência de Nash-Sutcliffe
<b>OEI</b>	Otimização Estocástica Implícita
<b>OMC</b>	Otimização de Monte Carlo
<b>PNRH</b>	Política Nacional de Recursos Hídricos
<b>PERH-PB</b>	Plano Estadual de Recursos Hídricos da Paraíba
<b>POP</b>	Política Operacional Padrão
<b>Sim#</b>	Simulação da Operação de Reservatório Número
<b>SINGREH</b>	Sistema Nacional de Gerenciamento de Recursos Hídricos

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
1.1	OBJETIVOS .....	17
1.1.1	<b>Objetivo Geral</b> .....	<b>17</b>
1.1.2	<b>Objetivos Específicos</b> .....	<b>17</b>
<b>2</b>	<b>REVISÃO DE LITERATURA</b> .....	<b>18</b>
2.1	PANORAMA DOS RECURSOS HÍDRICOS .....	18
2.2	CONFLITOS HÍDRICOS.....	20
2.3	OPERAÇÃO DE RESERVATÓRIOS.....	21
2.3.1	<b>Aspectos Gerais</b> .....	<b>21</b>
2.3.2	<b>Otimização de Monte Carlo</b> .....	<b>23</b>
2.4	FLORESTA ALEATÓRIA.....	24
2.4.1	<b>Árvore de Decisão</b> .....	<b>25</b>
2.4.2	<b>Bagging Trees</b> .....	<b>27</b>
2.4.3	<b>Floresta Aleatória</b> .....	<b>28</b>
<b>3</b>	<b>METODOLOGIA</b> .....	<b>32</b>
3.1	MODELO OMC-FA .....	33
3.1.1	<b>Geração de Vazões Estocásticas</b> .....	<b>33</b>
3.1.2	<b>Modelo Determinístico</b> .....	<b>34</b>
3.1.3	<b>Floresta Aleatória</b> .....	<b>35</b>
3.2	CALIBRAÇÃO DO MODELO OMC-FA .....	36
<b>4</b>	<b>APLICAÇÃO</b> .....	<b>39</b>
4.1	CARACTERIZAÇÃO DA ÁREA DE ESTUDO .....	39
4.2	CARACTERÍSTICAS HIDROLÓGICAS DO RESERVATÓRIO EPITÁCIO PESSOA.....	40
4.2.1	<b>Afluências</b> .....	<b>40</b>
4.2.2	<b>Cota-Área-Volume</b> .....	<b>40</b>
4.2.3	<b>Evaporação e Precipitação</b> .....	<b>41</b>
4.2.4	<b>Usuários do Sistema</b> .....	<b>42</b>
4.3	COMPARAÇÃO ENTRE MODELOS DE OPERAÇÃO .....	42
<b>5</b>	<b>RESULTADOS</b> .....	<b>44</b>
5.1	CALIBRAÇÃO DO MODELO OMC-FA .....	44

5.2	VALIDAÇÃO DO MODELO OMC-FA.....	46
5.3	CENÁRIOS DE VALIDAÇÃO .....	48
5.3.1	<b>Cenário 1</b> .....	<b>48</b>
5.3.2	<b>Cenário 2</b> .....	<b>50</b>
5.3.3	<b>Cenário 3</b> .....	<b>52</b>
5.3.4	<b>Cenário 4</b> .....	<b>54</b>
6	<b>CONCLUSÕES</b> .....	<b>56</b>
	<b>REFERÊNCIAS</b> .....	<b>57</b>
	<b>APÊNDICE A – VULNERABILIDADE MENSAL</b> .....	<b>66</b>

## 1 INTRODUÇÃO

A água é o principal recurso natural presente no planeta Terra, possuindo um papel chave para o desenvolvimento, manutenção de ecossistemas e da sociedade (MISHRA et al., 2021; YANG; YANG; XIA, 2021).

A escassez hídrica impacta a vida de milhões de pessoas ao redor do mundo e impõe dificuldades para o desenvolvimento sustentável da sociedade (MISHRA et al., 2021). As principais causas da escassez hídrica são o aumento populacional, as rápidas mudanças de consumo e a expansão da agricultura, aumentando a demanda por água e pressionando os sistemas hídricos (VÖRÖSMARTY et al., 2000; MEKONNEN; HOEKSTRA, 2016; DOSDOGRU et al., 2020; YANG; YANG XIA, 2021).

Segundo Mekonnen e Hoekstra (2016), estima-se que meio bilhão de pessoas vivem em situação permanente de extrema escassez hídrica e que quatro bilhões enfrentam a escassez de água em pelo menos um dos meses do ano.

Entre 2012 e 2017, por exemplo, a Região Nordeste do Brasil enfrentou um período de seca que afetou drasticamente a população, chegando a causar o colapso no abastecimento público em grandes cidades do semiárido, como é o caso de Campina Grande na Paraíba (BEZERRA; VIEIRA; RIBEIRO, 2021; JACOBI; BUCKERIDGE; RIBEIRO, 2021).

Regiões semiáridas possuem características hidroclimáticas como altas taxas de evaporação, baixa pluviosidade e vastas áreas com baixa capacidade de armazenamento subterrâneo devido aos tipos de solo e à geologia local, fazendo do armazenamento superficial uma das principais formas de se obter água (RIBEIRO NETO et al., 2022).

Os problemas causados pela seca, conflitos prévios relacionados a água e a oportunidade de aumentar os benefícios estimulam estudos para a gestão eficiente de sistemas hídricos (LOUCKS; BEEK, 2017).

As regras de alocação água são estratégias importantes para a gestão de recursos hídricos. Esta estratégia de gestão padroniza e busca suprir com razoabilidade a demanda de água, com o objetivo de administrar o volume disponível no sistema e garantir os usos múltiplos dos recursos hídricos. Com as regras, existe um ajuste dinâmico na alocação de acordo com o volume disponível e a demanda de água, tornando-as um método chave para a resolução de conflitos entre oferta e

demanda de água (MA et al., 2023).

No Brasil, o marco regulatório hídrico vigente é a Lei Federal nº 9.433, de 08 de janeiro de 1977, que instituiu a Política Nacional de Recursos Hídricos. Uma das premissas desta legislação é a de que a gestão de recursos hídricos deve sempre proporcionar o uso múltiplo das águas, exceto em situações de escassez. Este pressuposto converge diretamente para a alocação estratégica, apesar desta não ser um dos instrumentos formalmente instituídos pela legislação (BRASIL, 1997).

Existem diversas formas de se obter a alocação de água operando um sistema hídrico de reservatórios. Uma das mais simples e utilizadas é a Política de Operação Padrão (POP), do inglês *Standard Operation Policy*, que possui como premissa básica atender ao máximo à demanda hídrica. Em regiões que sofrem com estresses hídricos, a POP pode tornar o sistema frágil e susceptível a colapsos (MAAS et al., 1962; DRAPER; LUND, 2004; LOUCKS; BEEK, 2017).

Outra metodologia utilizada para mitigar os problemas causados pela escassez hídrica e gerar regras de operação para a alocação de água é a Otimização Estocástica Implícita (OEI), ou Otimização de Monte Carlo (OMC). A OMC consiste na otimização da operação do reservatório a partir de diferentes cenários de vazão e na definição de regras de operação através de modelos estatísticos, como os de regressão, usualmente relacionando alocações ótimas com volumes disponíveis (YOUNG JUNIOR, 1967; WILLIS; FINNEY; CHU, 1984; CARNEIRO; FARIAS, 2013; SULIS, 2018; GUARISO; SANGIORGIO, 2020; SHAIK; PATTANAYEK, 2022).

Os modelos estatísticos de Floresta Aleatória (FA) são utilizados para resolução de problemas de regressão ou classificação, sendo conceituados como aprendizado de máquina. Os modelos FA têm como princípio a criação de uma série de subconjuntos de dados para uso em árvores de decisão, introduzindo amostras aleatórias e relacionando dados de entrada e saída (BREIMAN, 2001).

Já existe na literatura científica aplicações de FA para análise de salinidade em rios (MELESSE et al., 2020), controle de inundações (DESAI; OUARDA, 2021), previsão de vazão, precipitação e nível de água subterrânea (HONG et al., 2021; ALI et al., 2020; LIU et al., 2022).

Apesar das citadas aplicações, o uso de Floresta Aleatória na área hidrológica ainda é considerado incipiente (DESAI; OUARDA, 2021). Do mesmo modo, aplicações para operação de reservatórios em regiões semiáridas utilizando a



simulação Monte Carlo são escassas na literatura (PINHEIRO; FARIAS; SANTOS, 2023).

Neste trabalho, propôs-se um método baseado em OMC e FA para geração de regras operacionais de reservatórios. Este estudo focou na geração de dados ótimos por meio de OMC para calibração de modelo de FA. Posteriormente, a metodologia OMC-FA foi aplicada a um reservatório do semiárido para determinação de alocações, tendo os seus resultados comparados com o desempenho de modelos tradicionais.

O presente estudo contribui com os Objetivos do Desenvolvimento Sustentável nº 6 (Água Potável e Saneamento), nº 11 (Cidades e Comunidades Sustentáveis) e nº 12 (Consumo e Produção Sustentáveis) da Organização das Nações Unidas, além de apoiar indiretamente outros objetivos e metas da Agenda 2030 (ONU, 2015).

## 1.1 OBJETIVOS

### 1.1.1 Geral

Desenvolver um modelo de operação mensal de reservatórios baseado em Otimização Monte Carlo (OMC) e Floresta Aleatória (FA).

### 1.1.2 Específicos

- a) Propor uma metodologia baseada no método Monte Carlo e em Floresta Aleatória de regressão para definir alocações otimizadas de água em função do volume hídrico disponível;
- b) Avaliar a aplicação do modelo em um reservatório de água localizado no semiárido, com registros históricos de déficits hídricos;
- c) Comparar os resultados gerados pelo modelo proposto com aqueles obtidos da aplicação da Política Operacional Padrão.

## 2 REVISÃO DE LITERATURA

### 2.1 PANORAMA DOS RECURSOS HÍDRICOS

No Brasil, o principal marco regulatório dos recursos hídricos é a Lei nº 9.433 de 8 de janeiro de 1997, que instituiu a Política Nacional de Recursos Hídricos. Esta legislação baseia-se em seis fundamentos, dentre os quais destacam-se: (a) a água é um bem de domínio público ou, em outras palavras, a água está sob responsabilidade do poder público; (b) a gestão hídrica deve prezar pelo uso múltiplo das águas; (c) em situações de escassez, serão prioritários os usos para abastecimento humano e dessedentação animal; e (d) a gestão deve ser descentralizada, abarcando o poder público, os usuários diretos e a população civil (BRASIL, 1997).

Tratando-se de governança das águas, a gestão é dependente dos contextos sociais, culturais, ambientais, econômicos e políticos inerentes ao território (RIBEIRO; JHONSSON, 2018). A população brasileira vem há um longo tempo lutando para reduzir os impactos causados pelas secas (CAMPOS, 2015). A crise hídrica decorre, principalmente, de falhas de governança da água (OCDE, 2015).

A escassez hídrica é um problema humanitário, que causa sérios problemas como desabastecimento de água e impacta em todas as áreas da sociedade. No Brasil, a Região Nordeste é a mais susceptível a ocorrência de crises de água. Entretanto, eventos recentes demonstraram a devastação de uma crise hídrica em outras localidades, como nos casos de escassez observados na Região Sudeste – quando o principal manancial da região reduziu-se a níveis alarmantes em 2015 – e no Centro-Oeste brasileiro, com o Distrito Federal tendo de enfrentar rodízios no abastecimento de água de até 48 horas em 2017 (SOARES NETO; PEDROSA, 2018).

A Região Nordeste é, historicamente, a mais afetada por crises hídricas no Brasil. Com a maior parte do seu território na zona semiárida, vários estados do Nordeste (e.g., Bahia, Ceará, Paraíba, Pernambuco, Piauí e Rio Grande do Norte) sofrem com secas prolongadas. O semiárido nordestino e a insegurança hídrica se relacionam de maneira bem específica. Este espaço é caracterizado pelo domínio de solos jovens, elevado índice de aridez, estação chuvosa delimitada em curto espaço de tempo ao longo do ano e presença numerosa de rios intermitentes (PINHEIRO et

al., 2022).

Devido à elevada insegurança hídrica da região semiárida, o Departamento Nacional de Obras Contra a Seca (DNOCS) implantou, a partir do início do Século XX, a cultura de construção de açudes, tornando este método o mais tradicional para armazenamento de água para usos futuros em locais com baixa pluviosidade (AZEVEDO et al., 2017; GRAFTON et al., 2013).

As regras de alocação água são estratégias utilizadas para gestão dos reservatórios, buscando atender aos seus múltiplos usos. A alocação somente pode ser considerada justa se em seu trâmite foi capaz de atender ao fundamento de múltiplos usos, baseando-se no conhecimento e cadastramento dos usuários e na adoção de princípios de usos sustentáveis, de eficiência econômica e equidade social (ARAÚJO; RIBEIRO; BRAGA, 2019).

Segundo Vieira (1998), em regiões como o semiárido nordestino, é necessária a adoção de medidas que visem a racionalização e a otimização da gestão de águas. Os modelos de simulação e otimização da gestão dos recursos hídricos surgem para simplificar os processos reais, minimizando falhas e maximizando os benefícios (SILVA, 2017).

No planejamento da alocação negociada de águas, os problemas hidrológicos do reservatório devem estar bem definidos, além de conter os estudos e estados hidrológicos, garantir a gestão participativa dos atores sociais interessados e atender às normativas, preservando, assim, a operação, manutenção e monitoramento do reservatório (ANA, 2015).

Diversos estudos propõem metodologias para o processo de alocação negociada de água, através de melhorias nas estratégias para a geração curvas de regras para a operação de reservatórios (ANA, 2015; GOMES, 2022; PINHEIRO, FARIAS; SANTOS, 2023).

Através do processo de alocação de águas, as tomadas de decisão concedem transparência ao ajuste das outorgas vigentes, possibilitando a minimização dos conflitos hídricos existentes com a adequação da disponibilidade hídrica à demanda (CURI et al., 2011; ALMEIDA; CURI, 2016).

## 2.2 CONFLITOS HÍDRICOS

Os conflitos por recursos hídricos advêm da escassez de água, partindo do pressuposto de que se a demanda é totalmente satisfeita não existem conflitos acerca da alocação desses recursos. Para gerir os conflitos é necessário entender com clareza a natureza das disputas em questão (PEDROSA, 2017).

