

AVALIAÇÃO COMPARATIVA DE MODELOS CLÁSSICOS E QUÂNTICOS HÍBRIDOS PARA PREVISÃO MULTIHORIZONTE DO NÍVEL DO RIO EM ÓBIDOS

COMPARATIVE EVALUATION OF CLASSICAL AND HYBRID QUANTUM
MODELS FOR MULTIHORIZON FORECASTING OF RIVER LEVEL IN ÓBIDOS

Ciências Exatas e da Terra, Engenharias • 15/06/2026

REGISTRO DOI: [10.70773/revistatopicos/781499748](https://doi.org/10.70773/revistatopicos/781499748)

Isabela Andrade Aguiar¹

Hendrio Luis de Souza Bragança²

Jean Mark Lobo de Oliveira³

RESUMO

Este trabalho avalia comparativamente o desempenho de modelos clássicos de aprendizado de máquina e de um modelo quântico híbrido simulado na previsão multihorizonte do nível do rio Amazonas em Óbidos. A pesquisa utiliza série histórica diária da estação fluviométrica 17050001, disponibilizada pela Agência Nacional de Águas e Saneamento Básico, abrangendo dados de 1970 a 2024. Foram considerados horizontes de 1, 7, 14, 30 e 90 dias, com construção de variáveis defasadas, estatísticas móveis e atributos sazonais. A comparação envolveu Persistência, Ridge Regression, Random Forest, XGBoost, Ridge compacto e um modelo híbrido baseado em circuito quântico simulado, cujas saídas foram utilizadas por um regressor Ridge. A avaliação foi realizada por métricas estatísticas e hidrológicas, incluindo MAE, RMSE, BIAS, NSE e KGE, além de indicadores associados às classes de seca e cheia. Os resultados indicaram que os modelos clássicos apresentaram melhor desempenho geral, com Ridge superior nos horizontes de 1, 7 e 14 dias, Random Forest em 30 dias e XGBoost em 90 dias. O modelo QML híbrido não superou os melhores modelos clássicos, mas apresentou desempenho superior à persistência em horizontes maiores, o que permite sua discussão como abordagem experimental. Conclui-se que, para a base avaliada e a arquitetura adotada, modelos clássicos permanecem mais adequados para previsão operacional, enquanto o QML exige investigação adicional quanto à codificação de atributos, arquitetura e custo computacional.

Palavras-chave: Previsão hidrológica; aprendizado de máquina; QML; rio Amazonas; Óbidos.

ABSTRACT

This study compares the performance of classical machine learning

models and a simulated hybrid quantum model for multihorizon forecasting of the Amazon River level at Óbidos. The research uses daily historical records from the fluviometric station 17050001, made available by the Brazilian National Water and Sanitation Agency, covering the period from 1970 to 2024. Forecast horizons of 1, 7, 14, 30 and 90 days were considered, with lagged variables, moving statistics and seasonal attributes. The comparison included Persistence, Ridge Regression, Random Forest, XGBoost, a compact Ridge model and a hybrid model based on a simulated quantum circuit, whose outputs were used by a Ridge regressor. Model performance was assessed using statistical and hydrological metrics, including MAE, RMSE, BIAS, NSE and KGE, as well as indicators related to drought and high-water classes. The results showed that classical models achieved the best overall¹ performance, with Ridge performing best for 1-, 7- and 14-day horizons, Random Forest for 30 days,

and XGBoost for 90 days. The hybrid QML model did not outperform the best classical models, although it performed better than persistence for longer horizons, supporting its discussion as an experimental approach. The study concludes that, for the evaluated dataset and architecture, classical models remain more suitable for operational forecasting, while QML requires further investigation regarding feature encoding, architecture and computational cost.

Keywords: Hydrological forecasting; machine learning; QML; Amazon River; Óbidos.

1. INTRODUÇÃO

A previsão hidrológica é uma atividade relevante para o acompanhamento de regimes fluviais, para a gestão de riscos associados a extremos hidrológicos e para o planejamento de usos

da água. A Organização Meteorológica Mundial apresenta a verificação de previsões hidrológicas como parte necessária para avaliar acurácia, confiabilidade e utilidade de sistemas preditivos, especialmente quando esses sistemas subsidiam decisões públicas ou operacionais (WMO, 2025). No contexto brasileiro, a Agência Nacional de Águas e Saneamento Básico mantém o sistema HidroWeb, que disponibiliza séries históricas de estações hidrometeorológicas, incluindo dados fluviométricos usados em estudos de monitoramento e previsão (ANA, 2026a).

A estação de Óbidos, identificada no HidroWeb pelo código 17050001, constitui um ponto de grande interesse para estudos hidrológicos da bacia Amazônica. Estudos científicos sobre a variabilidade de descarga do rio Amazonas em Óbidos destacam a relevância dessa seção de monitoramento por representar uma ampla área de drenagem da bacia (CALLÈDE et al., 2003). Pesquisas climato-hidrológicas também utilizam dados de Óbidos para caracterizar o comportamento do rio Amazonas e eventos como secas hidrológicas (MARENGO et al., 2008).

Nos últimos anos, modelos de aprendizado de máquina passaram a ser empregados em problemas de previsão hidrológica por sua capacidade de capturar relações não lineares em dados ambientais. Revisões recentes indicam que técnicas de aprendizado de máquina têm sido exploradas em diferentes tarefas de modelagem hidrológica, mas também ressaltam que a avaliação deve ser conduzida com métricas adequadas, bases temporais bem separadas e comparação contra modelos de referência (PAPACHARALAMPOUS; TYRALIS, 2022). Ao mesmo tempo, o aprendizado de máquina quântico tem sido proposto como campo emergente que busca explorar espaços de Hilbert e circuitos

parametrizados em tarefas de aprendizado supervisionado (BIAMONTE et al., 2017; HAVLÍČEK et al., 2019; SCHULD; KILLORAN, 2019).

A proposta deste trabalho é avaliar, em uma mesma base hidrológica, modelos clássicos e um modelo quântico híbrido simulado para previsão do nível do rio em Óbidos. O termo “híbrido” é utilizado porque o circuito quântico simulado atua como etapa de transformação de características, enquanto a predição final é realizada por um regressor clássico. Essa formulação evita tratar o QML como solução superior por princípio e permite uma análise mais controlada dos seus resultados frente a modelos consolidados, como Ridge, Random Forest e XGBoost.

