

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

### **MODELOS HIDROLÓGICOS DE DIFERENTES COMPLEXIDADES E INSTRUMENTAÇÃO NECESSÁRIA PARA ATENDIMENTO DAS RESOLUÇÕES ANM Nº95/2022 E ANM Nº 220/2025**

*Ana Carolina Canossa Becker<sup>1</sup>; Felipe Emanuel Domiciano Ribeiro<sup>2</sup>;*

*Daniel de Oliveira Dourado<sup>3</sup> & Stella Braga de Andrade<sup>4</sup>*

**Resumo:** A utilização de modelos hidrológicos no contexto da hidrologia aplicada à mineração, especialmente voltada à segurança de barragens, é uma das etapas que antecede o trânsito de cheias para a avaliação da borda livre do reservatório. A atualização na legislação busca aprimorar essa análise: as resoluções ANM nº 95/2022 e ANM nº 220/2025 preveem a calibração dos modelos das bacias hidrográficas relacionadas à barragem utilizando informações coletadas por instrumentos com período suficiente para calibração. Essa determinação reforça a importância de uma análise mais detalhada de modelos hidrológicos que podem ser utilizados para esse fim, considerando a necessidade da calibração. Este estudo tem como finalidade apresentar os instrumentos necessários para a calibração de modelos hidrológicos, em conformidade com a legislação, além de investigar as particularidades de modelos hidrológicos adequados a bacias de pequeno e médio porte, frequentemente encontradas no setor de barragens de mineração. Os modelos analisados neste trabalho incluem tanto abordagens conceituais, como o SCS, SMAP, SAC-SMA e SWAT, quanto técnicas de aprendizado de máquina, como MLP, Random Forest, XGBoost, CNN e LSTM. Entre os modelos avaliados, considerou-se que a escolha do modelo deve estar alinhada ao objetivo do estudo, às características da bacia e à qualidade dos dados disponíveis. Modelos mais detalhados exigem maior quantidade de informações e conhecimento técnico para serem aplicados de forma consistente. Por outro lado, modelos mais simples podem atender a análises preliminares ou a bacias com menor complexidade.

**Abstract:** The use of hydrological models in the context of hydrology applied to mining, especially focused on dam safety, is one of the stages preceding flood routing for the assessment of the reservoir's freeboard. Updates in legislation aim to enhance this analysis: ANM Resolution No. 95/2022 and ANM Resolution No. 220/2025 require the calibration of watershed models related to the dam using data collected by instruments with a sufficient period for calibration. This determination reinforces the importance of a more detailed analysis of hydrological models that can be used for this purpose, considering the need for calibration. This study aims to present the necessary instruments for the calibration of hydrological models, in compliance with the legislation, in addition to investigating the particularities of hydrological models suitable for small and medium-sized watersheds, which are frequently encountered in the mining dam sector. The models analyzed in this work include both conceptual approaches, such as SCS, SMAP, SAC-SMA, and SWAT, and machine learning techniques, such as MLP, Random Forest, XGBoost, CNN, and LSTM. Among the evaluated models, it was considered that the choice of model should be aligned with the study's objective, the

1) HIDROBR – [ana.becker@hidrobr.com](mailto:ana.becker@hidrobr.com) - (31) 3504-2733 – Av. Brasil, nº 888, 14º e 15º andar, Belo Horizonte – MG.

2) HIDROBR – [felipe.ribeiro@hidrobr.com](mailto:felipe.ribeiro@hidrobr.com) - (31) 3504-2733 – Av. Brasil, nº 888, 14º e 15º andar, Belo Horizonte – MG.

3) HIDROBR – [daniel.dourado@hidrobr.com](mailto:daniel.dourado@hidrobr.com) - (31) 3504-2733 – Av. Brasil, nº 888, 14º e 15º andar, Belo Horizonte – MG.

4) HIDROBR – [stella.andrade@hidrobr.com](mailto:stella.andrade@hidrobr.com) - (31) 3504-2733 – Av. Brasil, nº 888, 14º e 15º andar, Belo Horizonte – MG.

watershed characteristics, and the quality of the available data. More detailed models require a greater amount of information and technical knowledge to be applied consistently. On the other hand, simpler models may meet the needs of preliminary analyses or less complex watersheds.