Pedrosa (2017) utiliza-se do caso da Bacia Hidrográfica do Rio São Francisco para exemplificar o quão complexa pode ser o gerenciamento de conflitos para a gestão de águas. O rio atravessa vários estados brasileiros, tendo múltiplos usos (saneamento, irrigação, indústria, mineração, geração de energia, turismo, pesca, piscicultura, transposição de águas e outros), onde boa parte da bacia está inserida no semiárido, com regime de pluviosidade de até 800 mm/ano, sendo assim, necessária a gestão integrada das águas superficiais, subterrâneas e costeiras.

Casos como o do rio São Francisco, fazem com que seja necessário todo um esforço dos entes que envolvem o Sistema Nacional de Gerenciamento de Recursos Hídricos – SINGREH para que a gestão hídrica atenda a todos atores, além de uma operação eficiente de todos os reservatórios ao longo de seu curso (PEDROSA, 2017).

No Brasil, os comitês de bacia são os responsáveis por arbitrar e deliberar em primeira instância os conflitos hídricos existentes sob seu território (BRASIL, 1997). É inevitável a ocorrência de conflitos dentro da gestão hídrica e tais situações podem gerar discussões necessárias para o encontro de soluções (AMORIM; RIBEIRO; BRAGA, 2016).

Dados da Comissão Pastoral da Terra, que realiza desde 2009 um trabalho para registro de conflitos por água em todo o país, indicam que a Região Nordeste é a segunda mais conflituosa, sendo o impedimento e a redução do acesso às águas as principais causas nos estados da Bahia, Ceará e Paraíba (PEIXOTO; SOARES; RIBEIRO, 2021).

Tais impedimentos são causados, principalmente, pela escassez hídrica que reduz a quantidade de água disponível nos rios e reservatórios, cabendo aos entes da gestão à implementação de estratégias para mitigar ou até evitar os efeitos (BASTO; FONTES; MEDEIROS, 2020).

Uma das estratégias possíveis para a mitigação dos efeitos ocasionados decorrentes da escassez de água é a otimização da operação de reservatórios, um método que eleva a segurança hídrica, alocando – de forma racional e conforme prioridades e regras pré-definidas – a água disponível no reservatório (NUNES; GALVÃO; RÊGO, 2016; MORAIS; MAIA, 2021; BILLERBECK; MELLO JUNIOR, 2018; BASTO; FONTES; MEDEIROS, 2020).

## 2.3 OPERAÇÃO DE RESERVATÓRIOS


### 2.3.1 Aspectos Gerais

Os reservatórios são construções estratégicas com o objetivo de reduzir impactos de possíveis variabilidades hídricas e garantir abastecimento de água, através da regulação de vazão, garantindo uma fonte de água de longa duração para atendimento das necessidades humanas e ambientais (EHSANI et al., 2017; DRAPER; LUND, 2004).

Labadie (2004) afirma que o surgimento de novos usos em reservatórios, não previstos em projeto, aumenta a propensão ao colapso do sistema hídrico, não atendimento das demandas. Raje e Mujumdar (2010) corroboram ao afirmar que muitos reservatórios estão sob estresse hídrico, causado por crescimento populacional, demanda incompatível com a rede hidrológica e falhas na gestão dos recursos.

A Política de Operação Padrão (POP) é uma das regras mais simples, sendo comumente utilizada para operar reservatórios (MORAIS; MAIA, 2021). Este modelo baseia-se na política de alocação da máxima quantidade de água possível para atendimento da demanda. Tal direcionamento pode levar o reservatório ao colapso em um curto período de tempo, causando escassez hídrica (LOUCKS; BEEK, 2017; MORAIS; MAIA, 2021; PINHEIRO; FARIAS; SANTOS, 2023). Na Figura 1, observa-se o funcionamento da POP, em que a linha vermelha representa a POP sendo aplicada.

Figura 1 - Política de Operação Padrão



Fonte: Adaptada de Loucks e Beek (2017).

Na literatura, é constante a procura pela operação do reservatório através de algoritmos de otimização, na busca pelas melhores estratégias de operação que visem a praticidade e a diminuição de falhas na gestão dos recursos hídricos (AHMAD et al., 2014).

A principal tarefa na operação é decidir a quantidade de água que deve ser alocada agora e o quanto deve ser racionalizado para usos futuros, dado a situação atual do reservatório e a previsão de dados futuros, normalmente por meio de curvas chave, que indicam as ações a serem tomadas de acordo com o estado hidrológico (WURBS, 1993; CELESTE; BILLIB, 2009).

Um reservatório de usos múltiplos apresenta uma maior complexidade na operação, envolvendo muitas variáveis e objetivos, e considerando o risco e a incerteza (OLIVEIRA; LOUCKS, 1997; TU; HSU; YEH, 2003; LABADIE, 2004). Necessitando, assim, de um modelo de otimização da operação.

Um dos procedimentos utilizados para otimização é a Otimização de Monte Carlo, que gera regras operacionais a partir da aplicação de uma função determinística (CELESTE; BILLIB, 2009).

OMC pode ser utilizada para geração de regras mensais, como nos trabalhos de Carneiro e Farias (2013) e Tegegne e Kim (2020), bem como geração de curvas chave para estados hídricos de um reservatório, como em Santos e Celeste (2016).

### 2.3.2 Otimização de Monte Carlo

Uma das grandes dificuldades da operação de reservatórios é a incerteza hidrológica. A incerteza hidrológica impacta diretamente a aplicação dos modelos tradicionais de operação de reservatórios, que consideram apenas o volume disponível para alocar os recursos hídricos. Uma das soluções para operar um reservatório é o desenvolvimento de regras operacionais (GOMES, 2022).

Uma das formas mais utilizadas para gerar regras operacionais considerando a incerteza hidrológica é a Otimização usando Simulação Monte Carlo (OMC). A utilização de OMC favorece a criação dessas regras operacionais em relação à representação matemática do sistema físico do reservatório, sendo de fácil aplicação (MIZYED; LOFTINS; FONTANE, 1992).

A OMC funciona a partir da aplicação de um modelo ótimo (otimização determinística) para operação do reservatório sob diversos cenários de disponibilidade hídrica igualmente prováveis e analisa os dados operacionais ótimos para criar as curvas de regra (CELESTE; BILLIB, 2009).

Séries de dados de vazão são obtidas a partir de modelos de geração de vazões sintéticas para aplicação na otimização determinística. Segundo Farias (2009), estas vazões sintéticas devem possuir os mesmos padrões estatísticos da série histórica original. Para cada cenário gerado é obtido um conjunto de informações operacionais ótimas diferentes. As alocações ótimas são geralmente agrupadas e então relacionadas com a disponibilidade hídrica por meio de regressão linear (MIZYED; LOFTINS; FONTANE, 1992; CELESTE; BILLIB, 2009; CELESTE; EL-SHAFIE, 2018).

O uso de modelos estocásticos como a Otimização de Monte Carlo torna-se uma solução viável para o problema das incertezas hidrológicas, dando suporte racional às decisões sobre liberações de água (CELESTE; EL-SHAFIE, 2018).

Young Junior (1967) realizou, por meio de programação dinâmica, a primeira aplicação da OEI para gerar uma regra anual de operação. No Brasil, Barreto (1974) realizou uma das primeiras aplicações da OEI e regressão múltipla para criação de regras mensais de operação para o reservatório Três Marias, objetivando maximizar a produção energética.

Outro ponto positivo da utilização de modelos OEI é a sua versatilidade para

incorporar diferentes modelos de geração de regras operacionais, como as Redes Neurais Artificiais (CARNEIRO; FARIAS, 2013), Regressão Não-Linear Múltipla (CELESTE; BILLIB, 2009), Floresta Aleatória (PINHEIRO; FARIAS; SANTOS, 2022), Teoria dos Jogos (GOMES, 2022) e Algoritmos Genéricos (MOMTAHEN; DARIANE, 2007).

## 2.4 FLORESTA ALEATÓRIA

A aprendizagem estatística, utilizando-se de um banco de dados, vem sendo aplicada em diversas áreas, desde a ciência, medicina, economia e indústria. Dentro destas áreas abre-se um leque de opções para o uso de estatísticas, banco de dados e inteligência artificial na resolução dos problemas propostos (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

As técnicas de aplicação da aprendizagem estatística se subdividem entre os algoritmos de aprendizagem: *Random Forest*, Redes Neurais Artificiais, Árvores de Decisão, Máquinas de Suporte de Vetores, *Gradient Boosting*, entre outros. Trabalhos como os de Hastie, Tibshirani e Friedman (2009) e Caruana e Niculescu-Mizil (2006) já vêm testando o potencial de cada categoria destes algoritmos supracitados sob a ótica de diversos parâmetros (tamanho da base de dados, desvio padrão, precisão média, acurácia e outros).

Em seus estudos, Caruana e Niculescu-Mizil (2006) utilizaram algoritmos otimizados através da Escala de Platt, Regressão Isotônica e algoritmos não calibrados. Os resultados destes testes mostraram que os algoritmos de *Gradient Boosting*, Floresta Aleatória e Máquinas de Suporte de Vetores performaram melhor para parâmetros definidos.

Hastie, Tibshirani e Friedman (2009) utilizaram a base de dados de habitação da Califórnia, Estados Unidos da América para comparar os algoritmos Floresta Aleatória e *Gradient Boosting* através do número de árvores de decisão a serem usadas pela média do erro absoluto. Observou-se que a métrica de desempenho durante a calibração tendia a se estabilizar quando a Floresta Aleatória possuía 200 árvores, no *Gradient Boosting*, a estabilização só ocorreu após 1.000 árvores. Destaca-se que, após 600 árvores, o *Gradient Boosting* apresentava desempenho superior ao modelo de Floresta Aleatória.



A Floresta Aleatória com alta eficiência surgiu do aprimoramento do algoritmo de Classificação e Regressão de Árvores e *Bagging Trees* (BREIMAN et al., 1984; BREIMAN, 1996, 2001; YANG et al, 2016).

#### 2.4.1 Árvore de Decisão

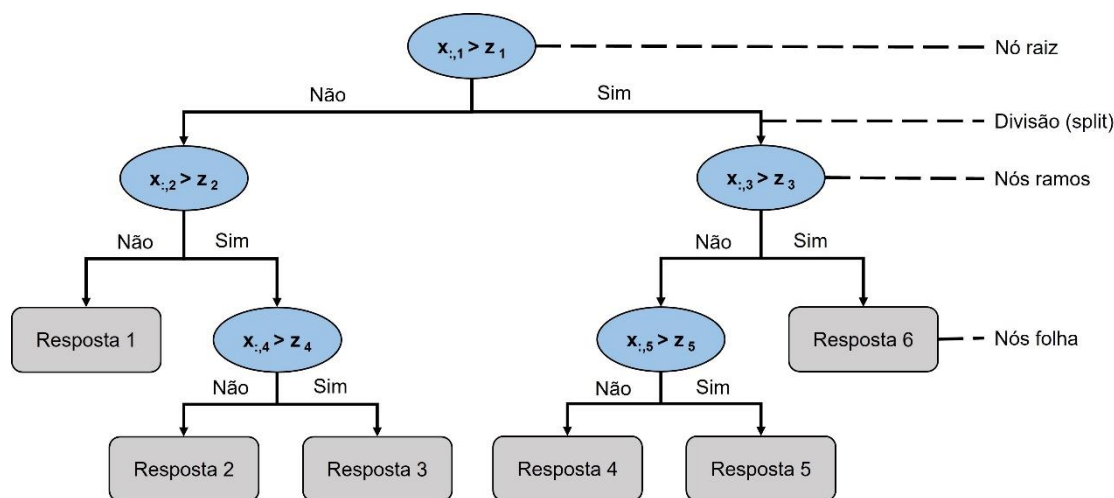
A árvore de decisão é uma das mais simples formas de se obter um algoritmo de aprendizagem. Apesar de sua simplicidade, é um modelo robusto e prático para resolução de problemas multivariados. Isto é obtido por meio da construção de regras de classificação ou regressão para um parâmetro a partir da subdivisão dos dados em um conjunto para análise (GIROLAMO NETO, 2018; SANTANA, 2020).

O topo de uma árvore de decisão é definido como nó raiz, que contém todo o conjunto de dados. O passo seguinte é a escolha dos melhores atributos para fazer a separação dos dados em dois nós ramos, cada ramo possuindo um teste conforme os atributos selecionados, repetindo-se este passo até que um critério de parada estabelecido seja atingido (GIROLAMO NETO, 2018; SANTANA, 2022).

Pode-se citar, como exemplos de critérios de parada, o momento em que há o esgotamento das possibilidades de divisão a partir dos parâmetros ou em que um número mínimo de nós folhas (terminais da árvore de decisão) é atingido (SANTANA, 2020).

Assim, compõem uma árvore de decisão o nó raiz (contém todo o conjunto de dados), as divisões (*splits*), os nós ramos e os nós folhas (SANTANA, 2022). Na Figura 2, apresenta-se um exemplo genérico de uma árvore de decisão.

Figura 2 - Árvore de decisão genérica



Fonte: Autoria Própria (2023).

Os melhores parâmetros para a divisão são avaliados conforme a separação dos dados em classes ou em valores esperados, chamada de medida de impureza (GIROLAMO NETO, 2018). Os principais métodos utilizados para a avaliação dos parâmetros são a Entropia e o Índice de Gini (ZHU et al., 2018; YU et al., 2021; SANTANA, 2022).

Uma das principais técnicas para criação de árvores de decisão são as Árvores de Classificação e Regressão (CART, do inglês *Classification and Regression Trees*), proposta por Breiman et al. (1984). O algoritmo CART constrói árvores de decisão binárias, ou seja, cada nó só pode ter no máximo dois ramos, que podem ser utilizadas para resolução de problemas de classificação e/ou regressão (BREIMAN et al., 1984; SANTANA, 2022).

A criação das partições em cada nó para modelos de regressão, na metodologia adotada por Breiman et al. (1984), utiliza-se da minimização do erro quadrático médio (MSE, do inglês *Mean Standard Error*), descrito pela equação a seguir:

$$MSE = \frac{1}{n} \sum_{i=1}^N (y_i - \bar{y})^2 \quad (1)$$

em que  $y_i$  é o valor de referência das amostras,  $\bar{y}$  é a média dos valores de referência e  $n$  é o número de amostras contidas no nó (SANTANA, 2020).

As árvores de decisão possuem como vantagem a facilidade de uso e interpretação. Entretanto, uma única árvore de decisão para um conjunto de dados pode ocasionar uma limitação da observação, diante da estocasticidade dos dados, ocasionando um sobreajuste do modelo (BAUM, 2020).

Como solução para o ajuste demasiado dos dados de treinamento, Breiman (1996) propôs a técnica *bagging*, que se trata da agregação de diversas árvores de decisão para predição.

