ReGeo ISSN: 2177-3246

MODELAGEM POR REDES NEURAIS DA QUALIDADE DA ÁGUA DA BACIA DO RIO DAS VELHAS(MG) COM PROJEÇÕES COMPUTACIONAIS ATÉ 2030

NEURAL NETWORK MODELING OF WATER QUALITY IN THE RIO DAS VELHAS BASIN (MG) WITH COMPUTATIONAL PROJECTIONS TO 2030

MODELADO MEDIANTE REDES NEURONALES DE LA CALIDAD DEL AGUA DE LA CUENCA DEL RÍO DAS VELHAS (MG) CON PROYECCIONES COMPUTACIONALES HASTA 2030

https://doi.org/10.56238/revgeov17n8-033

Data de submissão: 04/07/2026 **Data de publicação:** 04/08/2026

Marina Cristina Guimarães
Mestranda em Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: marinacrisg@hotmail.com

Christiano Pedro Guirlanda
Pós-Doutor em Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: cpguirlanda@gmail.com

Diego Fernandes Almeida Silva
Engenheiro de Telecomunicações
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: diego.telecoom@gmail.com

Ana Clara Cassin Cordeiro
Mestranda em Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: anacassin26@gmail.com

Helen Marques Martins
Mestranda em Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: helenmmartins@gmail.com

Vagner Fernandes Knupp
Professor de Química Analítica do Curso de Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: VFK@ufsj.edu.br

Juan Canellas Bosch Neto
Professor do curso de Engenharia Química
Instituição: Universidade Federal de São João del Rei (UFSJ)
E-mail: jboschbr@ufsj.edu.br

RESUMO
Este estudo realizou a modelagem preditiva, por Redes Neurais Artificiais (RNAs), de parâmetros de qualidade da água e a avaliação da dinâmica de eutrofização na bacia do Rio das Velhas (MG), integrando a base de dados do Instituto Mineiro de Gestão das Águas (IGAM) de 1997 a 2025 com projeções computacionais até 2030. A metodologia empregou uma RNA feedforward (algoritmo Levenberg-Marquardt, implementada em MATLAB), estruturada com duas camadas ocultas, contendo 32 e 16 neurônios cada e função de ativação tansig. A rede foi treinada com variáveis de entrada: ano, mês. estações de coleta, com dados de vazão fluviométrica, densidade populacional e sólidos suspensos sedimentares para predizer 16 parâmetros físico-químicos de saída, após pré-processamento via remoção de outliers, padronização, análise de componentes principais (PCA) e identificação de tendências. O padrão espacial das 158 estações foi obtido por agregação geoestatística dos dados observados e preditos. O modelo demonstrou elevada capacidade preditiva, alcançando coeficiente de correlação R = 0,90 no treinamento, teste e validação e erro quadrático médio (MSE) de 50,51. As simulações até 2030 indicam a persistência do estresse ambiental e a severa degradação da bacia, caracterizadas pelo aporte contínuo de sólidos suspensos, elevada turbidez e elevação da DQO e DBO, que comprometem a fotossíntese e reduzem os níveis de oxigênio dissolvido. A presença crônica de nutrientes (fósforo e nitrato), metais, contaminação por E. coli e arsênio confirma um processo avançado de eutrofização impulsionado por efluentes urbanos, industriais e minerários, com destaque para a vulnerabilidade de trechos como o Rio Itabirito e o Ribeirão Arrudas. Ressalta-se que a projeção para 2030 constitui uma extrapolação de tendência temporal, devendo ser interpretada considerando a não inclusão de variáveis exógenas de pressão antrópica futura. A principal contribuição deste estudo reside na validação dessa abordagem preditiva e na segmentação da bacia em três macrozonas de comportamento ecológico distintas, fornecendo subsídios diretos para a priorização espacial de investimentos em saneamento, manejo de solo e gestão hídrica.

Palavras-chave: Bacia do Rio das Velhas. Parâmetros Físico-Químicos. Redes Neurais Artificiais. Modelagem Preditiva. Eutrofização.