1.1. Problema de Pesquisa

O problema de pesquisa é formulado da seguinte forma: como modelos clássicos de aprendizado de máquina e um modelo quântico híbrido simulado se comportam na previsão multihorizonte do nível do rio Amazonas em Óbidos, considerando diferentes horizontes temporais de previsão?

1.2. Questão Norteadora e Hipótese

A questão norteadora é: modelos clássicos de aprendizado de máquina apresentam desempenho mais consistente que um modelo quântico híbrido simulado na previsão multihorizonte do nível do rio em Óbidos? A hipótese adotada é que modelos clássicos, especialmente Ridge, Random Forest e XGBoost, tendem a apresentar desempenho superior ao modelo quântico híbrido simulado para a base avaliada, devido à natureza tabular da série, à

forte autocorrelação temporal de curto prazo e à maior maturidade metodológica desses algoritmos em problemas de regressão.

1.3. Objetivo Geral

Avaliar comparativamente o desempenho de modelos clássicos de aprendizado de máquina e de um modelo quântico híbrido simulado na previsão do nível do rio Amazonas em Óbidos.

1.4. Objetivos Específicos

Os objetivos específicos são: organizar e caracterizar a série histórica diária da estação Óbidos; construir atributos temporais baseados em defasagens, médias móveis e sazonalidade; treinar modelos de Persistência, Ridge, Random Forest, XGBoost, Ridge compacto e QML híbrido; avaliar os modelos em horizontes de 1, 7, 14, 30 e 90 dias; comparar os resultados por MAE, RMSE, BIAS, NSE e KGE; analisar o comportamento dos modelos em classes associadas à seca e à cheia; e discutir limitações metodológicas do QML simulado no contexto estudado.

1.5. Justificativa

A justificativa regional decorre da importância do monitoramento hidrológico do rio Amazonas, especialmente em seções estratégicas como Óbidos. A justificativa técnica está associada à necessidade de comparar modelos de previsão por horizonte, pois a qualidade da previsão tende a variar conforme o tempo de antecedência. A justificativa científica está na avaliação crítica de modelos clássicos e de uma abordagem quântica híbrida simulada, em uma aplicação hidrológica concreta. Essa escolha é relevante porque a literatura de QML ainda recomenda cautela na comparação com métodos

clássicos e na interpretação de possíveis vantagens computacionais ou preditivas (BIAMONTE et al., 2017; HAVLÍČEK et al., 2019).

2. FUNDAMENTAÇÃO TEÓRICA OU REVISÃO DA LITERATURA

2.1. Monitoramento Hidrológico e a Estação de Óbidos

O monitoramento fluviométrico permite acompanhar variações de nível e vazão em rios, constituindo base para estudos hidrológicos e para verificação de modelos de previsão. No Brasil, o HidroWeb, vinculado ao Sistema Nacional de Informações sobre Recursos Hídricos, disponibiliza séries históricas de estações hidrometeorológicas, sendo uma fonte institucional adequada para estudos baseados em dados observados (ANA, 2026a).

A estação de Óbidos é utilizada em estudos sobre a variabilidade do rio Amazonas por estar localizada em uma seção de grande representatividade hidrológica. Callède et al. (2003) descrevem a seção de Óbidos como uma estação de referência para análise da descarga do Amazonas e indicam ampla área de drenagem associada a esse ponto. Marengo et al. (2008), ao analisar a seca amazônica de 2005, também utilizam dados hidrológicos de Óbidos para caracterizar alterações no comportamento do rio Amazonas.

2.2. Previsão Hidrológica Multihorizonte

A previsão hidrológica pode ser construída para diferentes horizontes temporais. Em horizontes curtos, a persistência e a autocorrelação da série tendem a desempenhar papel relevante; em horizontes maiores, a previsão se torna mais difícil porque a incerteza aumenta e a dependência entre o estado atual e o alvo futuro diminui. A WMO (2025) recomenda que sistemas de previsão

hidrológica sejam avaliados por métricas de erro, habilidade e utilidade, considerando a finalidade da previsão e o comportamento em eventos extremos.

Neste trabalho, o caráter multihorizonte é representado por previsões de 1, 7, 14, 30 e 90 dias. Essa escolha é uma proposta metodológica da pesquisa, não uma padronização oficial encontrada na literatura. A utilidade da escolha está em observar a degradação do desempenho conforme aumenta a antecedência da previsão.

2.3. Modelos Clássicos de Aprendizado de Máquina

A Ridge Regression é uma técnica de regressão linear regularizada que adiciona penalização L2 aos coeficientes, buscando reduzir instabilidade associada a colinearidade ou excesso de variáveis correlacionadas. O método foi formalizado por Hoerl e Kennard (1970), sendo adequado como modelo clássico de referência em problemas de regressão com atributos numéricos.

Random Forest é um método baseado em conjunto de árvores de decisão, no qual múltiplos preditores são combinados para reduzir variância e melhorar capacidade de generalização. Breiman (2001) descreve *Random Forests* como combinações de árvores que dependem de vetores aleatórios independentes, característica que justifica seu uso em problemas não lineares.

XGBoost é um sistema de *gradient boosting* baseado em árvores, projetado para escalabilidade e desempenho em tarefas de aprendizado supervisionado. Chen e Guestrin (2016) apresentam o XGBoost como um sistema de *boosting* de árvores com

mecanismos de regularização, tratamento de esparsidade e otimização computacional.

2.4. Métricas de Avaliação Hidrológica

As métricas MAE e RMSE medem erro absoluto médio e raiz do erro quadrático médio, respectivamente, permitindo avaliar magnitude média do erro. O BIAS indica tendência média de superestimativa ou subestimativa. A eficiência de Nash-Sutcliffe, proposta por Nash e Sutcliffe (1970), compara o erro do modelo com a variabilidade observada, sendo amplamente usada em modelagem hidrológica. A KGE foi proposta por Gupta et al. (2009) como decomposição diagnóstica que considera correlação, variabilidade e viés, oferecendo interpretação complementar à NSE.

2.5. Aprendizado de Máquina Quântico e Modelos Híbridos

O aprendizado de máquina quântico é uma área que investiga como recursos da computação quântica podem ser utilizados em tarefas de aprendizado. Biamonte et al. (2017) apresentam o campo como uma interseção entre computação quântica e aprendizado de máquina. Havlíček et al. (2019) discutem o uso de espaços de características quânticos em aprendizado supervisionado, enquanto Schuld e Killoran (2019) analisam formulações de aprendizado em espaços de Hilbert de características.