#### 2.4.2 Bagging Trees

A ideia principal do algoritmo *Bagging Trees*, ou agrupamento de árvores, é corrigir os erros do modelo de predição de uma única árvore de decisão (PRASAD; IVERSON; LIAW, 2006).

Considerando que uma das limitações na árvore de decisão é que o modelo se ajusta demasiadamente ao conjunto de dados (*overfitting*), Breiman (1996) propõe a utilização de *bootstrap* – que significa a retirada de vários subconjuntos do conjunto de dados originários – para criação de uma árvore de decisão para cada subconjunto. Assim, a predição final faz-se a partir da votação da maioria (classificação) ou da média (regressão) dos resultados das árvores de decisão agrupadas. Este procedimento recebe o nome de *bagging* (BAUM, 2020).

No *bootstrap*, cerca de um terço da amostra é retirada do conjunto principal, sendo repostos por dados replicados do próprio banco de dados, estes dados retirados recebem o nome de fora do saco (do inglês, *out of bag* – OOB). Os dois terços restantes, conhecidos como dentro do saco (do inglês, *in bag*) são utilizados para criação de uma árvore de decisão. O processo é repetido até obter-se as  $n$  árvores de decisão pretendidas para o agrupamento de árvores (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; PRASAD; IVERSON; LIAW, 2006; SANTANA, 2020).

Este processo resulta em um conjunto de dados perturbados pelas replicações, fazendo com que o método perca a estrutura simples e de fácil interpretação das árvores de decisão (BREIMAN, 1996). Todavia, o agrupamento de várias árvores com diferentes subconjuntos de dados de um mesmo banco de dados gera uma melhora na acurácia do modelo, diminuindo a propensão ao ajuste demasiado do modelo aos dados de treinamento, potencializando o seu desempenho na predição (BREIMAN,

1996; BAUM, 2020). Buscando melhorar o desempenho com o uso de árvores de decisão, Breiman (2001) aprimorou o *bagging* para um modelo chamado de Floresta Aleatória.

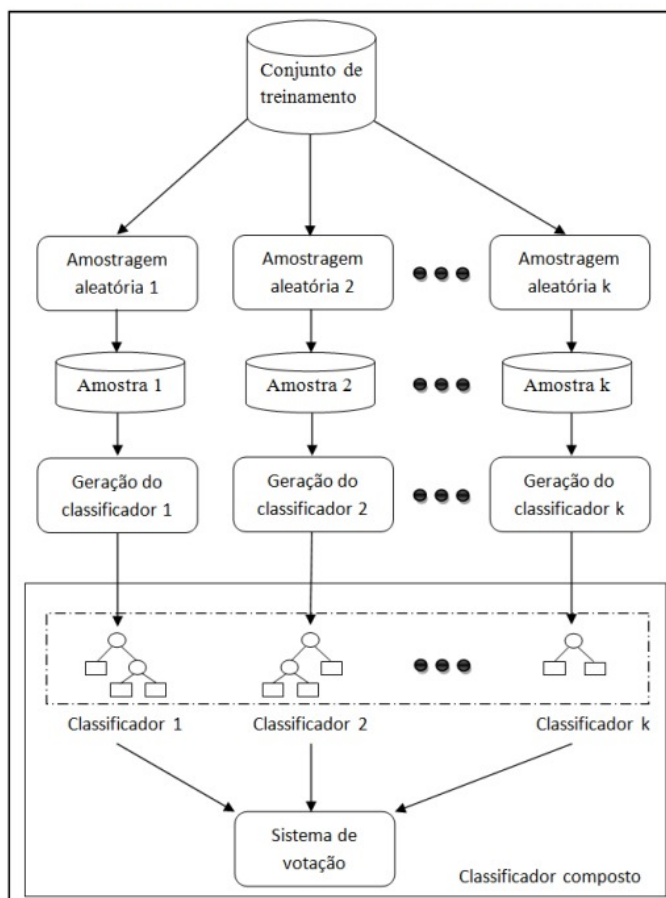
### 2.4.3 Floresta Aleatória

A Floresta Aleatória (do inglês, *Random Forest*) foi criada para solucionar o *overfitting* (ou sobreajuste) associando dois métodos de aleatorização de dados, o *bagging* e a seleção aleatória de variáveis (BREIMAN, 2001; SANTANA, 2020). Breiman (2001) decidiu reunir esses dois métodos após diversos estudos (AMIT; GEMAN, 1997; DIETTERICH, 1998; HO, 1998) mostrarem que a aleatorização das variáveis garante uma melhora na acurácia do modelo e reduz o sobreajuste do modelo aos dados.

Segundo Breiman (2001), a correlação de dados obtidos através de simulações *Random Forest* deriva da implementação de aleatoriedade nos dados por meio dos métodos de ensacamento (*bagging*) e uso da aleatoriedade, que melhora a acurácia do método.

Na Figura 3, apresenta-se um modelo estrutural genérico do algoritmo para classificação de uma floresta aleatória, em que os dados são divididos através de *bootstrap* em subconjuntos de amostragem aleatória, formando novas amostras. Cada amostra gerará uma árvore de classificação, em que o resultado final se dará através de votação por maioria (GIROLAMO NETO, 2018).

Figura 3 – Estrutura genérica de floresta aleatória para classificação



Fonte: Girolamo Neto (2018)

A aleatoriedade produzida através do *bagging* ocorre de maneira igual à descrita anteriormente, através da utilização do *bootstrap*. As amostras fora do saco (OOB) podem ser utilizadas de forma a avaliar a eficiência do modelo, de maneira análoga à validação cruzada de dados (SANTANA, 2020)

A seleção aleatória de variáveis consiste em selecionar aleatoriamente as variáveis que serão utilizadas em cada nó durante a construção das árvores de decisão. Uma amostra  $z$  de variáveis preditoras é escolhida para o espaço das variáveis a partir do banco de dados completo  $p$  de preditores. Para problemas de classificação e regressão, os valores padrões de  $z$  são  $\sqrt{p}$  e  $p/3$ , respectivamente (BREIMAN, 2001; BAUM, 2020; SANTANA, 2020).

Hastie, Tibshirani e Friedman (2009) salientam que o melhor ajuste de  $z$  dependerá do problema a ser resolvido, não sendo obrigatório seguir estes valores padrões, e que estes devem ser tratados como variáveis de aprimoramento do modelo.

Santana (2020) cita outros dois parâmetros de otimização importantes no modelo: número de árvores, que deve ser grande o suficiente para estabilizar o erro das amostras OOB (caso esta seja a escolha para análise de eficiência do modelo); e número padrão mínimo de nós, que na classificação é usualmente um e, na regressão, cinco. Ainda de acordo com o autor, os resultados obtidos com os parâmetros padrões e os otimizados são bastante similares.

O modelo de FA permite lidar com conjuntos de dados com grande número de variáveis preditoras, sendo computacionalmente eficientes, evitando o sobreajuste e possuindo mais acurácia do que seus antecessores (BREIMAN, 2001; SEGAL, 2004; GIROLAMO NETO, 2018).

O uso de modelos de aprendizado de máquina utilizando floresta aleatória vem crescendo, muito pela simplicidade e praticidade do uso destes algoritmos para previsões (SANTANA, 2020).

A difusão de seu uso pode ser observada nos mais diversos campos da literatura. Wolfe et al. (2010), por exemplo, utilizou o algoritmo para criação de uma escala de severidade dos sintomas comuns a fibromialgia, uma doença que afeta a musculatura do corpo humano. A FA contribuiu para mostrar a importância das variáveis, entretanto, não apontou um ponto ótimo para o corte das variáveis, sendo necessário implementar outro método junto ao algoritmo de aleatoriedade.

Na aviação, Gui et al. (2020) aplicaram métodos de aprendizado de máquina em *Big Data* para prever voos atrasados. Dentre os resultados obtidos, o *long short-term memory* (LSTM) obteve excelente desempenho, mas demonstrou problemas devido ao *overfitting* dos dados. A FA contornou este problema e obteve uma acurácia de 90,2%.

A FA também é bastante aplicada no campo do geoprocessamento. Para Belgiu e Drăguț (2016), o uso desta metodologia de aprendizado de máquina tornou-se popular junto ao sensoriamento remoto devido a sua precisão ao lidar com multidimensionalidade. Por outro lado, apresentou defeitos ao lidar com desenho amostral dos dados obtidos em imagens.

Tratando-se de recursos hídricos, as metodologias de aprendizado de máquina vêm sendo bastante utilizadas para a operação de reservatórios. Estudos como o de Draper (2001) e Farias (2009) demonstram a eficácia destas técnicas em relação ao método padrão de operação dos reservatórios. Draper et al. (2004), no entanto,

salienta que os métodos precisam ser práticos, pois muitos modelos de simulação acabam por tornarem-se restritos devido à complexidade imposta pelas suas regras de operação.

Neste sentido, a Floresta Aleatória aparece como alternativa viável para o modelo padrão de operação e como algoritmo de aprendizagem com fácil entendimento de uso.

A utilização da FA é bem recente para a operação de reservatórios, com o estudo de Yang et al. (2016) sendo um dos primeiros a serem publicados. Nesta pesquisa, eles usam o método de classificação e regressão por meio de árvores junto a um método de combinação cruzada embaralhada para definir as regras de operação de reservatórios no estado da Califórnia, Estados Unidos. Os resultados do estudo concluíram que o modelo proposto conseguiu gerar regras de operação adequadas.

Yang et al. (2017) realizou uma comparação entre os métodos Floresta Aleatória, redes neurais artificiais e vetor de suporte a regressão para definir um modelo de operação mensal para dois reservatórios, um na Califórnia e outro na China, observando como regra principal de operação os fenômenos climáticos presentes nas duas localidades. Neste estudo foi possível observar que o modelo que melhor previu a demanda foi o da Floresta Aleatória e que uma de suas vantagens é a possibilidade de interpretação na inserção de dados brutos.

Hong et al. (2021) analisou diversos algoritmos de aprendizado de máquina para prever vazões afluentes a um reservatório de múltiplos usos na Coreia do Sul. Nesta pesquisa o método FA teve o segundo melhor desempenho com *Nash–Sutcliffe efficiency* (NSE) de 0,765, sendo inferior ao modelo LSTM, com NSE de 0,796.

Chen et al. (2018) utilizaram FA para classificar as principais variáveis hidrológicas que influenciam diretamente na afluência do reservatório Três Gargantas, China. Eles obtiveram boas estratégias baseadas em FA para operação do reservatório.

Na gestão dos recursos hídricos, ainda há muito a se explorar com a ferramenta Floresta Aleatória (DESAI; OUARDA, 2021). Uma das lacunas que se observa na literatura é a utilização desta metodologia aliada a uma técnica de operação de reservatórios, o que, de acordo com Pinheiro, Farias e Santos (2023), pode simplificar e potencializar a operação de mananciais.

### 3 METODOLOGIA

O presente trabalho possui abordagem metodológica de pesquisa aplicada, de natureza exploratória e abordagem quantitativa (GIL, 2002). Divide-se em duas etapas: exploratória e aplicada.

A fase exploratória é composta pelo levantamento bibliográfico, enquanto a etapa aplicada consiste na implementação de um método, proposto por este trabalho, para operação de reservatórios e obter dados de operação através desta metodologia.

Para obter a regra de operação, utilizou-se a Otimização de Monte Carlo, que necessita de uma longa série de vazões (em geral, vazões sintéticas) para aplicação de um Modelo Determinístico e obtenção dos dados ótimos. As vazões sintéticas foram geradas pelo Método dos Fragmentos (SVANIDZE, 1980). Após a obtenção das alocações ótimas, conduziu-se a calibração da Floresta Aleatória de regressão e foi possível aplicar de forma prática o método OMC-FA para obtenção das alocações.

Na Figura 4, observa-se o fluxograma metodológico deste trabalho.

Figura 4 - Fluxograma metodológico



Fonte: Autoria Própria (2023).



### 3.1 MODELO OMC-FA

A Otimização de Monte Carlo pressupõe o uso de longas séries de vazões, que podem ser obtidas por modelos que simulam vazões sintéticas. O passo seguinte consiste em usar um Modelo Determinístico (DET) para otimizar a operação do reservatório e obter dados ótimos. Por fim, regras operacionais (alocação em função de volume disponível) podem ser obtidas por meio de simples regressão ou outras técnicas. Neste estudo, o modelo segue os seguintes passos:

- a) Gerar  $M$  meses de vazões sintéticas (estocásticas);
- b) Aplicar um modelo DET para otimizar a operação do reservatório; e
- c) Relacionar as alocações ótimas e a disponibilidade hídrica para geração de uma regra mensal única de operação por meio de FA de regressão.

#### 3.1.1 Geração de Vazões Estocásticas

O modelo OMC-FA de operação de reservatórios necessita que séries de vazões sintéticas sejam geradas, produzindo uma sequência histórica de vazões mensais de entrada que possuam as mesmas características da série histórica. Para este trabalho, as sequências de vazões sintéticas foram concebidas pelo Método dos Fragmentos e utilizadas para operação mensal de reservatórios.

O Método dos Fragmentos (MF) foi proposto primeiramente por Svanidze (1980) e possui uma abordagem relativamente simples para gerar séries históricas sintéticas. A metodologia vem sendo aplicada com grande sucesso em regiões semiáridas e tal sucesso dá-se pela preservação de propriedades estatísticas das séries hidrológicas originárias, como média, desvio padrão, distorção e curtose. Como exemplo do uso do Método dos Fragmentos, pode-se citar os trabalhos de Carneiro e Farias (2013); Silva Filho e Farias (2018); Gomes (2022); Pinheiro, Farias e Santos (2023).

O MF possui como objetivo principal desagregar vazões anuais em vazões mensais, a partir de uma metodologia padronizada (CARNEIRO; FARIAS, 2013). Para calcular um fragmento, é necessário dividir a vazão mensal de um determinado ano pela soma de todas as vazões mensais daquele respectivo ano, ou seja:

$$f(a, m) = \frac{Q(a, m)}{\sum_{m=1}^{12} Q(a, m)} \quad (2)$$

na qual  $f(a, m)$  e  $Q(a, m)$  são, respectivamente, o fragmento do mês  $m$  do ano  $a$  e a vazão observada no mês  $m$  do ano  $a$ .

Após a realização do cálculo dos fragmentos, processa-se os dados através de uma função de densidade de probabilidade (f.d.p.) adequada (CARNEIRO; FARIAS, 2013). Neste estudo, a f.d.p. adotada foi a distribuição gama, já que é bastante utilizada para modelar vazões anuais sem autocorrelação em trabalhos no semiárido (CELESTE; CURI; CURI, 2007; CARNEIRO; FARIAS, 2013; GOMES, 2022). A distribuição gama utilizada seguiu os procedimentos presentes em Bussab e Moretin (2017).