**Palavras-Chave:** Barragens de mineração, calibração de modelos hidrológicos, aprendizado de máquina.

## 1. INTRODUÇÃO

No contexto da hidrologia aplicada à mineração, visando a segurança de barragens, a aplicação de modelos hidrológicos é uma das etapas que antecede o trânsito de cheias para a verificação da segurança de estruturas. Tradicionalmente, essa etapa é realizada por meio da aplicação do modelo SCS – Soil Conservation Service (atual NRCS – Natural Resources Conservation Service), conhecido por apresentar resultados de vazão conservadores para a realidade brasileira (Cunha et al, 2015). No entanto, as resoluções ANM nº 95/2022 e ANM nº 220/2025 preveem a calibração de modelos hidrológicos, o que deve tornar essa verificação de segurança de barragens mais assertiva: de acordo com o §5º do Artigo 24 da Resolução ANM nº 95/2022, “o empreendedor deve calibrar os dados das bacias e das sub-bacias de sua barragem com dados obtidos de instrumentos com tempo suficiente para calibração visando o adequado dimensionamento dos vertedouros com dados reais, compreendendo 2 (dois) ciclos hidrológicos com eventos de máxima significativos”. Essa determinação norteia a necessidade de maior compreensão de modelos hidrológicos aplicados nesse contexto, considerando a necessidade de calibração. A Resolução ANM nº 220/2025, prevê, por sua vez, que essa calibração deve ocorrer para barragens de mineração que realizarão o reforço da estrutura.

O presente estudo tem como objetivo apresentar a instrumentação necessária para esse processo visando o cumprimento da legislação, bem como explorar as características de modelos hidrológicos aplicáveis a bacias pequenas e médias, que são comumente presentes no contexto de barragens de mineração.

A Figura 1 representa esquematicamente os passos necessários para o atendimento das resoluções ANM nº 95/2022 e ANM nº 220/2025.

Figura 1 – Fluxograma para atendimento do §5º do Artigo 24 da Resolução ANM nº 95/2022.



Os modelos explorados nesse trabalho englobaram modelos conceituais, como SCS (Soil Conservation Service), SMAP (Soil Moisture Accounting Procedure), SAC-SMA (Sacramento Soil Moisture Accounting Model), SWAT (Soil and Water Assessment Tool) e modelos de aprendizado de máquina, como MLP (Multilayer Perceptron), RF (Random Forest), XGBoost (Extreme Gradient Boosting), CNN (Convolutional Neural Networks) e LSTM (Long Short-Term Memory).

Os modelos hidrológicos conceituais buscam integrar os diferentes conceitos e processos que estão envolvidos no ciclo hidrológico. Tucci (2005) aponta que os aspectos mais importantes no uso e na estruturação dos modelos hidrológicos são: os objetivos da utilização do modelo, as limitações do modelo na representação dos processos e a qualidade e quantidade das informações utilizadas em

conjunto com o modelo. Os aspectos listados ressaltam a importância de associar a aplicação de modelos hidrológicos à disponibilidade de dados e ao monitoramento das bacias hidrográficas.

Adicionalmente, modelos de aprendizado de máquina foram incluídos no estudo considerando a recente evolução da temática na área de recursos hídricos. A partir de 2018, observou-se um crescimento exponencial nas aplicações de ML para problemas na hidrologia, principalmente utilizando redes neurais artificiais, árvores de decisão e modelos híbridos (Hasan et. al., 2024). Detzel et al. (2021), conduziram uma revisão bibliográfica sistemática com o objetivo de avaliar o uso de aprendizado de máquina em estudos hidrológicos no Brasil, revelando que 75% dos trabalhos brasileiros publicados até maio de 2021 focaram na aplicação de técnicas de ML para a previsão de variáveis hidrológicas e 23% de todos os trabalhos se concentram no ano de 2023, o que evidencia a popularização no uso da tecnologia aplicada na área de recursos hídricos.

## 2. INSTRUMENTAÇÃO E ENSAIOS PARA MONITORAMENTO VISANDO A CALIBRAÇÃO DE MODELOS HIDROLÓGICOS

O monitoramento da bacia hidrográfica associada à barragem de mineração é uma etapa essencial para a calibração de modelos hidrológicos. Os principais instrumentos necessários são o pluviógrafo e o linígrafo. É importante ressaltar que a discretização temporal recomendada para a coleta de dados desses equipamentos deve possibilitar que as cheias sejam devidamente registradas ao longo de sua duração. Para isso, adota-se a discretização recomendada para hietogramas de 1/5 do tempo de concentração ou de 1/3 do tempo de pico, conforme indicado por Tucci (2005).