No presente trabalho, o QML é tratado como abordagem experimental simulada. A implementação utiliza um circuito quântico como transformador de características e emprega observáveis de Pauli para gerar atributos posteriormente utilizados por um modelo Ridge. A documentação oficial do Qiskit descreve a classe `Statevector` como recurso para representação e manipulação

de vetores de estado quântico, e SparsePauliOp como representação esparsa de operadores em base de Pauli, o que sustenta tecnicamente os componentes usados na implementação (IBM QUANTUM, 2026a; IBM QUANTUM, 2026b).

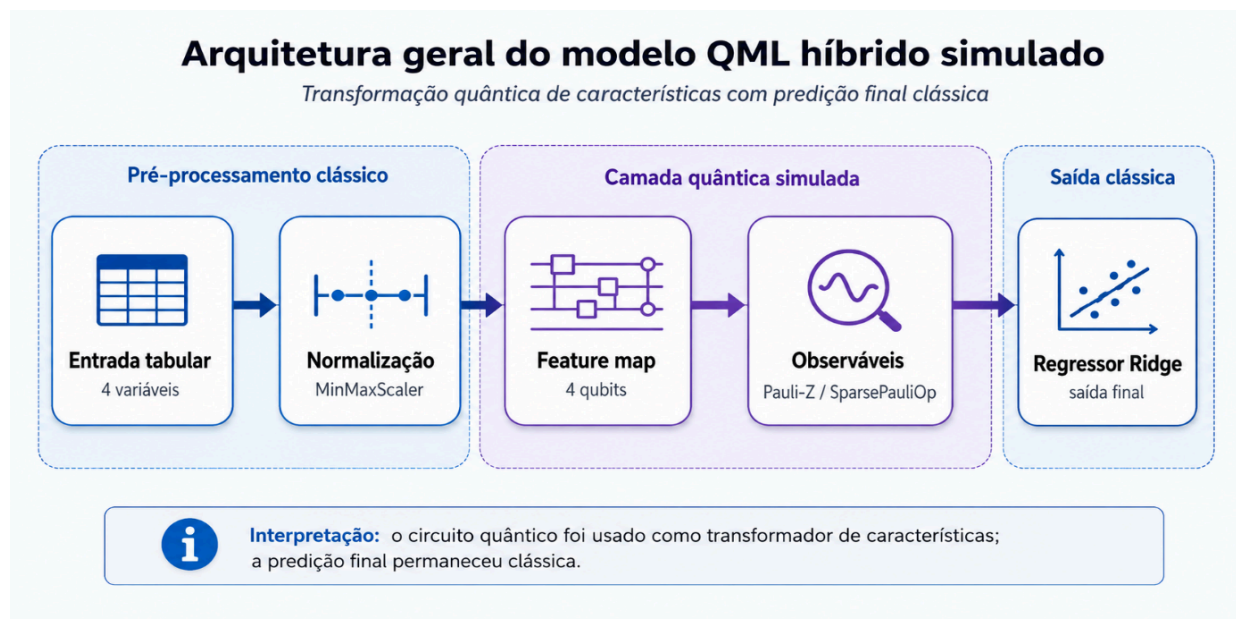


Figura 1 - Arquitetura geral do modelo QML híbrido simulado.

2.6. Trabalhos Relacionados e Lacuna

A literatura recente sobre aprendizado de máquina em hidrologia indica expansão do uso de modelos supervisionados em previsão e modelagem hidrológica, mas também reforça a necessidade de comparações justas, avaliação temporal e interpretação cautelosa dos resultados (PAPACHARALAMPOUS; TYRALIS, 2022). Para o recorte específico deste TCC, não encontrei fonte confiável suficiente para sustentar que modelos QML híbridos já estejam consolidados em previsão operacional do nível do rio Amazonas em Óbidos. Assim, a lacuna explorada é a comparação experimental entre modelos clássicos consolidados e uma arquitetura QML simulada em uma base hidrológica real.

3. METODOLOGIA

A pesquisa é aplicada, quantitativa e experimental-comparativa. É aplicada porque utiliza uma base hidrológica real para resolver um problema de previsão; quantitativa porque os modelos são avaliados por métricas numéricas; e experimental-comparativa porque diferentes algoritmos são treinados e comparados sob o mesmo conjunto de horizontes e métricas.



Figura 2 - Fluxo metodológico da avaliação comparativa.

3.1. Base de Dados e Área de Estudo

A base utilizada corresponde à série diária do nível do rio Amazonas na estação fluviométrica Óbidos, código 17050001, extraída do HidroWeb/ANA, que disponibiliza séries históricas de estações hidrometeorológicas brasileiras (ANA, 2026a). A estação contém 19.909 observações, no período de 01/04/1970 a 02/10/2024, sem dados faltantes após reindexação diária.

Tabela 1 - Caracterização geral da série utilizada.

Indicador	Valor
-----------	-------

Número de observações	19.909
Data inicial	01/04/1970
Data final	02/10/2024
Média da cota (cm)	483,90
Desvio-padrão (cm)	217,94
Mínimo (cm)	-92
Mediana (cm)	527
Máximo (cm)	860
Dados faltantes após reindexação	0

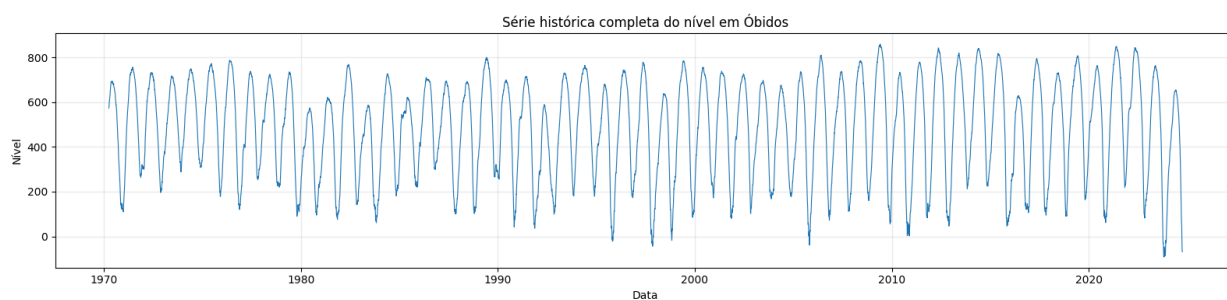


Figura 3 - Série histórica diária do nível do rio em Óbidos.