### 3.1.2 Modelo Determinístico

É imprescindível a utilização de um modelo que se equipare à realidade para que as regras operacionais do reservatório sejam adequadas (GOMES, 2022). Para tal, o modelo deve identificar a alocação ideal para os recursos hídricos que satisfaçam as demandas sem que ocorra um comprometimento da operação do sistema (CARNEIRO; FARIAS, 2013).

O modelo DET conhece todo o horizonte de vazões de entrada da operação e estabelece as alocações com base nas características e restrições inerentes ao reservatório.

Para o correto funcionamento deste modelo é necessário a definição de uma função objetivo. No presente trabalho, a otimização terá como função objetivo minimizar a vulnerabilidade média mensal do reservatório, seguindo os critérios estabelecidos por Hashimoto, Stedinger e Loucks (1982).

As equações do modelo DET são representadas por:

$$\min VUL = \sum_{t=1}^M \left[ \frac{R(t) - D(t)}{D(t)} \right]^2 \quad (3)$$

$$V(1) = V_0 + Q(1) - R(1) - S_p(1) + P(1) - E_V(1)$$

$$V(t) = V(t-1) + Q(t) - R(t) - S_p(t) + P(t) - E_V(t); \forall t = 2, \dots, M \quad (4)$$

$$0 \leq R(t) \leq D(t); \forall t \quad (5)$$

$$V_{min} \leq V(t) \leq V_{max}; \forall t \quad (6)$$

$$S_p(t) \geq 0; \forall t \quad (7)$$

A vulnerabilidade mensal do reservatório, descrita pela Equação (3), segundo Hashimoto, Stedinger e Loucks (1982), é a soma dos erros quadráticos entre a alocação e a demanda, em que  $VUL$  é a vulnerabilidade,  $M$  é o horizonte de operações em meses,  $R(t)$  é a alocação de água e  $D(t)$  é a demanda total em um determinado mês  $t$ .

O balanço hídrico da operação é representado pela Equação (4), na qual  $V(t)$  é o volume do reservatório equivalente ao final do mês  $t$ ,  $V_0$  é o volume inicial do reservatório,  $Q(t)$  é a vazão afluente do reservatório durante o mês  $t$ ,  $E_V(t)$  e  $P(t)$  são a evaporação e a precipitação sobre a superfície líquida do reservatório durante o mês  $t$ , respectivamente, e  $S_p(t)$  é o vertimento que pode ocorrer durante o mês  $t$ .

As limitações estruturais do sistema hídrico, segundo Carneiro e Farias (2013), definem as restrições de operação do reservatório para alocação, volume e vertimento. Tais delimitações físicas são descritas pela Equações (5), (6) e (7), em que  $V_{min}$  é o volume mínimo do reservatório, ou volume morto, e  $V_{max}$  é o volume máximo de armazenamento do sistema.

### 3.1.3 Floresta Aleatória

A Otimização de Monte Carlo, como já citado anteriormente, utiliza-se do modelo DET para acessar as alocações ótimas para o sistema hídrico. Com estes resultados é necessário aplicar um modelo estatístico para se obter as regras de operação do reservatório (CELESTE; CURI; CURI, 2009). Tais modelos estatísticos podem ser redes neurais artificiais (FARIAS, 2009), regressões não-lineares múltiplas (CELESTE; CURI; CURI, 2009), regressão não-linear (GOMES, 2022), entre outros.

Neste estudo, aplicou-se o modelo de Floresta Aleatória de regressão, que consiste em realizar regressões múltiplas para obtenção das alocações em função da disponibilidade hídrica, da demanda e do corrente mês, gerando uma única regra de operação para o sistema hídrico (BREIMAN, 2001; PINHEIRO; FARIAS; SANTOS, 2023).

### 3.2 CALIBRAÇÃO DO MODELO OMC-FA

Após a obtenção dos valores otimizados de  $R(t)$  e  $V(t)$ , para  $t = 1, \dots, M$ , procede-se para a calibração da regra de operação OMC-FA, em que a Floresta Aleatória é representada por:

$$h(X) = \frac{1}{K} \sum_{k=1}^K h(x, \theta_k) \quad (8)$$

em que  $K$  é o número de árvores de regressão ( $k = 1, 2, \dots, K$ ),  $x$  é um subconjunto de dados referente à  $X$  (dados de entrada) e de mesmo tamanho,  $\theta$  são variáveis aleatórias independentes e identicamente distribuídas, e  $h(x, \theta_k)$  são as árvores de decisão (BREIMAN, 2001; SEGAL, 2004; ABDA et al., 2022).

O modelo prevê a calibração de Florestas Aleatórias com diferentes quantidades de árvores de decisão (e.g., 25, 50, 75, ..., e 500), para que se encontre, através das métricas de eficiência utilizadas, o arranjo mais adequado para o conjunto de dados. Recomenda-se treinar cada composição no mínimo 10 vezes, para maximizar as chances de encontrar os ótimos globais (PINHEIRO; FARIAS; SANTOS, 2023).

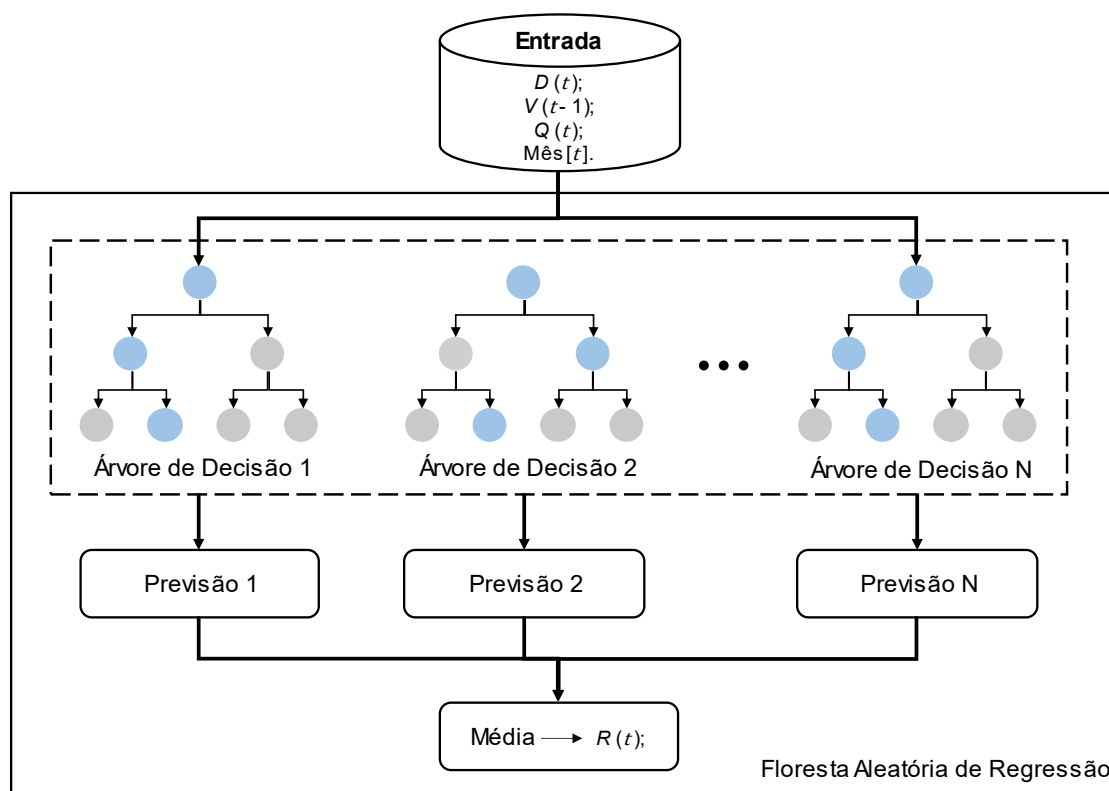
Optou-se por fixar a quantidade mínima de folhas nas árvores de regressão em duas folhas para o modelo OMC-FA, levando em consideração todas as variáveis durante o processo de calibração. Tal configuração faz-se necessário para evitar a perda de informações vitais, como a sazonalidade e a disponibilidade hídrica.

Após a calibração, a regra OMC-FA pode determinar a alocação mensal baseada na demanda, na disponibilidade hídrica do reservatório (representada por volume inicial e vazão atual) e no vetor mês ([1 0 0 0 0 0 0 0 0 0 0] para janeiro, [0

1 0 0 0 0 0 0 0 0 0] para fevereiro, ..., e [0 0 0 0 0 0 0 0 0 0 0 1] para dezembro), que incorpora a sazonalidade local (PINHEIRO; FARIAS; SANTOS, 2023).

Na Figura 5, observa-se um fluxograma sobre o funcionamento do modelo preditivo da Floresta Aleatória para regressão.

Figura 5 - Modelo de previsão da Floresta Aleatória



Fonte: Autoria Própria (2023).

O desempenho da FA foi avaliado por meio do Índice de Eficiência de Nash-Sutcliffe (NSE), proposto por Nash e Sutcliffe (1970) e representado por:

$$NSE = 1 - \frac{\sum_{i=1}^N (R_{obs}^i - R_{sim}^i)^2}{\sum_{i=1}^N (R_{obs}^i - \overline{R_{obs}})^2} \quad (9)$$

em que  $NSE$  é o coeficiente de eficiência,  $R_{obs}^i$  é a alocação observada na amostra  $i$ ,  $R_{sim}^i$  é a alocação simulada através do modelo na amostra  $i$ ,  $\overline{R_{obs}}$  é a alocação média para a série analisada, e  $N$  é o número total de registros de alocação.

Para o modelo também foi analisada a Raiz Quadrada do Erro Médio, do inglês *Root Mean Squared Error* (RMSE). Quanto menor o RMSE, dentre os valores analisados por este modelo, melhor será o resultado, este índice exprime a análise do erro entre os valores observados e as predições. O RMSE é representado por:

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(R_{sim}^i - R_{obs}^i)^2}{N}} \quad (10)$$

## 4 APLICAÇÃO

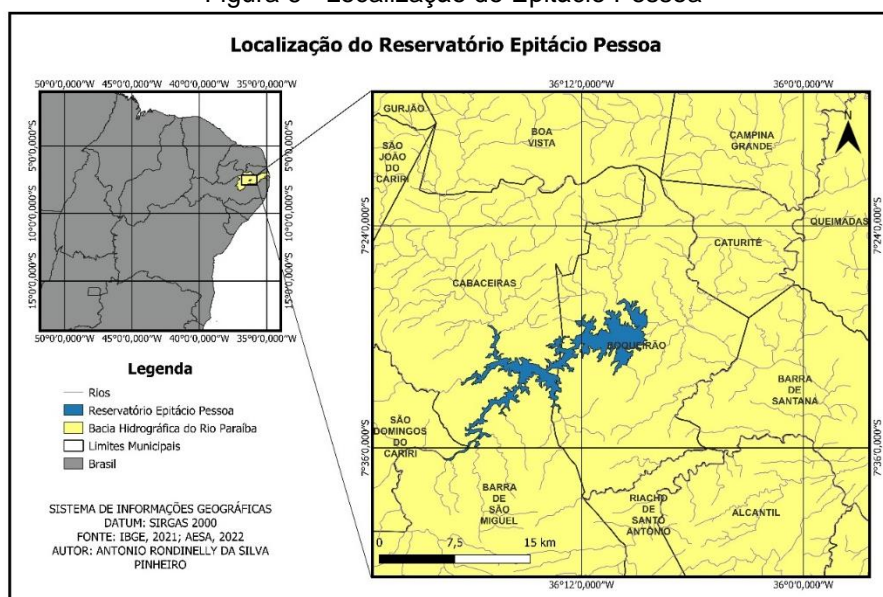
Para validar a metodologia, os métodos e modelos propostos para este estudo foram implementados em *MATLAB* (versão R2015b) e aplicados ao reservatório Epitácio Pessoa, na cidade de Boqueirão-PB, um dos açudes mais importantes do estado da Paraíba.

### 4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O reservatório Epitácio Pessoa está inserido na Bacia Hidrográfica do Rio Paraíba (Figura 6) e localizado na mesorregião da Borborema, no Estado da Paraíba. Sua construção foi realizada pelo Departamento de Obras Contra a Seca (DNOCS) entre os anos de 1953 e 1956. O seu principal objetivo é sanar os problemas de abastecimento público na cidade de Campina Grande-PB, além da perenização do médio curso do rio Paraíba, e atendimento de demandas para irrigação, piscicultura e lazer (NUNES, 2015).

O reservatório é o segundo maior da Paraíba, tendo sido projetado com capacidade para 536 hm<sup>3</sup> de água. Atualmente, entretanto, devido ao assoreamento, a sua capacidade máxima é de 466,53 hm<sup>3</sup> (SOARES, 2014; NUNES, 2015; ANA, 2022a).

Figura 6 - Localização do Epitácio Pessoa



Fonte: Adaptado de Pinheiro, Farias e Santos (2023).

Por se tratar de reservatório construído pela União, a operação do sistema fica a cargo da Agência Nacional de Águas e Saneamento Básico (ANA). As vazões regularizáveis atuais para os reservatórios foram definidas pela ANA através do marco regulatório presente na Resolução Conjunta ANA/AESA nº 126, de 26 de julho de 2022, com auxílio do Relatório de Análise de Impacto de Regulatório nº 1/2022/COMAR/SER, de 18 de janeiro de 2022.

## 4.2 CARACTERÍSTICAS HIDROLÓGICAS DO RESERVATÓRIO EPITÁCIO PESSOA

### 4.2.1 Afluências

As afluências que serão utilizadas por este trabalho foram obtidas por Nunes (2015), através do cálculo do balanço hídrico, em que se considera as diferenças de volumes medidos, as perdas por evaporação e as retiradas médias diárias, estas últimas obtidas com base nos dias sem entrada para cada período.

### 4.2.2 Cota-Área-Volume

A Cota-Área-Volume (CAV) foi obtida através do Relatório de Análise de Impacto de Regulatório, com a batimetria tendo sido realizada no ano de 2018 (ANA, 2022a). Nesta batimetria, o volume máximo (466,53 hm<sup>3</sup>) e o volume mínimo (40,68 hm<sup>3</sup>) foram determinados (ANA, 2022a). Na Tabela 1, apresenta-se a curva CAV.