A discretização espacial ao longo da bacia hidrográfica também é recomendada para a instalação dos pluviômetros. Idealmente, os equipamentos podem ser distribuídos por áreas de diferentes declividades, uso e ocupação do solo, sem deixar de considerar a exequibilidade e a delimitação da área do empreendedor.

Complementarmente, a instalação de Tanques Classe A para a mensuração diária de evaporação também pode fazer com que a calibração do modelo seja mais assertiva, visto que a parcela de água evaporada passaria a ser englobada pelo modelo. Essa variável também pode ser obtida por meio da estação meteorológica completa: a partir dos dados de temperatura e umidade relativa, é possível aplicar o método de Hargreaves para obter a evapotranspiração potencial.

A Tabela 1 apresenta a instrumentação indicada para a calibração de modelos hidrológicos.

Tabela 1 – Instrumentação indicada para a calibração de modelos hidrológicos

Variável mensurada	Instrumento	Quantidade	Recomendações para a instalação
Precipitação (mm)	Pluviógrafo ou estação meteorológica completa	Bacias de até 5 km <sup>2</sup> : 1 unidade 5 km <sup>2</sup> a 10 km <sup>2</sup> : 2 unidades >10 km <sup>2</sup> : 2 ou mais unidades  (distribuir os instrumentos por áreas de diferentes declividades, uso e ocupação do solo e tipo de solo, considerando a exequibilidade e a delimitação da área do empreendedor)	Altura: 1,50 m Distância de obstáculos: 3 m ou a uma angulação de 30° a 45° com a horizontal (BLAINSKI, 2012). Discretização dos registros: 1/5 do tempo de concentração (TUCCI, 2005)

Variável mensurada	Instrumento	Quantidade	Recomendações para a instalação
Temperatura (°C), umidade relativa (%), pressão (mb) e velocidade do vento (m/s)	Estação meteorológica completa	1 unidade (próxima ao reservatório)	Altura: 1,50 m Distância de obstáculos: 3 m ou a uma angulação de 30° a 45° com a horizontal (BLAINSKI, 2012).
Nível de água no reservatório (m)	Linígrafo	1 por reservatório	Longe do vertedor para que a medida não seja influenciada pela velocidade da água Atenção para o local (variações de NA) Discretização dos registros: 1/5 do tempo de concentração (TUCCI, 2005)
Evaporação (mm/dia)	Tanque Classe A com leitor automatizado	Perto da estação meteorológica/pluviógrafo 1 por reservatório Caso os reservatórios sejam próximos, manter 1 para todos	Seguindo instruções específicas, por exemplo: Sondaterra (2025)

Adicionalmente, é desejável a realização de ensaios de perfil de solo e de infiltração para a determinação da condutividade hidráulica. A determinação dos locais para a realização desses ensaios deve considerar, além do uso e ocupação do solo, a análise do mapa do tipo de solo, como por exemplo o de EMBRAPA (2020), e identificação de áreas de possível incerteza quanto à classificação. A permeabilidade intrínseca ( $k$ ) depende das dimensões e da geometria e organização interna dos poros do solo. Esta se relaciona com a condutividade hidráulica ( $K$ ) pela Equação 1 (TUCCI, 2001), onde  $\rho$  é a massa específica da água (0,998202 g/cm<sup>3</sup>),  $g$  é aceleração da gravidade (9,81 m/s<sup>2</sup>) e  $\mu$  é a viscosidade dinâmica da água (1,0016 mPa·s);

$$K = k \frac{\rho g}{\mu} \quad (1)$$

Com o ensaio de permeabilidade também é possível entender qual o tipo de solo predominante, conforme Tabela 2 (DAS, 2007).