ABSTRACT
This study performed predictive modeling of water quality parameters and evaluated eutrophication dynamics in the Rio das Velhas basin (Minas Gerais, Brazil) using Artificial Neural Networks (ANNs), integrating the database from the Minas Gerais Institute for Water Management (IGAM) from 1997 to 2025 with computational projections up to 2030. The methodology employed a feedforward ANN (Levenberg-Marquardt algorithm, implemented in MATLAB), structured with two hidden layers, 48 neurons, and a tansig activation function. The network was trained using temporal variables (year and month, collection stations, streamflow data , population density, settleable suspended solids) as inputs to predict 16 output physicochemical parameters, following preprocessing via outlier removal, standardization, principal component analysis (PCA), and trend identification. The spatial pattern across 158 monitoring stations was obtained through geostatistical aggregation of observed and predicted data. The model demonstrated high predictive performance, achieving a correlation coefficient of R = 0.90 across training, testing, and validation phases, with a Root Mean Square Error (MSE) 50,51. Simulations up to 2030 indicate persistent environmental stress and severe degradation of the basin, characterized by continuous input of suspended solids, high turbidity, and elevated COD and BOD, which impair photosynthesis and drastically reduce dissolved oxygen levels. The chronic presence of nutrients (phosphorus and nitrate), metals, *E. coli* contamination, and arsenic confirms an advanced eutrophication process driven by urban, industrial, and mining effluents, highlighting the vulnerability of critical stretches such as the Itabirito River and the Arrudas Stream. Notably, the projection to 2030 constitutes a temporal trend extrapolation and should be interpreted acknowledging the omission of exogenous variables representing future anthropogenic pressure. The main

contribution of this study lies in the validation of this predictive approach and the segmentation of the basin into three distinct ecological macro-zones, providing direct support for spatial prioritization of investments in sanitation, sustainable land management, and water resources management.

Keywords: Rio das Velhas Basin. Physicochemical Parameters. Artificial Neural Networks. Predictive Modeling. Eutrophication.

RESUMEN
Este estudio realizó la modelación predictiva, mediante Redes Neuronales Artificiales (RNA), de parámetros de calidad del agua y la evaluación de la dinámica de eutrofización en la cuenca del Río das Velhas (Minas Gerais, Brasil), integrando la base de datos del Instituto Mineiro de Gestión de las Aguas (IGAM) de 1997 a 2025 con proyecciones computacionales hasta 2030. La metodología empleó una RNA *feedforward* (algoritmo Levenberg-Marquardt, implementada en MATLAB), estructurada con dos capas ocultas, 48 neuronas y función de activación tansig. La red fue entrenada utilizando variables (año, mes, estaciones de muestreo de agua, caudal fluvial, densidad poblacional, sólidos suspendidos sedimentables) como entradas para predecir 16 parámetros físico-químicos de salida, tras un preprocesamiento mediante eliminación de valores atípicos (*outliers*), estandarización, análisis de componentes principales (PCA) e identificación de tendencias. El patrón espacial de las 158 estaciones se obtuvo mediante agregación geoestadística de los datos observados y predichos. El modelo demostró una elevada capacidad predictiva, alcanzando un coeficiente de correlación R = 0,90 en las fases de entrenamiento, prueba y validación y (MSE) 50,51. Las simulaciones hasta 2030 indican la persistencia del estrés ambiental y la severa degradación de la cuenca, caracterizadas por el aporte continuo de sólidos suspendidos, elevada turbidez e incremento de la DQO y DBO, factores que comprometen la fotosíntesis y reducen drásticamente los niveles de oxígeno disuelto. La presencia crónica de nutrientes (fósforo y nitrato), metales, contaminación por *E. coli* y arsénico confirma un proceso avanzado de eutrofización impulsado por efluentes urbanos, industriales y mineros, destacando la vulnerabilidad de tramos como el Río Itabirito y el Ribeirão Arrudas. Cabe resaltar que la proyección para 2030 constituye una extrapolación de tendencia temporal, debiendo interpretarse considerando la no inclusión de variables exógenas de presión antrópica futura. La principal contribución de este estudio radica en la validación de este enfoque predictivo y en la segmentación de la cuenca en tres macrozonas de comportamiento ecológico diferenciadas, proporcionando insumos directos para la priorización espacial de inversiones en saneamiento, manejo del suelo y gestión hídrica.

Palabras clave: Cuenca del Río das Velhas. Parámetros Fisico Químicos. Redes Neuronales Artificiales. Modelación Predictiva. Eutrofización.