Tabela 1 - CAV do Epitácio Pessoa

Cota (m)	Área (km <sup>2</sup> )	Volume (hm <sup>3</sup> )
343,80	0,00	0,00
344,00	0,00	0,00
345,00	0,10	0,03
346,00	0,27	0,22
347,00	0,50	0,60
348,00	0,71	1,21
349,00	0,99	2,05
350,00	1,29	3,20
351,00	1,66	4,67
352,00	2,13	6,56



<b>353,00</b>	2,58	8,91
<b>354,00</b>	3,09	11,74
<b>355,00</b>	3,89	15,18
<b>356,00</b>	4,77	19,52
<b>357,00</b>	5,65	24,72
<b>358,00</b>	6,55	30,82
<b>359,00</b>	7,46	37,82
<b>360,00</b>	8,43	45,77
<b>361,00</b>	9,30	54,63
<b>362,00</b>	10,24	64,38
<b>363,00</b>	11,40	75,19
<b>364,00</b>	12,63	87,20
<b>365,00</b>	13,92	100,46
<b>366,00</b>	15,51	115,13
<b>367,00</b>	17,43	131,56
<b>368,00</b>	19,43	149,98
<b>369,00</b>	21,77	170,61
<b>370,00</b>	24,05	193,51
<b>371,00</b>	26,43	218,74
<b>372,00</b>	28,90	246,39
<b>373,00</b>	31,46	276,56
<b>374,00</b>	34,21	309,40
<b>375,00</b>	37,22	345,09
<b>376,00</b>	40,27	383,83
<b>377,00</b>	43,69	425,81
<b>377,90</b>	46,79	466,53

Fonte: ANA (2022a).

### 4.2.3 Evaporação e Precipitação

Os dados mensais de evaporação e precipitação necessários para a realização deste trabalho estão dispostos em Nunes (2015) e Macêdo (2020).

A lâmina utilizada para operação do reservatório foi obtida através da subtração da lâmina evaporada pela lâmina precipitada na bacia hidráulica do reservatório. Na Tabela 2, observa-se os dados da lâmina perdida para a atmosfera.

Tabela 2 - Lâmina perdida

<b>Mês</b>	<b>Lâmina Perdida (m)</b>
<b>Janeiro</b>	0,186
<b>Fevereiro</b>	0,132
<b>Março</b>	0,065

<b>Abril</b>	0,047
<b>Mai</b>	0,040
<b>Junho</b>	0,037
<b>Julho</b>	0,061
<b>Agosto</b>	0,120
<b>Setembro</b>	0,165
<b>Outubro</b>	0,196
<b>Novembro</b>	0,224
<b>Dezembro</b>	0,214

Fonte: Macêdo (2020).

#### 4.2.4 Usuários do Sistema

O açude Epitácio Pessoa conta com pouca variedade de usos, sendo o abastecimento urbano a principal. Em se tratando de abastecimento urbano, a demanda visa atender às cidades do entorno do reservatório, como Boqueirão-PB, Cabaceiras-PB e outras, sendo Campina Grande-PB a maior demanda para este fim (SOARES, 2014; NUNES, 2015).

Os usuários de água para irrigação correspondem aos empreendimentos situados à montante do barramento do reservatório, atendendo às zonas rurais de Boqueirão-PB, Barra de São Miguel-PB e Cabaceiras-PB. A presença de pecuaristas nas imediações do reservatório é pequena, sendo o principal uso para dessedentação animal advindo de pequenas criações dos agricultores (SOARES, 2014).

As demandas mensais para os principais usos do reservatório Epitácio Pessoa estão dispostas na Tabela 3.

Tabela 3 - Demandas mensais para o reservatório

<b>Uso</b>	<b>Vazão (m<sup>3</sup>/s)</b>
Abastecimento Urbano	1,415
Abastecimento Rural	0,078
Dessedentação Animal	0,063
Irrigação	0,489
<b>Total</b>	<b>2,045</b>

Fonte: ANA (2017).

#### 4.3 COMPARAÇÃO ENTRE MODELOS DE OPERAÇÃO

Os resultados da aplicação do modelo OMC-FA foram comparados com os

resultados do modelo DET, que conhece todo o horizonte de disponibilidade hídrica, e com a Política de Operação Padrão, modelo comumente utilizado para a operação de reservatórios e que objetiva apenas o atendimento da demanda mensal, sem qualquer cautela com respeito à disponibilidade hídrica futura.

As operações do reservatório considerando os vários modelos também foram comparadas quanto à vulnerabilidade média mensal.

## 5 RESULTADOS

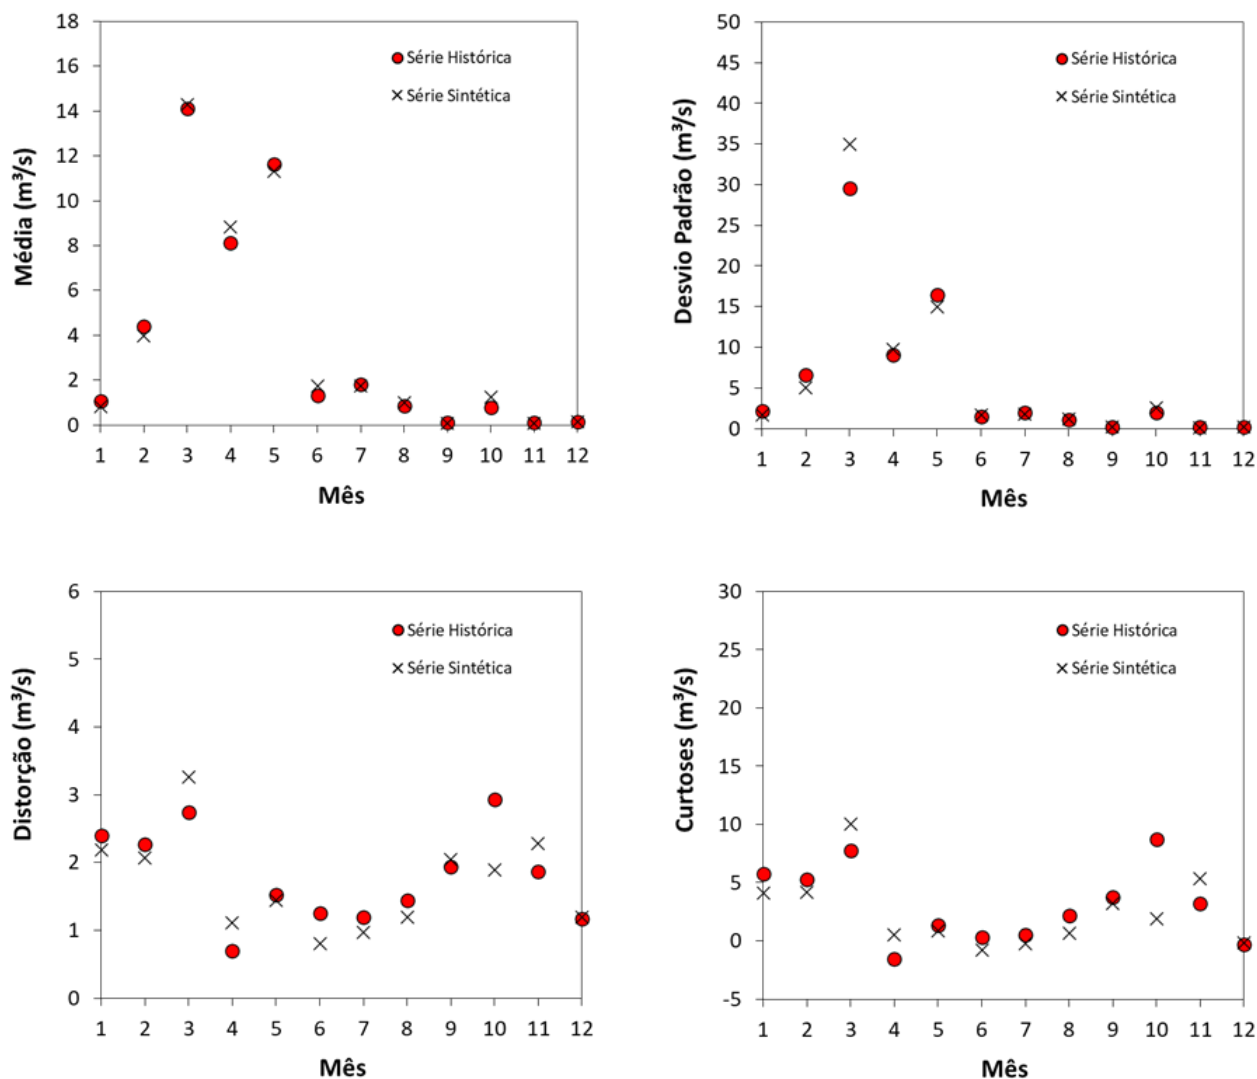
### 5.1 CALIBRAÇÃO DO MODELO OMC-FA

Como já destacado, as características hidrológicas e estruturais do reservatório (demanda, histórico de vazões, precipitação e evaporação, limites máximo e mínimo de armazenamento, e CAV) foram obtidas através dos trabalhos de Nunes (2015), Macêdo (2020) e ANA (2022a). Admitiu-se uma demanda hídrica total no reservatório de 2,045 m<sup>3</sup>/s e que o volume inicial para operação do reservatório correspondia a 50% de sua capacidade.

Calibrou-se o MF através das vazões afluentes obtidas por Nunes (2015), utilizando uma série histórica de 10 anos (2006-2015), para gerar 504 anos de dados mensais de vazões sintéticas. Optou-se por uma série de 504 anos por conta de limitações computacionais na etapa de otimização e das condições de contorno (eliminação dos dois primeiros e últimos anos, resultando em 500 anos de dados ótimos).

Na Figura 7, compara-se as propriedades estatísticas entre a série gerada pelo MF e a série histórica. Nota-se que existe uma reprodução adequada das características nas séries, na média é possível observar a conservação das condições hidrológicas de uma região semiárida com os períodos de maior afluência se concentrando no primeiro semestre. O desvio padrão, a distorção e a curtoses demonstram que a série sintética gerada, apesar de reproduzir o comportamento da série histórica, apresenta diferença quantitativa, ou seja, não possui igualdade.

Figura 7 - Comparação entre as propriedades estatísticas mensais



Fonte: Autoria Própria (2023).

Os dados da série sintética foram inseridos no modelo DET para obtenção dos dados otimizados e posterior geração da regra de alocação. Como já citado, os dois primeiros e os dois últimos anos gerados foram descartados para atender às condições de contorno do reservatório, resultando em 500 anos (6.000 meses) de dados ótimos de vazão, alocação e volume inicial do reservatório.

O recorte da série temporal ocorre para que se utilize somente dados de plena operação do reservatório, evitando a influência do volume inicial adotado e eliminando os resultados nos anos finais, quando o modelo DET entende que não haverá mais demandas e pode esvaziar o reservatório.

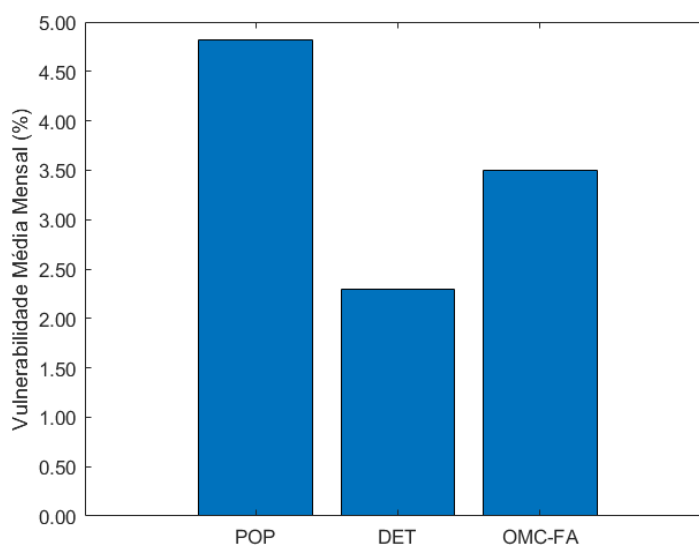
A calibração da FA ocorreu com os 6.000 meses de disponibilidade hídrica e alocações otimizadas. Em busca de se obter a melhor configuração para o modelo, treinou-se 20 FA com 25, 50, 75, ..., e 500 árvores de decisão com pelo menos duas folhas. A melhor configuração obtida foi a de 250 árvores de decisão com pelo menos duas folhas, obtendo um coeficiente *NSE* de 0,80 na calibração e *RMSE* de  $3,7878 \times 10^5$ .

## 5.2 VALIDAÇÃO DO MODELO OMC-FA

Gerou-se, por meio do MF, 100 novas séries sintéticas de vazão, cada uma com 14 anos de dados, para validação da regra OMC-FA. Para atendimento das condições de contorno, novamente os dois primeiros e os dois últimos anos de dados foram descartados, resultando em 100 séries sintéticas de 10 anos (120 meses).

As vulnerabilidades médias mensais obtidas foram de 3,5% para o modelo OMC-FA; 4,8% para o modelo POP; e 2,3% para o modelo DET. Ao fornecer uma vulnerabilidade média mensal próxima à observada no modelo DET e inferior à obtida pela POP, os resultados evidenciaram que o modelo OMC-FA é promissor. As vulnerabilidades médias para as operações com os três modelos encontram-se dispostas na Figura 8.

Figura 8 - Vulnerabilidade média mensal para os modelos aplicados no reservatório Epitácio Pessoa.



Fonte: Autoria Própria (2023).

Os demais resultados de vulnerabilidade mensal, com valores máximos, médios e mínimos para todas as séries geradas nesta aplicação, estão dispostos na Tabela 4. No Apêndice A encontram-se as vulnerabilidades das 100 simulações realizadas.

Tabela 4 - Valores mínimos, médios e máximos de vulnerabilidade mensal para todas as séries de vazões geradas


	POP	DET	OMC-FA
<b>Mínimo</b>	0,00%	0,00%	0,19%
<b>Médio</b>	4,82%	2,29%	3,50%
<b>Máximo</b>	32,14%	19,92%	24,57%

Fonte: Autoria Própria (2023).

Os valores médios e máximos encontrados para os modelos simulados apontam para um modelo OMC-FA menos susceptível à vulnerabilidade do que o modelo POP. Pinheiro, Farias e Santos (2023) encontraram resultados semelhantes ao utilizarem um modelo OMC-FA que trabalha com aleatoriedade nas variáveis.

Na Figura 9, compara-se os valores de vulnerabilidades obtidos na aplicação dos modelos.

Figura 9 - Vulnerabilidades.



Fonte: Autoria Própria (2023).

Nota-se que a maioria das simulações apresentam valores de vulnerabilidade menor do que a média, estes casos apresentam-se quando existe água suficiente no reservatório para atender as demandas durante todo o horizonte de operações.