Tabela 2 – Associação do resultado de permeabilidade com o tipo de solo predominante

Tipo de Solo	Diâmetro dos Grãos (mm)	Permeabilidade (k) (cm/s)	Classificação de Permeabilidade
Pedregulho (Graúdo)	> 20	10 <sup>0</sup> – 10 <sup>2</sup> (1 – 100)	Muito Alta
Areia Grossa	2 – 0,6	10 <sup>-2</sup> – 10 <sup>0</sup> (0,01 – 1)	Alta
Areia Fina	0,6 – 0,2	10 <sup>-3</sup> – 10 <sup>-2</sup> (0,001 – 0,01)	Moderada
Silte	0,06 – 0,002	10 <sup>-5</sup> – 10 <sup>-3</sup> (0,00001 – 0,001)	Baixa
Argila	< 0,002	< 10 <sup>-5</sup> (< 0,00001)	Muito Baixa

### 3. MODELOS AVALIADOS

Esse item apresenta as principais características dos modelos avaliados nesse trabalho: SCS (Soil Conservation Service), SMAP (Soil Moisture Accounting Procedure), SAC-SMA (Sacramento

Soil Moisture Accounting Model), SWAT (Soil and Water Assessment Tool) e modelos de Machine Learning (ML) como MLP (Multilayer Perceptron), RF (Random Forest), XGBoost (Extreme Gradient Boosting), CNN (Convolutional Neural Networks) e LSTM (Long Short-Term Memory).

### 3.1. SCS (Soil Conservation Service)

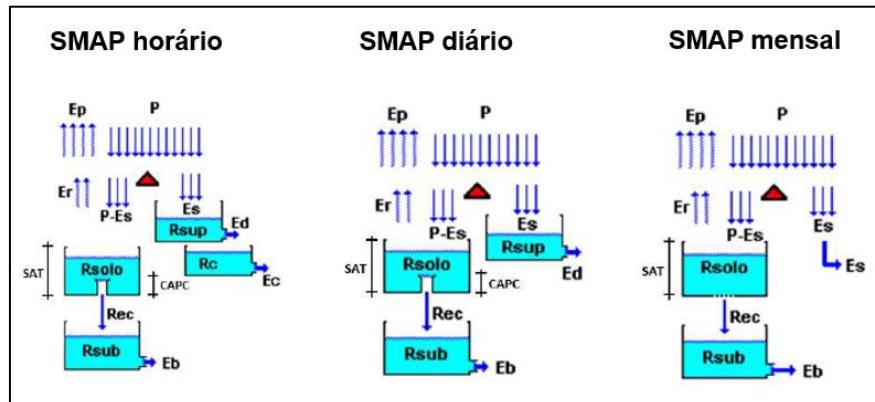
Desenvolvido pelo Soil Conservation Service dos EUA (SCS, 1956), atual NRCS - Natural Resources Conservation Service, o modelo SCS é amplamente utilizado para estimativa de runoff em bacias hidrográficas. Esse modelo se baseia no parâmetro CN, definido com base nas características do solo, uso da terra e umidade antecedente. O modelo calcula o escoamento a partir da precipitação e da retenção potencial do solo. Singh et al. (2023) apontam que uma das limitações do modelo é não levar em conta, de forma contínua, o teor de umidade no solo, o que pode fazer com que alterações na consideração de umidade antecedente dentro do parâmetro CN possam induzir variações significativas no escoamento. Portanto, embora o modelo SCS seja simples e eficiente, com baixa demanda de dados, o modelo não detalha processos hidrológicos complexos, tais como escoamento subterrâneo e evapotranspiração, sendo mais adequado para bacias pequenas e homogêneas. Mesmo para tais casos, Singh et al. (2023) ressaltam a importância da escolha, dentre as diversas variações do modelo, de um método adequado para a simulação do escoamento.

### 3.2. SMAP (Soil Moisture Accounting Procedure)

O SMAP foi concebido para simulação contínua do balanço hídrico, representando processos como infiltração, evapotranspiração e escoamento superficial/subterrâneo. Esse modelo é amplamente utilizado no setor elétrico brasileiro (ONS, 2005), aplicado a grandes bacias hidrográficas. No entanto, por ser um modelo simplificado e de moderada facilidade de aplicação, é uma válida alternativa para bacias pequenas e médias, visto que esse modelo tem o diferencial de considerar o escoamento subterrâneo em simulações contínuas, ao contrário do SCS, por exemplo.

O modelo SMAP é estruturado em camadas de solo, simuladas por meio de unidades distintas denominadas “reservatórios subterrâneos”, conforme ilustrado pela Figura 2. A quantidade de reservatórios a serem considerados varia conforme a discretização temporal adotada para a simulação (WERLANG, 2001). Em bacias menores, por conta da necessidade de discretização temporal mais detalhada, conforme visto no item 2, recomenda-se o uso da versão horária do modelo, com mais reservatórios conceituais.