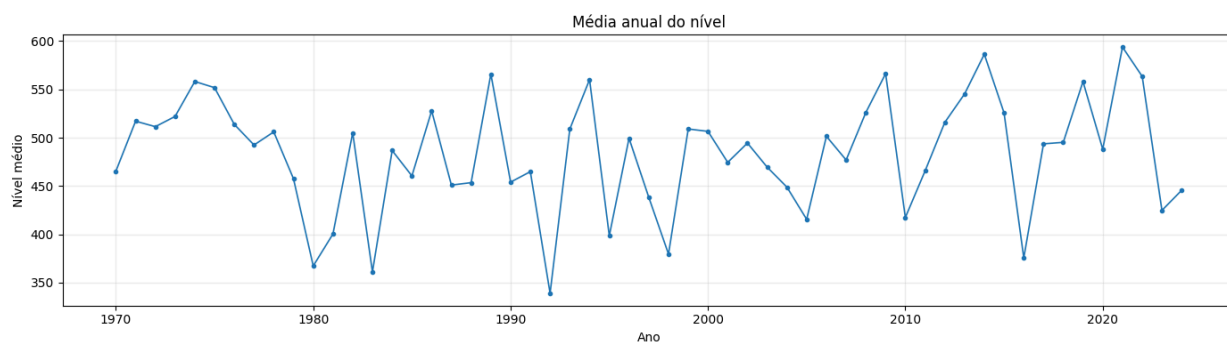


Figura 4 - Média anual da cota observada.

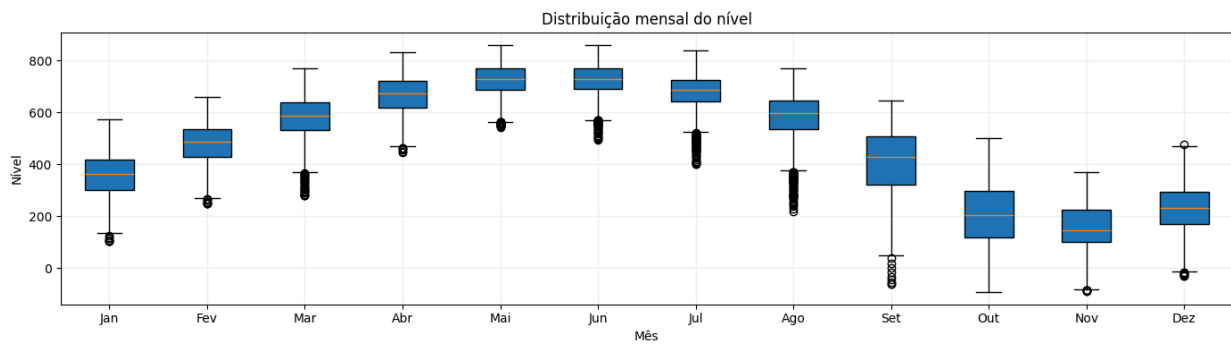


Figura 5 - Distribuição mensal da cota.

3.2. Pré-processamento e Engenharia de Atributos

O pré-processamento consistiu na organização da série por data, reindexação diária e verificação de dados faltantes. Em seguida, foram gerados atributos temporais baseados em defasagens de 1, 3, 7, 14, 30, 60 e 90 dias, médias móveis de 7, 14 e 30 dias, desvios móveis, diferenças temporais e atributos sazonais derivados do mês e do dia do ano. A transformação senoidal e cossenoidal do dia do ano é uma estratégia de codificação cíclica para representar sazonalidade anual, compatível com práticas de engenharia de atributos temporais documentadas em bibliotecas de aprendizado de máquina (SCIKIT-LEARN, 2026b).

3.3. Horizontes e Divisão Temporal

Foram avaliados cinco horizontes: 1, 7, 14, 30 e 90 dias. O conjunto de treino correspondeu ao período de 1970 a 2012; a validação, de 2013 a 2018; e o teste, de 2019 a 2024. A divisão respeita a ordem temporal dos dados, critério necessário para séries temporais, pois divisões aleatórias podem gerar treinamento com informação futura e avaliação artificialmente otimista. A documentação do TimeSeriesSplit do scikit-learn orienta que, em dados ordenados no tempo, índices de teste devem ser posteriores aos índices de treino, evitando treinamento sobre dados futuros (SCIKIT-LEARN, 2026a).

3.4. Limiar de Eventos Hidrológicos

Para análise auxiliar de eventos, utilizou-se limiares de permanência associados a seca e cheia. Boletins da ANA para acompanhamento da Bacia do Rio Amazonas informam, para estação de Óbidos, cota 95% igual a 111 cm e cota 5% igual a 737 cm; um boletim de 2025 também informa cota 10% igual a 706 cm (ANA, 2025; ANA, 2026b). Não encontrei fonte confiável suficiente para sustentar 1400 cm como cota oficial de inundação em Óbidos.

Tabela 2 - Classes hidrológicas utilizadas.

Classe/limiar utilizado	Quantidade de registros	Observação metodológica
Seca: cota \leq 111 cm	1.032	Limiar de permanência 95% informado em boletins da ANA para Óbidos.
Cheia P10: cota \geq 706 cm	3.528	Limiar de permanência 10% informado em boletim ANA de 2025 para Óbidos.
Cheia P5: cota \geq 737 cm	2.083	Limiar de permanência 5% informado em boletins da ANA para Óbidos.
Inundação: cota \geq 1400 cm	0	Não foi encontrada fonte confiável suficiente para sustentar 1400 cm como cota oficial de inundação em Óbidos; usado apenas como marca exploratória.

3.5. Modelos Avaliados

Os modelos avaliados foram: Persistência, Ridge, Random Forest, XGBoost, Ridge compacto e QML híbrido. A Persistência foi usada como baseline, assumindo que o valor futuro é aproximado pelo valor atual. Ridge, Random Forest e XGBoost representam modelos clássicos de aprendizado supervisionado com diferentes níveis de

complexidade. O Ridge compacto foi mantido como versão com subconjunto reduzido de atributos, permitindo comparação com a entrada limitada do QML. O QML híbrido usou quatro variáveis principais e quatro qubits simulados, gerando características quânticas posteriormente ajustadas por Ridge.