1 INTRODUÇÃO

A qualidade das águas superficiais é um importante indicador da saúde ambiental de uma bacia hidrográfica, refletindo os efeitos de pressões antrópicas como urbanização, atividades agropecuárias, efluentes industriais e impactos minerários. A bacia do Rio das Velhas (MG) é a maior sub-bacia do Rio São Francisco em território mineiro, abrangendo mais de 50 municípios e a Região Metropolitana de Belo Horizonte (RMBH). Essas pressões geram um quadro crítico de degradação hídrica.

Estudos anteriores, como o de Trindade et al. (2017) mediante técnicas estatísticas multivariadas, confirmaram a eficácia do diagnóstico hídrico e a tendência de deterioração em sub-bacias específicas, corroborando boletins do Instituto Mineiro de Gestão das Águas (IGAM, 2023, 2025) que registram recorrentes violações nos padrões de enquadramento. Contudo, a literatura existente sobre a bacia é predominantemente diagnóstica e retrospectiva, carece de ferramentas prospectivas capazes de quantificar a trajetória da qualidade da água no tempo com margem de incerteza explicitada (IRANI et al., 2025).

As Redes Neurais Artificiais (RNAs), por sua capacidade de reconhecer padrões não lineares complexos em séries temporais ambientais, vêm se consolidando como alternativas robustas para preencher essa lacuna de modelagem (ZHU et al., 2022; RAHAT et al., 2023). No entanto, a aplicação dessas técnicas em bacias brasileiras de grande escala e elevada heterogeneidade espacial, como o Rio das Velhas, que atravessa múltiplos gradientes de contaminação ao longo de seus mais de 800 km, ainda é limitada.

Em particular, observa-se uma carência de arcabouços que integrem de forma contínua a dimensão temporal e o padrão espacial dos pontos de monitoramento para a antecipação de processos de degradação e eutrofização (TRINDADE et al., 2017; RAHAT et al., 2023).

Este trabalho tem como objetivo modelar a dinâmica dos parâmetros de qualidade da água e da eutrofização na bacia do Rio das Velhas (MG), por meio de uma RNA *feedforward (*algoritmo Levenberg-Marquardt), utilizando a base de dados histórica do IGAM (1997–2025) para gerar projeções computacionais até 2030. A contribuição central deste estudo reside em validar estatisticamente a capacidade preditiva da rede, reportando métricas de erro e avaliando abertamente as limitações inerentes à extrapolação temporal; traduzir as projeções em três macrozonas de comportamento ecológico distintas, alinhadas às diretrizes de enquadramento da Deliberação COPAM-CERH/MG nº 08/2022, fornecendo subsídios diretos e espacializados para o planejamento e a gestão sustentável dos recursos hídricos na bacia.

2 REFERENCIAL TEÓRICO

2.1 PRESSÕES ANTRÓPICAS E QUALIDADE HÍDRICA NA BACIA DO RIO DAS VELHAS

A bacia do Rio das Velhas destaca-se como a maior sub-bacia do Rio São Francisco em Minas Gerais, abrangendo mais de 50 municípios, incluindo a Região Metropolitana de Belo Horizonte (RMBH). Apesar de sua relevância socioeconômica, a bacia enfrenta históricos e severos problemas ambientais decorrentes do lançamento de esgotos domésticos não tratados, efluentes industriais e impactos associados às intensas atividades minerárias (TRINDADE et al., 2017; IGAM, 2023). A contaminação por nutrientes (nitrato e fósforo), matéria orgânica e metais pesados associados aos sedimentos compromete a capacidade de autodepuração do rio, afetando os níveis de oxigênio dissolvido e a saúde pública (GUIMARÃES et al., 2020; SANTOS et al., 2023).

Nesse cenário de contaminação complexa, o acompanhamento temporal de parâmetros como Demanda Bioquímica de Oxigênio (DBO), Demanda Química de Oxigênio (DQO) e turbidez através das séries históricas do Instituto Mineiro de Gestão das Águas (IGAM) torna-se crucial para identificar padrões de recuperação ou degradação da qualidade da água (GUIMARÃES et al., 2020; SANTOS et al., 2023; IGAM, 2023).