Figura 2 – Variações conceituais do modelo SMAP com base na discretização temporal. Fonte: Werlang (2021).



### 3.3. SAC-SMA (Sacramento Soil Moisture Accounting Model)

Criado pelo National Weather Service (NWS) dos EUA, o SAC-SMA (Sacramento Soil Moisture Accounting) é um modelo hidrológico concentrado (WMO, s.d.) que simula o balanço de

água no solo, dividindo-o em duas zonas principais (superior e inferior) para representar os processos de armazenamento e escoamento da água, permitindo estimar a vazão em corpos hídricos a partir de dados de precipitação e evapotranspiração (WERKHOVEN et al., 2008).

O referido modelo pode ser aplicado em diferentes tipos de bacias, tendo mostrado bom desempenho em diversas regiões (WERKHOVEN et al., 2008; WIJAYARATHNE; COULIBALY, 2020). Reconhecido por sua precisão operacional, o SAC-SMA é amplamente utilizado em sistemas de previsão de cheias (LIMA et al., 2024; WIJAYARATHNE; COULIBALY, 2020).

### 3.4. SWAT (Soil and Water Assessment Tool)

Desenvolvido pelo USDA (Departamento de Agricultura dos Estados Unidos), o SWAT é um modelo conceitual semi-distribuído que pode ser aplicado em diferentes escalas e adaptado para múltiplos propósitos. O modelo SWAT divide a bacia em sub-bacias e unidades hidrológicas (HRUs), simulando processos como evapotranspiração, infiltração, escoamento superficial, transporte de sedimentos e nutrientes (ALOUI et al., 2023; JANJIĆ; TADIĆ, 2023; DWIVEDI, et al., 2024).

### 3.5. RF (Random Forest) e XGBoost (Extreme Gradient Boosting)

O Random Forest (Floresta Aleatória) é um algoritmo baseado em múltiplas árvores de decisão, combinadas por meio de agregação e seleção aleatória de features para predição da variável objetivo (BREIMAN, 2001). O XGBoost (eXtreme Gradient Boosting) é um algoritmo avançado que combina iterativamente modelos fracos (geralmente árvores de decisão rasas) para formar um preditor robusto (CHEN; GUESTRIN, 2016). Em ambos os algoritmos a quantidade do ajuste está diretamente ligada a quantidade dados disponíveis.

### 3.6. MLP (Multilayer Perceptrons), CNN (Redes Neurais Convolucionais) e LSTM (Long Short-Term Memory)

Multilayer Perceptrons (MLP), Redes Neurais Convolucionais (CNN) e Long Short-Term Memory (LSTM) são diferentes arquiteturas de Redes Neurais Artificiais, amplamente utilizadas em problemas de modelagem e predição. Essas redes são capazes de captar padrões e relações complexas entre as variáveis, possibilitando a realização de previsões precisas das variáveis objetivo, mesmo em cenários caracterizados por alta variabilidade e não linearidade (TAKALE et al., 2024).

## 4. COMPARAÇÃO E DISCUSSÃO

Os modelos apresentados no item anterior foram categorizados conforme a complexidade, número de parâmetros físicos, dados mínimos de entrada, discretização temporal e temporalidade. A Tabela 3 apresenta o resumo das principais características avaliadas.

O modelo SCS se diferencia dos demais por sua simplicidade. Entre os modelos avaliados, esse é o que apresentou menor número de parâmetros. A aplicação desse modelo é mais indicada em casos de escassez de dados, tendo em vista que, nessas situações, um número extensivo de parâmetros pode apenas adicionar mais incertezas ao processo de modelagem. No entanto, por ter menos parâmetros, sua calibração tende a ser mais complexa, tendo em vista que os parâmetros podem acabar perdendo seu significado físico no processo de calibração. Em um caso em que a calibração indique que o CN precise ser alterado para um número que seja incompatível com o tipo e uso do solo, vale a pena refletir se um modelo que considere o fluxo de base poderia ser mais indicado. O SMAP, o SAC-SMA e o SWAT consideram esse processo. Entre eles, o SMAP foi o que apresentou menos parâmetros, seguido pelo SAC-SMA.

Tabela 3 – Comparaçao exploratória das características de modelos hidrológicos avaliados.