3.6. Métricas de Avaliação

A avaliação considerou MAE, RMSE, BIAS, NSE e KGE. MAE e RMSE foram priorizadas para medir magnitude de erro em centímetros; o BIAS foi utilizado para identificar tendência média de superestimativa ou subestimativa; NSE e KGE foram empregadas como métricas hidrológicas complementares, fundamentadas em Nash e Sutcliffe (1970) e Gupta et al. (2009).

4. RESULTADOS E DISCUSSÕES OU ANÁLISE DOS DADOS

Os resultados apresentados nesta seção correspondem à etapa experimental da pesquisa, obtidos a partir da aplicação dos modelos de previsão ao conjunto de dados hidrológicos analisado. A avaliação concentrou-se principalmente nas métricas RMSE, MAE, NSE e KGE, pois elas permitem examinar, de forma complementar, a magnitude dos erros, a precisão média das estimativas, a habilidade hidrológica dos modelos e a consistência estatística das previsões em diferentes horizontes temporais.

4.1. Desempenho Geral por RMSE

O RMSE indica aumento do erro conforme cresce o horizonte de previsão, comportamento esperado em previsão multihorizonte porque a dependência entre o estado atual do rio e o alvo futuro se reduz com o tempo. Nos horizontes de 1, 7 e 14 dias, o Ridge

apresentou os menores RMSEs. Em 30 dias, o Random Forest apresentou o menor RMSE. Em 90 dias, o XGBoost obteve o melhor resultado. Essa distribuição sugere que modelos lineares regularizados são muito competitivos em horizontes curtos, enquanto modelos baseados em árvores e boosting se tornam mais úteis em horizontes maiores.

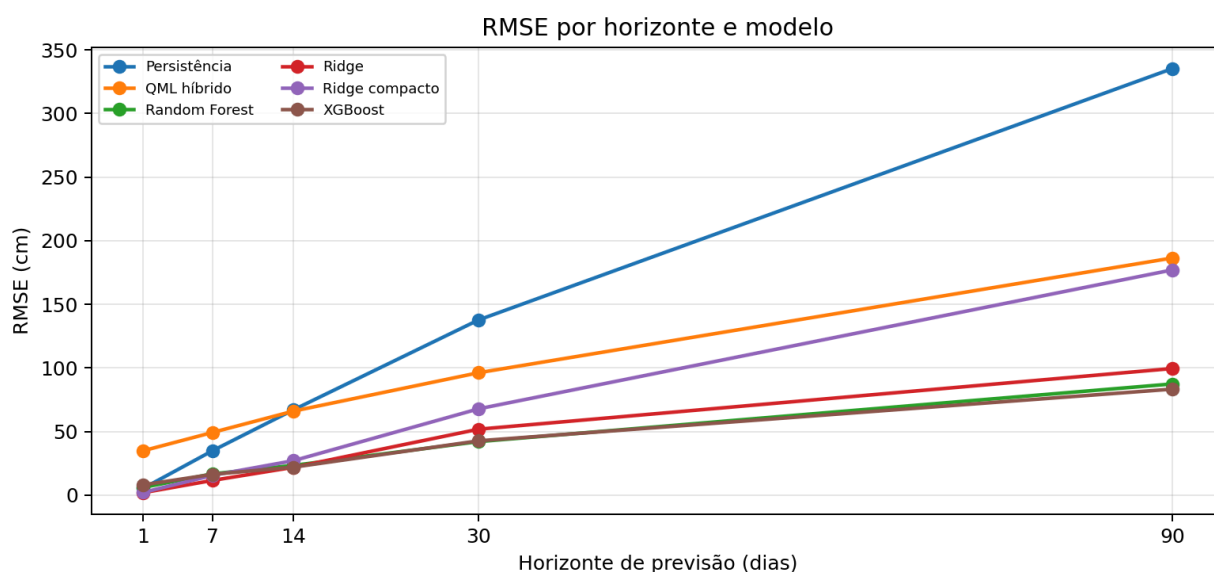


Figura 6 - RMSE por horizonte e modelo.

Tabela 3 - Melhor modelo por horizonte segundo RMSE.

Horizonte	Melhor modelo por RMSE	RMSE	MAE	NSE	KGE
1	Ridge	1,9521	1,4462	0,9999	0,9999
7	Ridge	11,6100	8,4971	0,9977	0,9966
14	Ridge	21,9046	16,0656	0,9920	0,9900
30	Random Forest	42,1004	30,2354	0,9706	0,9566

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/avaliacao->

4.2. Comparação Entre Modelos Clássicos e QML Híbrido

O QML híbrido não superou os melhores modelos clássicos em nenhum horizonte. Em 1 dia, seu RMSE foi de 34,92 cm, enquanto o Ridge obteve 1,95 cm. Em 7 dias, o QML atingiu 49,32 cm, contra 11,61 cm do Ridge. Em 14 dias, o QML aproximou-se da Persistência, mas ainda ficou distante dos melhores modelos clássicos. Em 30 e 90 dias, o QML superou a Persistência, porém permaneceu abaixo de Random Forest, Ridge e XGBoost. A interpretação mais segura é que a arquitetura QML simulada funcionou como experimento de transformação de características, mas não como alternativa operacional superior.