2.2 REDES NEURAIS ARTIFICIAIS (RNAS) NA MODELAGEM AMBIENTAL

Na modelagem de sistemas ambientais não lineares e dinâmicos, métodos estatísticos convencionais frequentemente apresentam limitações ao capturar interações complexas entre múltiplas variáveis físicas e químicas (GUIMARÃES et al., 2020; ZHU et al., 2022). As Redes Neurais Artificiais (RNAs) emergem como alternativas eficientes por sua arquitetura inspirada em processos biológicos, estruturada em camadas de neurônios interconectados capazes de mapear padrões complexos e realizar predições com elevada precisão a partir de grandes volumes de dados (ZHU et al., 2022; RAHAT et al., 2023). Nos estudos limnológicos e de gestão hídrica, as RNAs do tipo feedforward têm demonstrado capacidade adaptativa superior no reconhecimento de tendências temporais e na simulação de processos de eutrofização, convertendo séries históricas em ferramentas prospectivas de suporte à tomada de decisão (RAHAT et al., 2023; SANTOS et al., 2023).

2.3 OTIMIZAÇÃO VIA ALGORITMO LEVENBERG-MARQUARDT E DESAFIOS DE AJUSTE

O treinamento de RNAs para predições ambientais requer algoritmos de otimização capazes de minimizar a função de erro com eficiência e rapidez. O algoritmo de Levenberg-Marquardt (LM) destaca-se na literatura clássica e contemporânea de otimização não linear por combinar a estabilidade do método do Gradiente Descendente em regiões distantes do mínimo com a velocidade de

convergência do método de Gauss-Newton nas proximidades da solução ideal (HAGAN; MENHAJ, 1994; ZHU et al., 2022).

Essa abordagem híbrida concede ao algoritmo LM superioridade computacional na convergência de problemas de mínimos quadrados em comparação ao gradiente descendente puro. Contudo, a aplicação de redes neurais de pequeno ou médio porte treinadas por LM exige cautela quanto à hiperparametrização: arquiteturas cujos neurônios e camadas ocultas não são validados sistematicamente apresentam elevada suscetibilidade ao overfitting (superajuste), onde o modelo memoriza o ruído dos dados de treinamento, mas perde capacidade de generalização para dados não vistos. Para mitigar esse desafio, a literatura recomenda o controle rigoroso da divisão dos dados (treinamento, validação e teste), garantindo a estabilidade e a acurácia das projeções geradas.

3 METODOLOGIA

A avaliação da dinâmica hídrica e a modelagem preditiva na Bacia do Rio das Velhas foram conduzidas a partir da base de dados do Instituto Mineiro de Gestão das Águas (IGAM). A série histórica compreende o período de 1997 a 2025, contabilizando 11.472 registros tabulares (com aproximadamente 263.856 entradas individuais) distribuídos em 158 estações de monitoramento ao longo da calha principal e principais afluentes da bacia.

3.1 PRÉ-PROCESSAMENTO E TRATAMENTO ESTATÍSTICO

O banco de dados passou por um fluxo inicial de pré-processamento. A remoção de valores discrepantes (outliers) e ruídos de medição foi realizada por meio do algoritmo DataCleaner em ambiente MATLAB. Lacunas temporais (missing data) na série histórica foram tratadas via interpolação linear para pequenos intervalos ausentes; séries com descontinuidade superior a 30% no histórico de uma dada estação foram desconsideradas para evitar vieses inequívocos de padrões.

Análises estatísticas descritivas (mínimo, máximo, média, mediana, desvio padrão e variância) foram calculadas para a caracterização das variáveis. Para viabilizar a convergência do algoritmo de treinamento da rede neural e evitar a saturação das funções de ativação, todos os dados foram normalizados para a faixa [-1, 1]. A Análise de Componentes Principais (PCA) foi aplicada para a identificação das variáveis físico-químicas de maior variância acumulada e representatividade na dinâmica de contaminação hídrica.