Modelo	Complexidade	Número de parâmetros físicos	Dados mínimos de entrada	Discretização de dados de entrada	Temporalidade
SCS	Simples	2 parâmetros (CN, Lagtime) 1 parâmetro de inicialização (Abs. Inic.)	Precipitação	Dias, horas, minutos	Eventos isolados
SMAP	Moderada	6 parâmetros 3 parâmetros de inicialização	Precipitação e evapotranspiração	Diária ou horária	Simulação contínua
SAC-SMA	Moderada	13 parâmetros	Precipitação e evapotranspiração	Diária ou horária	Simulação contínua
SWAT	Alta	Extensiva quantidade de parâmetros	Precipitação, umidade, insolação, temperatura, vento, uso e ocupação do solo e parâmetros do solo	Diária ou horária	Simulação contínua
XGBoost e RF	Moderada	Parâmetros ajustados de forma iterativa	Precipitação, vazão	Ajustável	Simulação contínua
MLP, CNN e LSTM	Alta	Parâmetros ajustados de forma iterativa	Precipitação, vazão	Ajustável	Simulação contínua

O modelo SWAT, por sua vez, requer grande quantidade e qualidade de dados de entrada (clima, solo, uso do solo, topografia), o que pode limitar sua aplicação em regiões com dados escassos ou de baixa resolução. Outro ponto de atenção em relação ao SWAT é o custo computacional, tendo em vista que o modelo lida com maior diversidade e complexidade de parâmetros, o que pode aumentar a necessidade de tempo e equipamentos para o desenvolvimento do modelo.

Modelos de ML baseados em árvores, como o Random Forest e o XGBoost, são técnicas de aprendizado de máquina supervisionado utilizadas pela capacidade de capturar relações não lineares e realizar classificações e regressões de forma eficiente. Por outro lado, redes neurais artificiais, como os MLPs, CNNs e LSTMs, possuem grande capacidade de generalização. Enquanto MLPs são redes totalmente conectadas, aplicáveis a dados tabulares e problemas gerais, as CNNs se destacam na análise de dados espaciais. As LSTMs, por sua vez, são especialmente eficazes no tratamento de dados sequenciais e séries temporais. Embora existam diferenças estruturais e operacionais entre os métodos baseados em árvores e redes neurais, ambos são amplamente aplicados na área de recursos hídricos para tarefas de predição e classificação.

Vale ressaltar que modelos de aprendizado de máquina são facilmente adaptáveis para a inclusão de mais parâmetros além dos descritos, como é o caso de Rehman et al. (2019), que consideraram também a temperatura no modelo. No entanto, considerou-se a precipitação e a vazão como dados mínimos de entrada, visto que a precipitação é a variável mais sensível para a variabilidade da vazão (variável resposta), conforme apontado por Rehman et al. (2019).

Cada um dos modelos de aprendizado de máquina apresenta especificidades vantajosas para a modelagem hidrológica, seja na capacidade de lidar com dados complexos, de capturar dependências temporais em séries temporais ou na flexibilidade para modelar relações não lineares. Zamboni et al. (2023), por exemplo, indicaram que o LSTM, especialmente na abordagem regional, superou significativamente o modelo convencional, demonstrando ser uma ferramenta promissora para a previsão de vazões e compreensão dos processos hidrológicos no Brasil. Portanto, a escolha entre

modelos conceituais de base física e modelos de aprendizado de máquina depende das características específicas da bacia hidrográfica e a periodicidade e discretização dos dados disponíveis.

## 5. CONSIDERAÇÕES FINAIS

A necessidade de calibração de modelos hidrológicos, conforme definido pela resoluções ANM nº 95/2022 e ANM nº 220/2025, reforça a importância da coleta de dados em campo para garantir maior representatividade dos processos simulados. A utilização de pelo menos dois ciclos hidrológicos com eventos significativos permite que a resposta da bacia seja melhor compreendida, contribuindo para a definição de parâmetros mais próximos da realidade.

Neste trabalho, foram apresentadas as principais ferramentas de instrumentação necessárias à calibração, com destaque para a distribuição espacial e temporal dos dados. Também foram discutidos diferentes modelos hidrológicos, desde os mais simples e amplamente utilizados, como o SCS, até modelos contínuos, como SMAP, SAC-SMA e SWAT. Modelos baseados em dados, como os de aprendizado de máquina também foram considerados, especialmente quando há disponibilidade de séries históricas extensas.