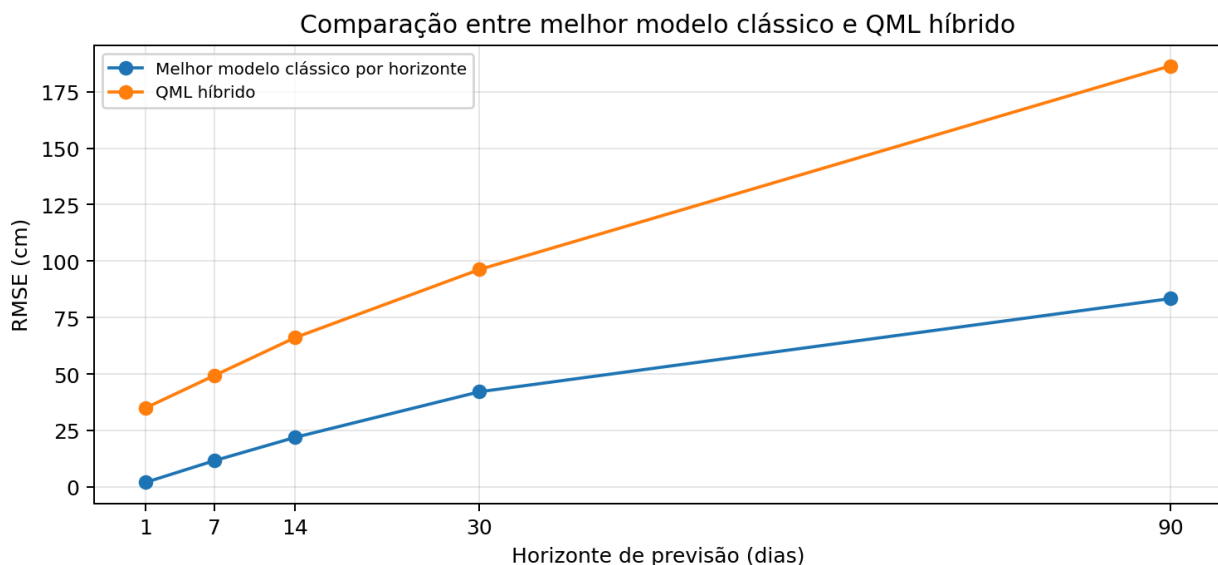


Figura 7 - Comparação entre melhor modelo clássico por horizonte e QML híbrido.

4.3. Métricas Hidrológicas NSE e KGE

A NSE foi elevada para os modelos clássicos nos horizontes curtos e intermediários, com valores próximos de 1 em vários cenários. No horizonte de 90 dias, a Persistência apresentou NSE negativa, indicando desempenho inferior ao uso da média observada como

referência, conforme interpretação geral da métrica proposta por Nash e Sutcliffe (1970). O XGBoost apresentou a maior NSE em 90 dias, com 0,8872, indicando melhor habilidade relativa nesse horizonte.

A KGE confirmou padrão semelhante, com bons resultados dos modelos clássicos e degradação em horizontes longos. O XGBoost obteve KGE de 0,8615 em 90 dias, enquanto a Persistência caiu para 0,0652. A KGE é útil nessa análise porque combina elementos de correlação, variabilidade e viés, permitindo observar não apenas a magnitude do erro, mas também a coerência estatística da previsão (GUPTA et al., 2009).

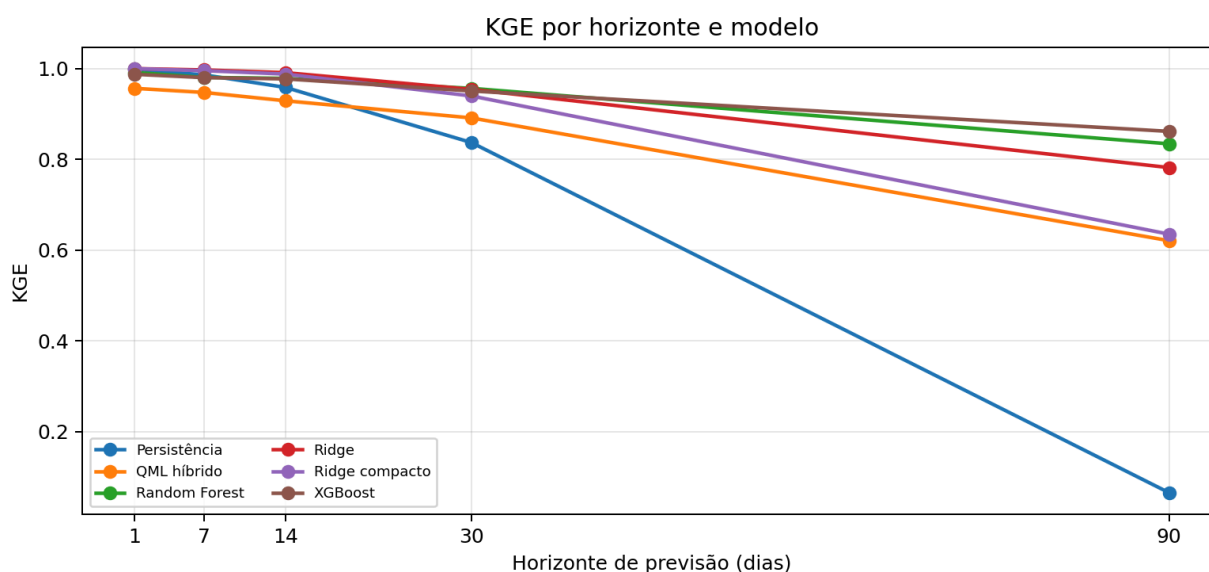


Figura 8 - KGE por horizonte e modelo.

4.4. Análise de Eventos de Seca

A análise de seca utiliza o limiar de 111 cm, associado à cota de permanência 95% informada em boletins da ANA para Óbidos (ANA, 2025; ANA, 2026b). Os resultados indicam que a identificação de seca se torna mais difícil em horizontes longos. Em 90 dias, vários modelos apresentaram F1-score reduzido ou nulo para seca, evidenciando que boa performance global em RMSE ou NSE não

garante necessariamente bom desempenho em eventos extremos. Essa distinção é coerente com recomendações de verificação hidrológica, que destacam a necessidade de avaliar previsões conforme seu uso e comportamento em eventos relevantes (WMO, 2025).