Observa-se que quando a vulnerabilidade é superior a média, em casos onde existe uma maior propensão ao colapso do reservatório, a POP apresenta-se com vulnerabilidade superior ao modelo proposto OMC-FA.

### 5.3 CENÁRIOS DE VALIDAÇÃO

Após a validação com a simulação de 100 novas séries sintéticas, com 10 anos cada, selecionou-se quatro simulações que representam cenários diversos de operação.

Os seguintes cenários foram utilizados para análise:


- a) Cenário 1: Simulação em que os modelos POP, DET e OMC-FA possuem vulnerabilidade mínima;
- b) Cenário 2: Simulação em que os modelos POP, DET e OMC-FA apresentam vulnerabilidade próxima à média;
- c) Cenário 3: Simulação em que se verifica o modelo POP com vulnerabilidade máxima;
- d) Cenário 4: Simulação em que os modelos DET e OMC-FA apresentam sua vulnerabilidade máxima.

#### 5.3.1 Cenário 1

A Simulação nº 74 correspondeu a este cenário, em que os modelos POP, DET e OMC-FA apresentaram suas vulnerabilidades mínimas iguais a 0%, 0% e 0,19%, respectivamente.




Figura 10 - Volume do reservatório na Simulação nº 74



Fonte: Autoria Própria (2023).

Figura 11 - Alocação de água na Simulação nº 74



Fonte: Autoria Própria (2023).

Nas Figuras 10 e 11, observa-se que o reservatório não apresenta situação de severa escassez de água, contando com uma boa disponibilidade hídrica. Assim, os


modelos atendem satisfatoriamente as demandas, com comportamentos similares tanto no volume como nas alocações, sobretudo para os modelos DET e POP.

Na Figura 11, nota-se um comportamento cauteloso do modelo OMC-FA, mesmo em um cenário de alta disponibilidade hídrica. Cenários como este, em que há disponibilidade hídrica suficiente para a não ocorrência de colapsos, o modelo POP é o ideal (LOUCKS; BEEK, 2017).

### 5.3.2 Cenário 2


Na Simulação nº 98, os modelos POP, DET e OMC-FA resultaram em vulnerabilidades próximas às médias, com 5,88%, 2,47% e 2,38%, respectivamente. Nesta simulação, o modelo OMC-FA obteve os melhores resultados dentro do horizonte de operações.

Figura 12 - Volume do reservatório na Simulação nº 98



Fonte: Autoria Própria (2023).

Figura 13 - Alocação de água na Simulação nº 98



Fonte: Autoria Própria (2023).

Nas Figuras 12 e 13, observa-se que o modelo POP leva o reservatório ao colapso em dois momentos. O modelo OMC-FA começa a operação já realizando racionamento na alocação de água e mantém uma postura cautelosa durante os 120 meses, não colapsando nos momentos críticos.

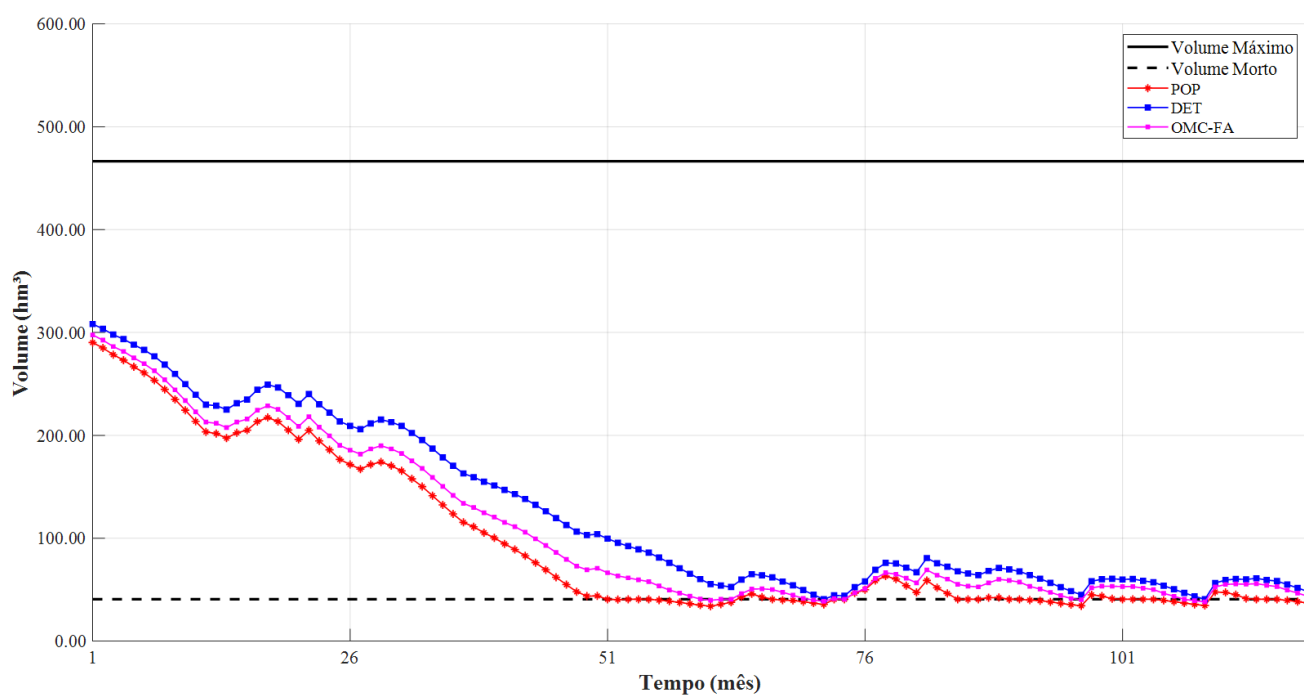
O modelo DET, que conhece todo o horizonte de operações, realiza um racionamento mais cadenciado no início. Entretanto é realizado um acréscimo contínuo no racionamento, conforme ocorre o decréscimo de volume no reservatório. Tal fato fez com que o modelo OMC-FA obtivesse uma menor vulnerabilidade para o recorte de 10 anos. Importante lembrar que a otimização foi realizada para 14 anos e que certamente o modelo DET forneceu a menor vulnerabilidade considerando esse período total.

Os resultados dos modelos OMC-FA e POP, neste cenário de vulnerabilidade média, assemelham-se com outras aplicações da Otimização de Monte Carlo, como observado em Celeste et al. (2005), Celeste e Bilib (2009), Carneiro e Farias (2013), Celeste e El-Shafie (2018) e Gomes (2022).

### 5.3.3 Cenário 3


A Simulação nº 21 resultou na máxima vulnerabilidade do modelo POP, com vulnerabilidade de 32,14%. Os modelos DET e OMC-FA obtiveram vulnerabilidade de 18,28% e 21,70%, respectivamente. Nesta simulação, o reservatório apresentou uma severa escassez hídrica em mais da metade dos 120 meses de simulação.

Figura 14 - Volume do reservatório na Simulação nº 21



Fonte: Autoria Própria (2023).

Figura 15 - Alocação de água na Simulação nº 21



Fonte: Autoria Própria (2023).

Nas Figuras 14 e 15, nota-se que a operação se torna complicada devido aos baixos níveis de armazenamento no reservatório. Tal fato inicia-se próximo do 50º mês de simulação. Situações como essa desfavorecem a POP, que não dispõe de qualquer mecanismo de racionamento para mitigar ou evitar situações de seca (LOUCKS; BEEK, 2017).

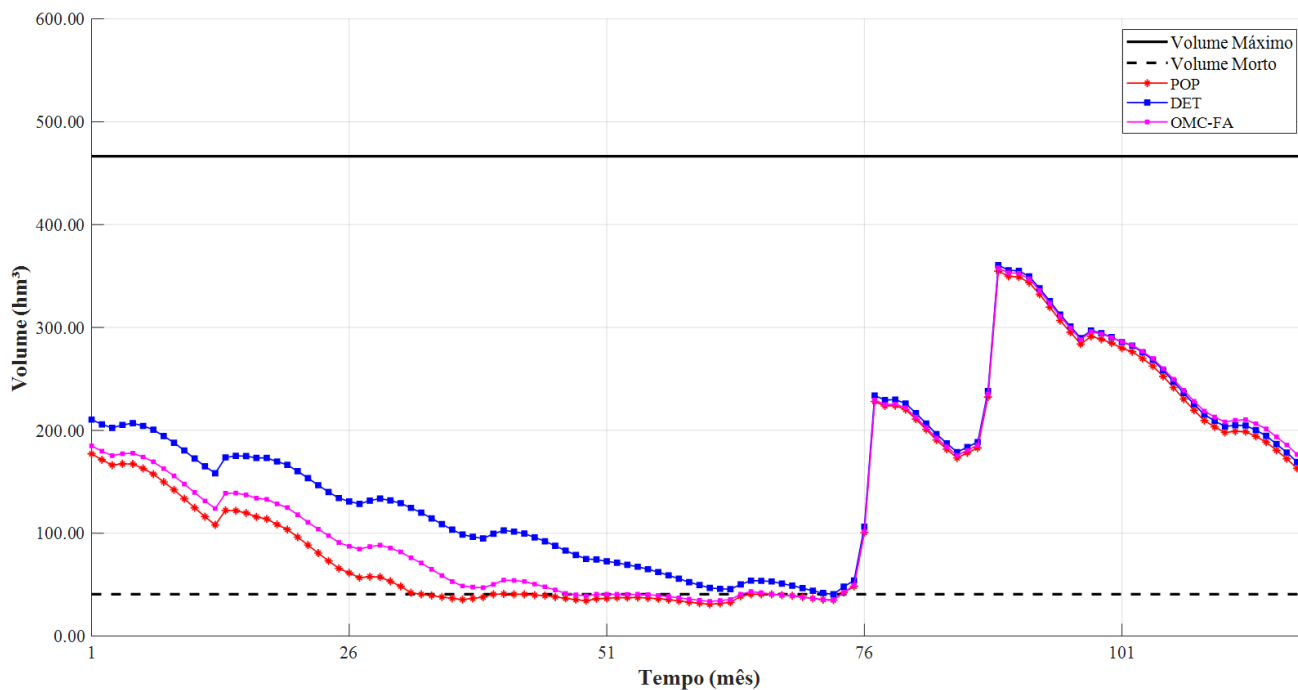
O uso da POP ocasiona o colapso do reservatório em diversos momentos entre os meses 51 e 120 da operação. O modelo DET, por ter conhecimento de todos os eventos futuros, começa a racionar de uma forma mais severa que o modelo OMC-FA, aumentando gradualmente o racionamento (PINHEIRO; FARIAS; SANTOS, 2023). Através deste controle de alocação, o modelo DET evita o colapso do reservatório.

O modelo proposto neste trabalho, OMC-FA, inicia a operação realizando um leve racionamento de água, a cautela empregada evita que o reservatório colapse por diversos meses consecutivos. Entretanto, o método acaba por não alocar água em alguns meses da operação devido à severa crise hídrica que foi apresentada na simulação.

### 5.3.4 Cenário 4


Na Simulação nº 63, obteve-se as máximas vulnerabilidades para os modelos DET e OMC-FA, com 19,92% e 24,57%, respectivamente. O método tradicional, POP, resultou em uma vulnerabilidade de 30,40%.

Figura 16 - Volume do reservatório na Simulação nº 63



Fonte: Autoria Própria (2023).

Figura 17 - Alocação de água na Simulação nº 63



Fonte: Autoria Própria (2023).

Nesta simulação, o reservatório é acometido de um severo período de seca, recuperando-se somente com duas grandes recargas hídricas seguidas entre os meses 70 e 90 (Figura 16).

Na Figura 17, observa-se que os modelos OMC-FA e POP colapsam diversas vezes com a situação extrema de crise hídrica no reservatório. Mesmo com a severa crise, é possível notar que o modelo OMC-FA foi menos vulnerável, colapsando menos, que o método tradicional de operação.

A grande recarga próxima ao mês 75 proveu água suficiente para que a operação do reservatório ocorresse com pleno funcionamento dos modelos. Entretanto, convém notar que o modelo OMC-FA se mostra cauteloso ao retomar a operação e começa a realizar um racionamento conforme o volume do reservatório vai diminuindo (Figuras 16 e 17) (PINHEIRO; FARIAS; SANTOS, 2023).

Apesar desta simulação possuir a máxima vulnerabilidade do modelo DET, a aplicação do racionamento de aumento gradual ajudou a mitigar os efeitos futuros advindos da crise hídrica e o reservatório manteve a alocação de água sem ocorrência de colapsos.

## 6 CONCLUSÕES

Neste trabalho, propôs-se um método baseado em Otimização Monte Carlo e Floresta Aleatória para gerar uma regra única de operação de reservatórios, levando em consideração a demanda total. A metodologia consistiu na utilização de um Modelo Determinístico para definir alocações otimizadas de água, visando minimizar a vulnerabilidade do reservatório, e um Modelo de Floresta Aleatória de Regressão para associar as alocações ótimas às disponibilidades hídricas. A validação do modelo ocorreu por meio da aplicação do método ao reservatório Epitácio Pessoa, localizado em Boqueirão-PB, no semiárido brasileiro.

Os resultados obtidos neste estudo demonstram a superioridade do modelo proposto OMC-FA em comparação à Política Operacional Padrão (POP), minimizando eficientemente a vulnerabilidade e apresentando desempenho semelhante ao modelo determinístico, que leva em conta todo o horizonte de operação. A análise da métrica NSE indica que a Floresta Aleatória de Regressão é altamente eficaz na associação das alocações ótimas às disponibilidades hídricas, resultando em um modelo OMC-FA com boa acurácia para estimar alocações com base na disponibilidade hídrica e sazonalidade do reservatório.

Como resultado, entende-se que o método proposto representa uma alternativa viável para a alocação negociada de águas, proporcionando soluções sustentáveis para o reservatório e com grande potencial para reduzir conflitos hídricos. Além disso, destaca-se que a proposta apresentada é simples e prática de ser aplicada.



## REFERÊNCIAS

ABDA, Z. *et al.* Assessing machine learning models for streamflow estimation: a case study in Oued Sebaou watershed (Northern Algeria). **Hydrological Sciences Journal**, [s. l.], v. 67, n. 9, p. 1328–1341, 2022. Disponível em: <https://doi.org/10.1080/02626667.2022.2083511>.

AHMAD, A. *et al.* Reservoir optimization in water resources: A review. **Water Resources Management**, [s. l.], v. 28, n. 11, p. 3391–3405, 2014.

ALI, M. *et al.* Complete ensemble empirical mode decomposition hybridized with random forest and kernel ridge regression model for monthly rainfall forecasts. **Journal of Hydrology**, [s. l.], v. 584, n. November 2019, p. 124647, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.124647>.