A escolha do modelo deve estar alinhada ao objetivo do estudo e à qualidade dos dados disponíveis. Modelos mais detalhados exigem maior quantidade de informações, monitoramento da bacia e conhecimento técnico para serem aplicados de forma consistente. Por outro lado, modelos mais simples podem atender a análises preliminares ou a bacias com menor complexidade.

O alinhamento entre os dados coletados, os ensaios em campo e a escolha do modelo é essencial para que os estudos atendam às exigências normativas e apoiem decisões mais seguras. A adoção dessa abordagem, além de cumprir com a legislação vigente, permite melhorar a compreensão do comportamento hidrológico das bacias no contexto da mineração.

## REFERÊNCIAS

- ALOUI, S ; MAZZONI, A.; ELOMRI, A.; AOUSSI, J.; BOUFEKANE, A.; ZGHIBI, A.. (2023). "A review of Soil and Water Assessment Tool (SWAT) studies of Mediterranean catchments: Applications, feasibility, and future directions". Journal of environmental management, 326 Pt B, 116799 . Disponível em: <<https://doi.org/10.1016/j.jenvman.2022.116799>>. Acesso em: jun. 2025.
- BREIMAN, L. "Random Forests". (2001), v. 45, p. 5–32.
- BLAINSKI, E; GARBOSSA, L. H. P.; ANTUNES, E. N. (2012). "Estações hidrometeorológicas automáticas: recomendações técnicas para instalação". Florianópolis: Epagri.
- BRASIL. AGÊNCIA NACIONAL DE MINERAÇÃO – ANM. "Resolução ANM nº 95, de 07 de fevereiro de 2022. Consolida os atos normativos que dispõem sobre segurança de barragens de mineração ". (2022). Diário Oficial da União, Brasília, DF, Edição 33, seção 1, p. 49, 16 fev. 2022.
- BRASIL. AGÊNCIA NACIONAL DE MINERAÇÃO – ANM. "Resolução ANM nº 220, de 16 de outubro de 2025. Estabelece a disciplina aplicável às barragens de mineração ". (2025). Diário Oficial da União, Brasília, DF, Edição 199, seção 1, p. 43, 17 out. 2025.
- CHEN, T.; GUESTRIN, C. (2016). "XGBoost: A Scalable Tree Boosting System ". In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining.
- CUNHA, S. F.; SILVA, F. E. O.; MOTA, T. U.; PINHEIRO, M.C. (2015). "Avaliação da acurácia dos métodos do SCS para cálculo da precipitação efetiva e hidrogramas de cheia ". Revista Brasileira de Recursos Hídricos. Vol 20, nº 24. p. 837-848.
- DAS, B. M. (2007). "Fundamentos de Engenharia Geotécnica ". São Paulo.
- DETZEL, D. H. M.; MOURA, C. N.; CARVALHO, J. M.; RANGEL, L. A. (2021). "O uso de aprendizado de máquina em estudos hidrológicos no Brasil." In: XXIV Simpósio Brasileiro de Recursos Hídricos, Belo Horizonte – MG.
- DWIVEDI, S.; KOTHARI, M.; SINGH, P.; CHHIPA, B.; GUPTA, T. (2024). "SWAT model applications in hydrology: A systematic review ". International Journal of Advanced Biochemistry Research. Disponível em: <<https://doi.org/10.33545/26174693.2024.v8.i7sh.1596>>. Acesso em: jun. 2025.
- EMBRAPA. (2020). "Distribuição geográfica dos solos do Brasil". Disponível em: <[http://geoinfo.cnps.embrapa.br/layers/geonode%3Abrazil\\_solos\\_5m\\_20201104](http://geoinfo.cnps.embrapa.br/layers/geonode%3Abrazil_solos_5m_20201104)>. Acesso em: 22 mar 2024.
- HASAN, F.; MEDLEY, P. DRAKE, J. CHEN, G. (2024). "Advancing Hydrology through Machine Learning: Insights, Challenges, and Future Directions Using the CAMELS, Caravan, GRDC, CHIRPS, PERSIANN, NLDAS, GLDAS, and GRACE Datasets ". Water, v. 16, n. 13, p. 1904.
- JANJIĆ, J.; TADIĆ, L. (2023). "Fields of Application of SWAT Hydrological Model - A Review". Earth. Disponível em: <<https://doi.org/10.3390/earth4020018>>. Acesso em: jan. 2025.
- LIMA, M. F. D. S.; FERREIRA, D. M.; GONÇALVES, J.E.; PARANHOS, C. S. A.; PEREIRA, R. S. M. (2024). "Sistema de Previsão Hidrológica para o Rio Iguaçu, União da Vitória - PR ". in Anais do IV Encontro Nacional de Desastres, Curitiba, 2024.
- OPERADOR NACIONAL DO SISTEMA ELÉTRICO – ONS. (2005). "Revisão das séries de vazões naturais em bacias do Sistema Interligado Nacional". Disponível em: <[https://www.ons.org.br/sites/multimidia/Documentos%20Compartilhados/vazoes\\_naturais/2005/7-5.html](https://www.ons.org.br/sites/multimidia/Documentos%20Compartilhados/vazoes_naturais/2005/7-5.html)>. Acesso em: jun. 2025.