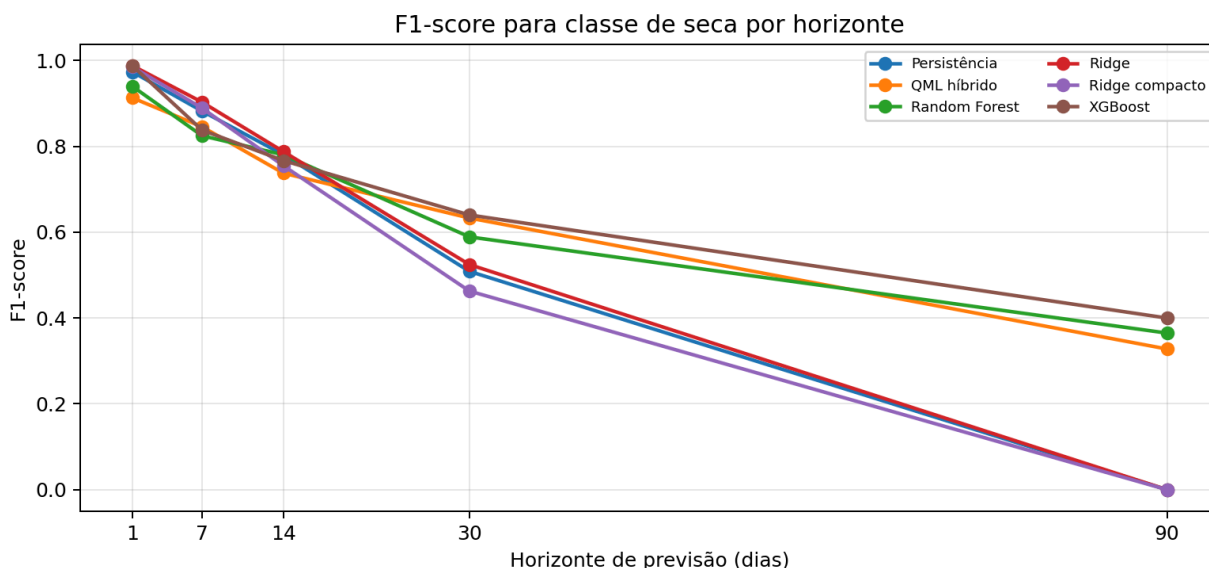


Figura 9 - F1-score para classe de seca por horizonte.

4.5. Síntese dos Resultados Numéricos

Tabela 4 - RMSE dos modelos por horizonte, em centímetros.

Horizonte (dias)	Persistência	QML híbrido	Random Forest	Ridge	Ridge compacto
1,0000	5,3600	34,9200	6,0800	1,9500	2,1700
7,0000	34,9700	49,3200	16,7900	11,6100	15,5700
14,0000	67,1200	66,0900	23,4000	21,9000	27,1200
30,0000	137,7400	96,2500	42,1000	51,8500	67,8600
90,0000	335,3500	186,4500	87,4400	99,5700	177,0900

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/avaliacao->

Tabela 5 - NSE dos modelos por horizonte.

Horizonte (dias)	Persistência	QML híbrido	Random Forest	Ridge	Ridge comparativo
1,0000	0,9995	0,9795	0,9994	0,9999	0,9995
7,0000	0,9795	0,9592	0,9953	0,9977	0,9995
14,0000	0,9247	0,9269	0,9908	0,9920	0,9877
30,0000	0,6851	0,8462	0,9706	0,9554	0,9233
90,0000	-0,8258	0,4356	0,8759	0,8391	0,4900

△ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/avaliacao-comparativa-de-modelos-classicos-e-quanticos-hibridos-para-previsao-multihorizonte-do-nivel-do-rio-em-obidos?noblockage>

Tabela 6 - KGE dos modelos por horizonte.

Horizonte (dias)	Persistência	QML híbrido	Random Forest	Ridge	Ridge comparativo
1,0000	0,9986	0,9564	0,9915	0,9999	0,9995
7,0000	0,9860	0,9473	0,9805	0,9969	0,9995
14,0000	0,9584	0,9289	0,9783	0,9909	0,9877
30,0000	0,8368	0,8911	0,9563	0,9541	0,9399
90,0000	0,0652	0,6206	0,8340	0,7817	0,6344

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/avaliacao-comparativa-de-modelos-classicos-e-quanticos-hibridos-para-previsao-multihorizonte-do-nivel-do-rio-em-obidos?noblockage>

4.6. Discussão Crítica dos Resultados

Os resultados sustentam a hipótese do trabalho: os modelos clássicos apresentaram desempenho mais consistente que o QML híbrido simulado. Isso não significa que QML seja inviável como área de pesquisa; significa apenas que, na arquitetura, base e configuração avaliadas, o QML não demonstrou vantagem empírica frente aos modelos clássicos. A comparação também mostra que a Persistência é forte em horizonte curto, mas perde qualidade rapidamente em horizontes maiores, especialmente em 90 dias.

A interpretação metodológica mais relevante é que o modelo Ridge apresentou melhor desempenho nos horizontes curtos, provavelmente em razão da forte dependência temporal presente na série hidrológica analisada. Em contrapartida, os modelos Random Forest e XGBoost demonstraram maior competitividade nos horizontes mais longos, o que pode estar associado à capacidade desses algoritmos de representar relações não lineares entre variáveis defasadas, estatísticas móveis e padrões sazonais. Essa análise deve ser compreendida como uma interpretação específica dos resultados experimentais deste estudo, não como uma generalização aplicável a todos os rios, estações fluviométricas ou bases hidrológicas.

5. CONSIDERAÇÕES FINAIS

Este trabalho avaliou comparativamente modelos clássicos de aprendizado de máquina e um modelo quântico híbrido simulado para previsão do nível do rio Amazonas em Óbidos. A pesquisa utilizou série histórica diária da estação 17050001, com horizontes de 1, 7, 14, 30 e 90 dias, atributos temporais derivados de defasagens, médias móveis e sazonalidade, além de métricas estatísticas e hidrológicas.

Os resultados indicaram que os modelos clássicos foram superiores ao QML híbrido simulado. O Ridge apresentou o melhor desempenho nos horizontes de 1, 7 e 14 dias; o Random Forest foi superior em 30 dias; e o XGBoost obteve o melhor resultado em 90 dias. O QML híbrido não venceu os modelos clássicos, mas superou a Persistência em horizontes maiores, o que permite mantê-lo como experimento exploratório, não como solução operacional principal.

A pergunta de pesquisa é respondida afirmativamente: para a base avaliada e a configuração experimental adotada, modelos clássicos apresentaram desempenho mais consistente que o modelo quântico híbrido simulado. A principal contribuição do trabalho está na comparação controlada entre modelos clássicos e uma arquitetura QML híbrida em uma aplicação hidrológica real, evidenciando tanto a força dos modelos clássicos quanto as limitações práticas do QML simulado no cenário estudado.

As delimitações deste estudo estão relacionadas ao escopo experimental adotado. A avaliação foi conduzida com base em uma série histórica univariada do nível do rio em Óbidos, considerando diferentes horizontes de previsão e modelos clássicos e quânticos híbridos simulados. Além disso, no caso do modelo quântico híbrido, sua aplicação foi limitada ao ambiente simulado, o que é compatível

com o caráter exploratório da pesquisa, mas abre espaço para investigações futuras com arquiteturas variacionais, kernels quânticos, diferentes formas de codificação dos dados e, quando disponível, avaliação em hardware quântico real.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (ANA). Acompanhamento da Bacia do Rio Amazonas: boletim diário. Brasília, DF: ANA, 2025. Disponível em: https://www.gov.br/ana/pt-br/sala-de-situacao/rio-amazonas/boletins/diario/boletim_01_amazonas_publica-44.pdf.