ALMEIDA, M. A.; CURI, W. F. Gestão do uso de água na bacia do Rio Paraíba, PB, Brasil com base em modelos de outorga e cobrança. **Ambiente e Agua - An Interdisciplinary Journal of Applied Science**, [s. l.], v. 11, n. 4, p. 989, 2016. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1980-993X2016000400989&lng=pt&nrm=iso&tlng=pt](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1980-993X2016000400989&lng=pt&nrm=iso&tlng=pt). Acesso em: 4 mar. 2023.

AMIT, Y.; GEMAN, D. Communicated by Shimon Ullman Shape Quantization and Recognition with Randomized Trees. **Neural Computation**, [s. l.], v. 9, p. 1545–1588, 1997.

AMORIM, A. L.; RIBEIRO, M. M. R.; BRAGA, C. F. C. Conflitos em bacias hidrográficas compartilhadas: O caso da bacia do rio Piranhas-Açu/PB-RN. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 21, n. 1, p. 36–45, 2016.

ANA, Agência Nacional de Águas e Saneamento Básico (Brasil). **Nota Técnica nº 10/2015/COMAR/SER Metodologia para Alocação de Água em Açudes Isolados – Meta Institucional da Superintendência de Regulação - 01/10/2014 e 30/09/2015**. Disponível em: <https://www.gov.br/ana/pt-br/todos-os-documentos-do-portal/documentos-sre/alocacao-de-agua/oficina-alocacao-de-agua-1/metodologia-da-ana-para-alocacao-de-agua-em-acudes-isolados.pdf>.

ANA, Agência Nacional de Águas e Saneamento Básico (Brasil). **Relatório de Análise de Impacto Regulatório nº 1/2022/COMAR/SRE, de 18 de janeiro de 2022**. 2022a. Disponível em: [https://www.gov.br/ana/pt-br/assuntos/regulacao-e-fiscalizacao/alocacao-de-agua-e-marcos-regulatorios/marcos-regulatorios/AIR\\_N1\\_2022\\_COMAR\\_SREMPessoa.pdf](https://www.gov.br/ana/pt-br/assuntos/regulacao-e-fiscalizacao/alocacao-de-agua-e-marcos-regulatorios/marcos-regulatorios/AIR_N1_2022_COMAR_SREMPessoa.pdf).

ANA, Agência Nacional de Águas e Saneamento Básico (Brasil). **Reservatórios do Semiárido Brasileiro: hidrologia, balanço hídrico e operação**. Anexo A. Brasília, 2017.

ANA, Agência Nacional de Águas e Saneamento Básico (Brasil). **Resolução Conjunta ANA/AESA nº 126, de 26 de julho de 2022**. 2022b. Disponível em:

<https://www.gov.br/ana/pt-br/assuntos/regulacao-e-fiscalizacao/alocacao-de-agua-e-marcos-regulatorios/marcos-regulatorios/Resoluo126ANAAESAMREPITACIOPESSOA.pdf>.

ARAÚJO, M. D.; RIBEIRO, M. M. R.; BRAGA, C. F. C. Integrating water allocation modelling into the DPSIR indicator system: Application to the semi-arid region of Brazil. **Engenharia Sanitaria e Ambiental**, [s. l.], v. 24, n. 6, p. 1167–1181, 2019.

AZEVÊDO, E. L. *et al.* How do people gain access to water resources in the Brazilian semiarid (Caatinga) in times of climate change?. **Environmental Monitoring and Assessment**, [s. l.], v. 189, n. 8, 2017.

BARRETO, L. A. L. **Otimização implícita estocástica para operação de reservatórios**. Dissertação de mestrado (Mestrado em Engenharia) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1974.

BASTO, I. D. R. G.; FONTES, A. S.; MEDEIROS, Y. D. P. Effects of an outflow regime adoption of the São Francisco River reservoir system to meet water demands for multiple uses. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 25, p. 1–22, 2020.

BAUM, F. **Otimização de propriedades físicas de pontos quânticos e nanopartículas de semicondutores por inteligência artificial e planejamento experimental**. Tese de Doutorado (Doutorado em Ciências dos Materiais) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.

BELGIU, M.; DRĂGU, L. Random Forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**. Elsevier.

BEZERRA, A. P.; VIEIRA, Z. M. C. L.; RIBEIRO, M. M. R. Water governance assessment at different scales: A reservoir case study in the Brazilian semiarid region. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 26, 2021. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S2318-03312021000100213&tlng=en](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312021000100213&tlng=en). Acesso em: 10 jan. 2022.

BILLERBECK, C.; MELLO JUNIOR, A. V. Optimal operation of the cantareira system for a critical inflow period. **Engenharia Sanitaria e Ambiental**, [s. l.], v. 23, n. 6, p. 1121–1130, 2018. PEIXOTO, F. da S.; SOARES, J. A.; RIBEIRO, V. S. Conflitos pela água no Brasil. **Sociedade & Natureza**, [s. l.], v. 34, n. 1, 2021.

BRASIL. **Lei nº 9.433, de 8 de janeiro de 1997**. Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos. Brasília, 1997.

BREIMAN, L. Bagging predictors. **Machine Learning**, 1996. v. 24, n. 2, p. 123–140.

BREIMAN, L. *et al.* **Classification and regression trees**. 1. ed. New York: Routledge, 1984.

BREIMAN, L. Random forests. **Mach. Learning**, 2001. v. 45, n. 1, p. 5–32.

BUSSAB, W. O.; MORETIN, P. A. **Estatística básica**. 9. ed. São Paulo: Saraiva, 2017.

CAMPOS, J. N. B. Paradigms and Public Policies on Drought in Northeast Brazil: A Historical Perspective. **Environmental Management**, [s. l.], v. 55, n. 5, p. 1052–1063, 2015.

CARNEIRO, T. C.; FARIAS, C. A. S. Otimização Estocástica Implícita e Redes Neurais Artificiais para Auxílio na Operação Mensal dos Reservatórios Coremas - Mãe d'Água. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 4, pp. 115-124, 2013.

CARUANA, R.; NICULESCU-MIZIL, A. **An empirical comparison of supervised learning algorithms**. [S.l.]: [s.n.], 2006. V. 148, p. 161–168. Disponível em: <[www.cs.cornell.edu](http://www.cs.cornell.edu)>.

CELESTE, A. B.; BILLIB, M. Evaluation of stochastic reservoir operation optimization models. **Advances in Water Resources**, [s. l.], v. 32, n. 9, p. 1429–1443, 2009. Disponível em: <http://dx.doi.org/10.1016/j.advwatres.2009.06.008>.

CELESTE, A. B.; CURI, W. F.; CURI, R. C. Análise de métodos para geração sintética de vazões. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 17., 2007, São Paulo. **Anais...** Porto Alegre: ABRH, 2007. p. 1-18,

CELESTE, A. B.; CURI, W. F.; CURI, R. C. Implicit stochastic optimization for deriving reservoir operating rules in semiarid Brazil. **Pesquisa Operacional**, [s. l.], v. 29, n. 1, p. 223–234, 2009.

CELESTE, A. B.; EL-SHAFIE, A. Assessment of Stochastic Operation Optimization for Reservoirs of Contrasting Scales. **Water Resources Management**, [s. l.], v. 32, n. 11, p. 3751–3763, 2018.

CELESTE, A. B.; SUZUKI, K.; KADOTA, A.; SANTOS, V. S. Derivation of reservoir operating rules by implicit stochastic optimization. **Annual Journal of Hydraulic Engineering**, [s. l.], v. 49, n. 2, p. 1111-1116, 2005.

CHEN, K. *et al.* The Value of Hydrologic Information in Reservoir Outflow Decision-Making. **Water**, [s. l.], v. 10, n. 10, p. 1372, 2018. Disponível em: <http://www.mdpi.com/2073-4441/10/10/1372>. Acesso em: 11 fev. 2022.

CURI, W. F. *et al.* Um Modelo de Outorga para Bacias Controladas por Reservatórios: 1 - Desenvolvimento do Modelo que Contempla Demandas Múltiplas e Variáveis Mensalmente. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 16, n. 2002, p. 73–82, 2011.

DESAI, S.; OUARDA, T. B. M. J. Regional hydrological frequency analysis at ungauged sites with random forest regression. **Journal of Hydrology**, [s. l.], v. 594, n. December 2020, p. 125861, 2021. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.125861>.

DIETTERICH, T. G. Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms. **Neural Computation**, United States, v. 10, n. 7, p. 1895–1923, 1998.

DOSDOGRU, F. *et al.* Potential impacts of land use/cover and climate changes on ecologically relevant flows. **Journal of Hydrology**, [s. l.], v. 584, n. December 2019, p. 124654, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.124654>.

DRAPER, A. J. **Implicit Stochastic Optimization with limited foresight for reservoir systems**. 2001. Tese (Doutorado em Engenharia), University of California, Davis, Estados Unidos da América, 2001.

DRAPER, A. J.; LUND, J. R. Optimal Hedging and Carryover Storage Value. **Journal of Water Resources Planning and Management**, [s. l.], v. 130, n. 1, p. 83–87, 2004.

DRAPER, A. J.; MUNÉVAR, A.; ARORA, S. K.; REYES, E.; PARKER, N. L.; CHUNG, F. I.; PETERSON, L. E. CalSim: Generalized model for reservoir system analysis, **J. Water Resour. Plann. Manage.**, 2004. v. 130, n. 6, p. 480–489.

EHSANI, N. *et al.* Reservoir operations under climate change: Storage capacity options to mitigate risk. **Journal of Hydrology**, [s. l.], v. 555, p. 435–446, 2017. Disponível em: <https://doi.org/10.1016/j.jhydrol.2017.09.008>.

FARIAS, C. A. S. **Derivation of hedging rules and forecasts by artificial neural networks for optimal real-time management of an integrated water resources system**. 2009. Tese (Doutorado em Engenharia), Ehime University, Matsuyama, Japão, 2009.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

GIROLAMO NETO, C. **Identificação de fitofisionomias de Cerrado no Parque Nacional de Brasília utilizando random forest aplicado a imagens de alta e média resoluções espaciais**. Tese de Doutorado (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

GOMES, F. N. **Otimização estocástica implícita e teoria dos jogos cooperativos para operação mensal de reservatórios com múltiplos usos**. Dissertação de mestrado (Mestrado em Gestão e Regulação de Recursos Hídricos) – Universidade Federal de Campina Grande, Sumé, 2022.

GRAFTON, R. Q. *et al.* Global insights into water resources, climate change and governance. **Nature Climate Change**, [s. l.], v. 3, n. 4, p. 315–321, 2013. Disponível em: <https://doi.org/10.1038/nclimate1746>.

GUARISO, G.; SANGIORGIO, M. Performance of Implicit Stochastic Approaches to the Synthesis of Multireservoir Operating Rules. **Journal of Water Resources Planning and Management**, [s. l.], v. 146, n. 6, 2020.

GUI, G. *et al.* Flight delay prediction based on aviation big data and machine learning. **IEEE Transactions on Vehicular Technology**, [s. l.], v. 69, n. 1, p. 140–150, 2020.

HASHIMOTO, T.; STEDINGER, J. R.; LOUCKS, D. P. Reliability, resiliency, and vulnerability criteria for water resource system performance evaluation. **Water Resources Research**, [s. l.], v. 18, n. 1, p. 14–20, 1982. Disponível em: <https://doi.org/10.1029/WR018i001p00014>.

HASTIE, T.; TIBSHIRANI R.; FRIEDMAN J. **The elements of statistical learning**. 2. ed. New York: Springer Science & Business Media; 2016.

HO, T. K. The random subspace method for constructing decision forests. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [s. l.], v. 20, n. 8, p. 832–844, 1998.

HONG, J. *et al.* Comparison of machine learning algorithms for discharge prediction of multipurpose dam. **Water (Switzerland)**, [s. l.], v. 13, n. 23, p. 1–12, 2021.

JACOBI, P. R.; BUCKERIDGE, M.; RIBEIRO, W. C. Governança da água na Região Metropolitana de São Paulo - desafios à luz das mudanças climáticas. **Estudos Avancados**, [s. l.], v. 35, n. 102, p. 209–226, 2021. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0103-40142021000200209&tlng=pt](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-40142021000200209&tlng=pt). Acesso em: 10 jan. 2022.

LABADIE, J. W. Optimal Operation of Multireservoir Systems: State-of-the-Art Review. **Journal of Water Resources Planning and Management**, [s. l.], v. 130, n. 2, p. 93–111, 2004.

LIU, Q. *et al.* Simulation of regional groundwater levels in arid regions using interpretable machine learning models. **Science of The Total Environment**, [s. l.], v. 831, n. 2022, p. 154902, 2022. Disponível em: <https://doi.org/10.1016/j.scitotenv.2022.154902>.

LOUCKS, D. P.; BEEK, E. V. **Water resource systems planning and analysis - An Introduction to Methods, Models, and Applications**. E-book: Deltares e UNESCO-IHE, 2017.

MA, J. *et al.* Research on Optimal Allocation of Water Resources in Handan City Based on the Refined Water Resource Allocation Model. **Water (Switzerland)**, [s. l.], v. 15, n. 1, 2023.

MAASS, A.; HUFSCHEIDT, M.M.; DORFMAN JR., H.A.; THOMAS, S.A.; MARGLIN, F. **Design of Water Resource Systems**. Harvard University Press, Cambridge, MA, 1962.

MACÊDO, T. C. **Derivação de regras baseadas em critérios sustentáveis para operação mensal do reservatório Epitácio Pessoa**. Dissertação de mestrado (Mestrado em Gestão e Regulação de Recursos Hídricos) – Universidade Federal de Campina Grande, Sumé, 2020.

MEKONNEN, M. M.; HOEKSTRA, A. Y. Sustainability: Four billion people facing severe water scarcity. **Science Advances**, [s. l.], v. 2, n. 2, p. 1–7, 2016.

MELESSE, A. M. *et al.* River water salinity prediction using hybrid machine learning models. **Water (Switzerland)**, [s. l.], v. 12, n. 10, p. 1–21, 2020. Disponível em: <https://www.mdpi.com/2073-4441/12/10/2951>. Acesso em: 4 jun. 2022.

MISHRA, K.; KUMAR, P.; SARASWAT, C.; CHAKRABORTY, S.; GAUTAM, A. Water Security in a Changing Environment: Concept. **Water**, [s. l.], v. 13, n. 490, 2021.

MIZYED, N. R.; LOFTIS, J. C.; FONTANE, D. G. Operation of Large Multireservoir Systems Using Optimal-Control Theory. **Journal of Water Resources Planning and Management**, [s. l.], v. 118, n. 4, p. 371–387, 1992.