- REHMAN, S.; YANG, Z.; SHAHID, M.; WEI, N.; HUANG, Y.; WAQAS, M.; TU, S.; REHMAN, O. (2019). “*Water Preservation in Soan River Basin Using Deep Learning Techniques*”.
- SINGH, H.; ALAM, M. A.; SHARMA, P. J.; RAUTELA, K. S. (2023). “*A comparison of the SCS-CN-based models for hydrological simulation of the Aghanashini River, Karnataka, India*”. AQUA Water Infrastructure, Ecosystems and Society. IWA Publishing.
- SOIL CONSERVATION SERVICE - SCS. (1956). “*Hydrology: National Engineering Handbook*”, Supplement A, Section 4.
- SONDATERRA. (2025) “*Manual de instrução: Tanque Classe A*”. Disponível em: <[https://www.sondaterra.com/upload/banco\\_imagens/files/tanq.pdf](https://www.sondaterra.com/upload/banco_imagens/files/tanq.pdf)>. Acesso em: mar/25.
- TAKALE, D.; WATTAMWAR, A. A.; SAIPATWAR, S. S., SAINDANE, H. V.; PATIL, T. B. (2024). “Comparative Analysis of LSTM, RNN, CNN and MLP Machine Learning Algorithms for Stock Value Prediction”
- TUCCI, C. E. M. (2001). “*Hidrologia: Ciência e Aplicação*”. 2 ed.
- TUCCI, C. E. M. (2005). “*Modelos Hidrológicos*”. 2 ed. Porto Alegre: Editora da UFRGS.
- WERKHOVEN, K.; WAGENER, T.; REED, P.; TANG, Y. (2008). “*Characterization of watershed model behavior across a hydroclimatic gradient*”. Water Resources Research, 44. Disponível em: <<https://doi.org/10.1029/2007WR006271>>.
- WERLANG, M. M. (2021). “*Desenvolvimento de um sistema simplificado para previsões probabilísticas de afluências ao reservatório da UHE Itaipu*”. Dissertação (mestrado) apresentada ao Programa de Pós Graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais. Belo Horizonte – MG, 2021.
- WIJAYARATHNE, D.; COULIBALY, P. (2020). “*Identification of hydrological models for operational flood forecasting in St. John’s, Newfoundland, Canada*”. Journal of Hydrology: Regional Studies, 27, 100646. Disponível em: <<https://doi.org/10.1016/j.ejrh.2019.100646>>.
- WORLD METEOROLOGICAL ORGANIZATION – WMO. (s.d.) “*Sacramento Soil Moisture Accounting Model (SAC-SMA)*”. Disponível em: <<https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKEwiXkofM3oWOAxXSq5UCHQqWLXMQFnoECBoQAQ&url=https%3A%2F%2Fetrp.wmo.int%2Fmod%2Fresource%2Fview.php%3Fid%3D14343&usg=AOvVaw2Y7dOEcAtSEtnaz51XcTda&opi=89978449>>. Acesso em: jun/2025.
- ZAMBONI, P. A; ALMAGRO, A, GONÇALVES, W. N., PAES, J. L. A. R., OLIVEIRA, P. T. S (2023). “*Inteligência Artificial na Modelagem Hidrológica Brasileira: Uma Abordagem Regional*.” In: XXV Simpósio Brasileiro De Recursos Hídricos. Aracaju, 2023.

## AGRADECIMENTOS

Os autores agradecem à HIDROBR pelo apoio na publicação.