Acesso em: 6 maio 2026.

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (ANA). Acompanhamento da Bacia do Rio Amazonas: boletim diário. Brasília, DF: ANA, 2026b. Disponível em: [https://www.gov.br/ana/pt-br/sala-de-situacao/rio-amazonas/boletins/diario/boletim_01_amazonas_publica-](https://www.gov.br/ana/pt-br/sala-de-situacao/rio-amazonas/boletins/diario/boletim_01_amazonas_publica-1777907503.24.pdf)

[1777907503.24.pdf](https://www.gov.br/ana/pt-br/sala-de-situacao/rio-amazonas/boletins/diario/boletim_01_amazonas_publica-1777907503.24.pdf). Acesso em: 6 maio 2026.

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO (ANA). HidroWeb: séries históricas de estações. Brasília, DF: ANA, 2026a. Disponível em: <https://www.snirh.gov.br/hidroweb/serieshistoricas>.

Acesso em: 6 maio 2026.

BIAMONTE, Jacob; WITTEK, Peter; PANCOTTI, Nicola; REBENTROST, Patrick; WIEBE, Nathan; LLOYD, Seth. Quantum machine learning. Nature, London, v. 549, n. 7671, p. 195-202, 2017. DOI: 10.1038/nature23474.

BREIMAN, Leo. Random forests. Machine Learning, Dordrecht, v. 45, p. 5-32, 2001. DOI: 10.1023/A:1010933404324.

CALLÈDE, Jacques; GUYOT, Jean-Loup; RONCHAIL, Josyane; SEYLER, Frédérique; GUIMARÃES, Valdemar; OLIVEIRA, Eduardo de. Amazon river discharge variability at the Obidos gauging station during the last century. In: EGS-AGU-EUG JOINT ASSEMBLY, 2003, Nice. Abstracts [...]. Nice: EGS/AGU/EUG, 2003. Disponível em: <https://ui.adsabs.harvard.edu/abs/2003EAEJA.....9224C/abstract>.

Acesso em: 6 maio 2026.

CHEN, Tianqi; GUESTRIN, Carlos. XGBoost: a scalable tree boosting system. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016, San Francisco. Proceedings [...]. New York: ACM, 2016. p. 785-794. DOI: 10.1145/2939672.2939785.

GUPTA, Hoshin V.; KLING, Harald; YILMAZ, Koray K.; MARTINEZ, Guillermo F. Decomposition of the mean squared error and NSE performance criteria: implications for improving hydrological modelling. Journal of Hydrology, Amsterdam, v. 377, n. 1-2, p. 80-91, 2009. DOI: 10.1016/j.jhydrol.2009.08.003.

HAVLÍČEK, Vojtěch; CÓRCOLES, Antonio D.; TEMME, Kristan; HARROW, Aram W.; KANDALA, Abhinav; CHOW, Jerry M.; GAMBETTA, Jay M. Supervised learning with quantum-enhanced feature spaces. Nature, London, v. 567, n. 7747, p. 209-212, 2019. DOI: 10.1038/s41586-019-0980-2.

HOERL, Arthur E.; KENNARD, Robert W. Ridge regression: biased estimation for nonorthogonal problems. Technometrics, Alexandria, v. 12, n. 1, p. 55-67, 1970. DOI: 10.1080/00401706.1970.10488634.

IBM QUANTUM. SparsePauliOp: Qiskit API reference. Yorktown Heights: IBM, 2026b. Disponível em: https://quantum.cloud.ibm.com/docs/api/qiskit/qiskit.quantum_info.SparsePauliOp. Acesso em: 6 maio 2026.

IBM QUANTUM. Statevector: Qiskit API reference. Yorktown Heights: IBM, 2026a. Disponível em: https://quantum.cloud.ibm.com/docs/api/qiskit/qiskit.quantum_info.Statevector. Acesso em: 6 maio 2026.

MARENCO, José A. et al. Hydro-climatic and ecological behaviour of the drought of Amazonia in 2005. *Philosophical Transactions of the Royal Society B: Biological Sciences*, London, v. 363, n. 1498, p. 1773-1778, 2008. DOI: 10.1098/rstb.2007.0015.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I: a discussion of principles. *Journal of Hydrology*, Amsterdam, v. 10, n. 3, p. 282-290, 1970. DOI: 10.1016/0022-1694(70)90255-6.

PAPACHARALAMPOUS, Georgia; TYRALIS, Hristos. A review of machine learning concepts and methods for addressing challenges in probabilistic hydrological post-processing and forecasting. *Frontiers in Water*, Lausanne, v. 4, 961954, 2022. DOI: 10.3389/frwa.2022.961954.

SCHULD, Maria; KILLORAN, Nathan. Quantum machine learning in feature Hilbert spaces. *Physical Review Letters*, College Park, v. 122, 040504, 2019. DOI: 10.1103/PhysRevLett.122.040504.

SCIKIT-LEARN. Time-related feature engineering. [S. l.]: scikit-learn developers, 2026b. Disponível em: [https://scikit-](https://scikit-learn.org/)

learn.org/stable/auto_examples/applications/plot_cyclical_feature_engineering.html. Acesso em: 6 maio 2026.

SCIKIT-LEARN. TimeSeriesSplit. [S. l.]: scikit-learn developers, 2026a. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html. Acesso em: 6 maio 2026.

WORLD METEOROLOGICAL ORGANIZATION (WMO). Guidelines on the verification of hydrological forecasts. Geneva: WMO, 2025. WMO-No. 1364. Disponível em: <https://wmo.int/media/news/wmo-issues-guidelines-verification-of-hydrological-forecasts>. Acesso em: 6 maio 2026.

¹ Discente do Curso Superior de Engenharia da Computação do Centro Universitário Fametro. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Doutor em Ciência da Computação pela Universidade Federal do Amazonas – UFAM. E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Mestrando em Engenharia de Processos (UFPA – PA). E-mail: [acesse o artigo original para visualizar o e-mail](#)