MOMTAHEN, S.; DARIANE, a B. for Optimization of Water Reservoir Operating Policies. **Journal of Water Resources Planning and Management**, [s. l.], v. 133, n. 13, p. 202–209, 2007.

MORAIS, A. A. C.; MAIA, A. G. Development of reservoir operation rules using seasonal climate forecasts. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 26, 2021.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I — A discussion of principles. **Journal of hydrology (Amsterdam)**, [s. l.], v. 10, n. 3, p. 282–290, 1970.

NUNES, T.H.C. **A gestão do reservatório Epitácio Pessoa e regras de operação otimizadas**. Dissertação de Mestrado (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Campina Grande, 2015.

NUNES, T. H. C.; GALVÃO, C. de O.; RÊGO, J. C. Curva-guia para incremento sazonal da outorga em reservatórios com baixas vazões de regularização. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 21, n. 3, p. 493–501, 2016.

OCDE. Organização para a Cooperação e Desenvolvimento Econômico. **Princípios da OCDE para a Governança da Água**. OCDE, 2015. Disponível em: <https://search.oecd.org/cfe/regionaldevelopment/OECD-Principles-Water-portuguese.pdf>.

OLIVEIRA, R.; LOUCKS, D. P. Operating rules for multireservoir systems. **Water Resources Research**, [s. l.], v. 33, n. 4, p. 839–852, 1997.

ONU. Organização das Nações Unidas. **Transformando nosso mundo: a Agenda 2030 para o Desenvolvimento Sustentável**. Nova York: ONU, 2015.

PEDROSA, V. A. **Soluções de conflito pelo uso da água**. 1. ed. Serra: ArcelorMittal Tubarão, 2017.

PEIXOTO, F. S.; SOARES, J. A.; RIBEIRO, V. S. Conflitos pela água no Brasil. **Sociedade & Natureza**, [s. l.], v. 34, n. 1, p. 1–13, 2021.

PINHEIRO, A. R. S. et al. O papel do município de Cajazeiras na gestão integrada dos recursos hídricos no estado da paraíba. **Anais do VII CONAPESC...** Campina Grande: Realize Editora, 2022. Disponível em: <<https://editorarealize.com.br/artigo/visualizar/87009>>. Acesso em: 13/12/2022 19:10.

PINHEIRO, A. R. S.; FARIAS, C. A. S.; SANTOS, C. A. G. Implicit Stochastic Optimization and Random Forest for Monthly Reservoir Operation. **Anales del XXX Congreso Latinoamericano de Hidráulica...** Madrid: IAHR Publishing, v. 68, p. 272-280, 2023.

PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. **Ecosystems**, [s. l.], v. 9, n. 2, p. 181–199, 2006. Disponível em: <https://doi.org/10.1007/s10021-005-0054-1>.

RAJE, D.; MUJUMDAR, P. P. Reservoir performance under uncertainty in hydrologic impacts of climate change. **Advances in Water Resources**, [s. l.], v. 33, n. 3, p. 312–326, 2010. Disponível em: <http://dx.doi.org/10.1016/j.advwatres.2009.12.008>.

RIBEIRO, N. B.; JOHNSON, R. M. F. Discussions on water governance: Patterns and common paths. **Ambiente e Sociedade**, [s. l.], v. 21, n. 0, 2018. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1414-753X2018000100314&lng=en&tlng=en](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-753X2018000100314&lng=en&tlng=en). Acesso em: 14 dez. 2022.

RIBEIRO NETO, G. G. *et al.* Drought Cycle Analysis to Evaluate the Influence of a Dense Network of Small Reservoirs on Drought Evolution. **Water Resources Research**, [s. l.], v. 58, n. 1, 2022.

SANTANA, C. F. D. **Árvore de decisão e simulação estocástica para análise de riscos em sistemas de reservatórios superficiais**. Tese de Doutorado (Doutorado em Engenharia Civil e Ambiental) - Universidade Federal de Campina Grande, Campina Grande, 2022.

SANTANA, F. B. **Floresta aleatória para desenvolvimento de modelos multivariados de classificação e regressão em química analítica**. Tese de

Doutorado (Doutorado em Química) – Universidade Estadual de Campinas, Campinas, 2020.

SANTOS, J. A. S.; CELESTE, A. B. Curvas-Guia Operacionais de Reservatório Sergipano Derivadas por Otimização Estocástica Implícita e Regressão Não Linear. **Scientia cum Industria**, [s. l.], v. 4, n. 1, p. 32–37, 2016.

SEGAL, M. R. Machine Learning Benchmarks and Random Forest Regression Publication Date Machine Learning Benchmarks and Random Forest Regression. **Center for Bioinformatics and Molecular Biostatistics**, [s. l.], p. 15, 2004. Disponível em: <https://escholarship.org/uc/item/35x3v9t4>.

SHAIKH, S. A.; PATTANAYEK, T. Implicit stochastic optimization for deriving operating rules for a multi-purpose multi-reservoir system. **Sustainable Water Resources Management**, [s. l.], v. 8, n. 5, p. 1–13, 2022. Disponível em: <https://doi.org/10.1007/s40899-022-00717-x>.

SILVA, G. N. S. **Apoio à gestão sustentável de recursos hídricos através de um modelo hidro-econômico desenvolvido em diferentes cenários de uso do solo e clima: o caso do sub-médio do São Francisco**. Tese de Doutorado (Doutorado em Engenharia Civil) – Universidade Federal de Pernambuco, Recife, 2017.

SILVA FILHO, J. A.; FARIAS, C. A. S. Stochastic modeling of monthly river flows by self-organizing maps. **Journal of Urban and Environmental Engineering**, [s. l.], v. 12, n. 2, p. 219–230, 2018.

SOARES, J. A. S. **Gestão de recursos hídricos: conflito pelo uso da água no açude Epitácio Pessoa-PB**. Dissertação de Mestrado (Mestrado em Recursos Naturais) Universidade Federal de Campina Grande, Campina Grande, 2014.

SOARES NETO, P. B.; PEDROSA, V. A. **Construindo a segurança hídrica**. 1. ed. Vitória: GSA Gráfica e Editora, 2018.

SULIS, A. Improved implicit stochastic optimization technique under drought conditions: The case study of agri-sinni water system. **International Journal of River Basin Management**, [s. l.], v. 16, n. 4, p. 493–504, 2018. Disponível em: <https://doi.org/10.1080/15715124.2017.1378225>.

SVANIDZE, G.G. **Mathematical Modeling of Hydrologic Series (for Hydroelectric and Water Resources Computations)**. Fort Collins: Water Resources Publications. 1980.

TEGEGNE, G.; KIM, Y. O. Representing inflow uncertainty for the development of monthly reservoir operations using genetic algorithms. **Journal of Hydrology**, [s. l.], v. 586, n. March, p. 124876, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.124876>.



TU, M.-Y.; HSU, N.-S.; YEH, W. W.-G. Optimization of Reservoir Management and Operation with Hedging Rules. **Journal of Water Resources Planning and Management**, [s. l.], v. 129, n. 2, p. 86–97, 2003.

VIEIRA, V. P. P. B. Water resources in Brazil and the sustainable development of the semi-arid north east. **International Journal of Water Resources Development**, [s. l.], v. 14, n. 2, p. 183–198, 1998.

VÖRÖSMARTY, C. J. *et al.* Global water resources: Vulnerability from climate change and population growth. **Science**, [s. l.], v. 289, n. 5477, p. 284–288, 2000.

WILLIS, R.; FINNEY, B. A.; CHU, W. S. Monte Carlo optimization for reservoir operation. **Water Resources Research**, v. 20, n. 9, p. 1177-1182, 1984.

WOLFE, F. *et al.* The American College of Rheumatology preliminary diagnostic criteria for fibromyalgia and measurement of symptom severity. **Arthritis Care and Research**, 2010. v. 62, n. 5, p. 600–610.

WURBS, R. A. Reservoir-System Simulation and Optimization Models. **Journal of Water Resources Planning and Management**, [s. l.], v. 119, n. 4, p. 455–472, 1993.

YANG, T. *et al.* Developing reservoir monthly inflow forecasts using artificial intelligence and climate phenomenon information. **Water Resources Research**, 2017. v. 53, n. 4, p. 2786–2812.

YANG, T. *et al.* Simulating California reservoir operation using the classification and regression-tree algorithm combined with a shuffled cross-validation scheme. **Water Resources Research**, 1 mar. 2016. v. 52, n. 3, p. 1626–1651.

YANG, D.; YANG, Y.; XIA, J. Hydrological cycle and water resources in a changing world: A review. **Geography and Sustainability**, [s. l.], v. 2, n. 2, p. 115–122, 2021. Disponível em: <https://doi.org/10.1016/j.geosus.2021.05.003>.

YOUNG JUNIOR., G. K. Finding Reservoir Operation Rules. **Journal of the Hydraulics Division**, [s. l.], v. 93, n. 6, p. 297-321, 1967.

YU, S. *et al.* C\_CART: An instance confidence-based decision tree algorithm for classification. **Intelligent Data Analysis**, [s. l.], v. 25, n. 4, p. 929–948, 2021.

ZHU, F. *et al.* **A classification algorithm of cart decision tree based on mapreduce attribute weights**. [S. l.: s. n.], 2018. Disponível em: <http://www.ijpe-online.com>.

## APÊNDICE A – VULNERABILIDADE MENSAL

<b>Simulação</b>	<b>POP</b>	<b>DET</b>	<b>OMC-FA</b>
1	0,00%	0,00%	0,45%
2	0,00%	0,00%	0,43%
3	1,33%	0,18%	2,10%
4	8,54%	2,24%	5,47%
5	0,00%	0,00%	0,19%
6	24,21%	13,89%	20,48%
7	3,52%	0,55%	1,66%
8	0,00%	0,00%	0,30%
9	2,21%	0,18%	1,34%
10	4,18%	0,56%	2,92%
11	0,00%	0,01%	0,60%
12	0,00%	0,00%	0,51%
13	0,00%	0,01%	0,77%
14	0,00%	0,02%	1,42%
15	0,00%	0,00%	0,30%
16	9,70%	2,86%	4,90%
17	0,00%	0,01%	0,77%
18	27,90%	18,86%	17,27%
19	0,00%	0,00%	0,22%
20	30,40%	19,92%	24,57%
21	32,14%	18,28%	21,70%
22	0,10%	0,00%	1,87%
23	4,17%	0,73%	1,88%
24	0,00%	0,00%	0,52%
25	0,00%	0,00%	0,66%
26	0,00%	0,00%	0,32%
27	0,00%	0,00%	0,67%
28	0,00%	1,05%	0,77%
29	13,43%	5,26%	9,39%
30	0,00%	0,00%	0,38%
31	0,00%	0,01%	0,20%
32	0,00%	0,00%	0,52%
33	0,00%	0,00%	0,29%
34	1,99%	0,16%	1,73%

<b>35</b>	0,00%	1,10%	0,99%
<b>36</b>	14,45%	6,50%	12,41%
<b>37</b>	9,73%	2,92%	4,84%
<b>38</b>	8,94%	1,88%	2,97%
<b>39</b>	3,58%	0,56%	1,67%
<b>40</b>	0,00%	0,00%	0,42%
<b>41</b>	7,41%	1,90%	2,43%
<b>42</b>	0,00%	0,06%	0,63%
<b>43</b>	9,45%	4,72%	5,77%
<b>44</b>	0,00%	0,00%	0,45%
<b>45</b>	0,00%	0,00%	0,43%
<b>46</b>	1,33%	0,18%	2,10%
<b>47</b>	8,54%	2,24%	5,47%
<b>48</b>	0,00%	0,00%	0,19%
<b>49</b>	24,21%	13,89%	20,48%
<b>50</b>	3,52%	0,55%	1,66%
<b>51</b>	0,00%	0,00%	0,30%
<b>52</b>	2,21%	0,18%	1,34%
<b>53</b>	4,18%	0,56%	2,92%
<b>54</b>	0,00%	0,01%	0,60%
<b>55</b>	0,00%	0,00%	0,51%
<b>56</b>	0,00%	0,01%	0,77%
<b>57</b>	0,00%	0,02%	1,42%
<b>58</b>	0,00%	0,00%	0,30%
<b>59</b>	9,70%	2,86%	4,90%
<b>60</b>	0,00%	0,01%	0,77%
<b>61</b>	27,90%	18,86%	17,27%
<b>62</b>	0,00%	0,00%	0,22%
<b>63</b>	30,40%	19,92%	24,57%
<b>64</b>	32,14%	18,28%	21,70%
<b>65</b>	0,10%	0,00%	1,87%
<b>66</b>	4,17%	0,73%	1,88%
<b>67</b>	0,00%	0,00%	0,52%
<b>68</b>	0,00%	0,00%	0,66%
<b>69</b>	0,00%	0,00%	0,32%
<b>70</b>	0,00%	0,00%	0,67%
<b>71</b>	0,00%	1,05%	0,77%
<b>72</b>	13,43%	5,26%	9,39%

<b>73</b>	0,00%	0,00%	0,38%
<b>74</b>	0,00%	0,01%	0,20%
<b>75</b>	0,00%	0,00%	0,52%
<b>76</b>	0,00%	0,00%	0,29%
<b>77</b>	1,99%	0,16%	1,73%
<b>78</b>	0,00%	1,10%	0,99%
<b>79</b>	14,45%	6,50%	12,41%
<b>80</b>	9,73%	2,92%	4,84%
<b>81</b>	8,94%	1,88%	2,97%
<b>82</b>	3,58%	0,56%	1,67%
<b>83</b>	0,00%	0,00%	0,42%
<b>84</b>	7,41%	1,90%	2,43%
<b>85</b>	0,00%	0,06%	0,63%
<b>86</b>	9,45%	4,72%	5,77%
<b>87</b>	1,51%	2,78%	1,81%
<b>88</b>	0,00%	0,01%	0,39%
<b>89</b>	0,00%	0,00%	0,30%
<b>90</b>	21,92%	10,12%	12,52%
<b>91</b>	0,00%	0,00%	0,26%
<b>92</b>	0,00%	0,00%	0,99%
<b>93</b>	0,00%	0,01%	0,28%
<b>94</b>	0,00%	0,01%	0,46%
<b>95</b>	0,00%	0,01%	0,30%
<b>96</b>	0,00%	0,00%	0,96%
<b>97</b>	15,89%	5,04%	7,28%
<b>98</b>	5,88%	2,47%	2,38%
<b>99</b>	1,61%	0,13%	2,37%
<b>100</b>	0,00%	0,00%	0,53%

Fonte: Autoria Própria (2023).