3.2 ARQUITETURA E TREINAMENTO DA REDE NEURAL ARTIFICIAL (RNA)

A modelagem preditiva temporal foi implementada por meio de uma Rede Neural Artificial (RNA) do tipo feedforward (Multi-Layer Perceptron - MLP) no software MATLAB (Figura 1). A arquitetura do modelo foi configurada da seguinte forma: camada de entrada (6 entradas): variáveis: ano, mês, estações de coleta, dados de vazão fluviométrica, densidade populacional e sólidos suspensos sedimentares camadas ocultas: duas camadas ocultas contendo 32 e 16 neurônios cada, utilizando a função de ativação tangente sigmoide (tansig); camada de saída (16 neurônios): turbidez, sólidos suspensos, DBO, DQO, nitrato, oxigênio dissolvido, ferro, manganês, fósforo, coliformes termotolerantes, arsênio, condutividade, óleos e graxas, cor verdadeira, pH, temperatura, entre outros.

Figura 1. Esquema estrutural da arquitetura da RNA feedforward implementada.

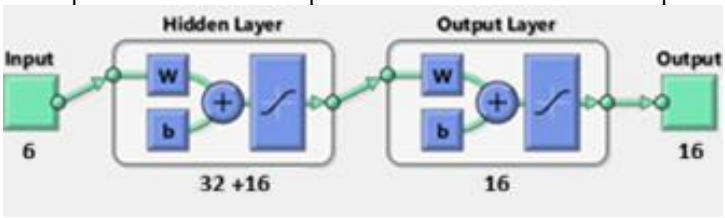

Fonte: Elaborado pelos autores, 2026.

O treinamento da rede foi executado pelo algoritmo de otimização não linear Levenberg-Marquardt (trainlm), reconhecido por sua rápida convergência. O conjunto de dados foi particionado aleatoriamente em: 70% para treinamento, 15% para validação e 15% para teste. O critério de parada antecipada (early stopping) foi adotado para interromper o treinamento assim que o erro no conjunto de validação começasse a aumentar, prevenindo o overfitting. A acurácia do modelo foi avaliada pelo coeficiente de correlação (R).

3.3 PROJEÇÃO COMPUTACIONAL (HORIZONTE 2030) E INCERTEZA

Após a validação estatística (R = 0,90), a RNA foi submetida a simulações de cenários temporais projetando a tendência dos 16 parâmetros até o ano de 2030. O modelo assume a manutenção dos padrões históricos observados no período 1997–2025, não incorpora variáveis exógenas determinísticas de pressão antrópica futura (como mudanças de uso do solo ou novos aportes industriais).

3.4 PÓS-PROCESSAMENTO E MAPEAMENTO GEOESPACIAL

A variação espacial do comportamento hídrico ao longo dos 800 km da bacia não foi inserida como entrada direta no algoritmo da RNA, mas obtida por meio de um pós-processamento geoestatístico.

As predições geradas pela rede neural para as 158 estações de amostragem foram vinculadas às suas respectivas coordenadas geográficas e cotas altimétricas (variando da altitude máxima de 1.322 m, na cabeceira/Serra do Gandarela, até a mínima de 472 m, na foz em Várzea da Palma). Utilizando rotinas automatizadas desenvolvidas em linguagem Python, os dados foram agregados e ordenados em função do vetor de fluxo fluvial longitudinal, permitindo a construção de perfis tridimensionais de sazonalidade e a regionalização da bacia nas macrozonas ecológicas de análise.

4 RESULTADOS E DISCUSSÕES

A modelagem preditiva via Redes Neurais Artificiais (RNA) feedforward, estruturada com 6 variáveis de entrada (ano, mês e estações de coleta de água, vazão fluviométrica, densidade populacional e sólidos suspensos sedimentares), 48 neurônios na camada oculta e 16 variáveis de saída, otimizada pelo algoritmo de Levenberg-Marquardt, permitiu simular a dinâmica espaço-temporal da qualidade da água na Bacia do Rio das Velhas no horizonte de 1997 a 2030. A fusão dos dados observados e projetados consolida a caracterização limnológica da bacia com a fundamentação estatística do modelo preditivo.

4.1 DESEMPENHO DO MODELO E CARACTERIZAÇÃO ESTATÍSTICA

O modelo alcançou excelente convergência estatística, registrando coeficiente de correlação global R = 0,90 ao contrastar os dados observados (1997–2025) com as projeções computacionais nas fases de treinamento (R = 0,911), validação (R = 0,941) e teste (R = 0,895) (Figura 2). O erro quadrático médio (MSE) resultou em 50,51.

Figura 2. Gráficos de regressão para treinamento, validação e teste.

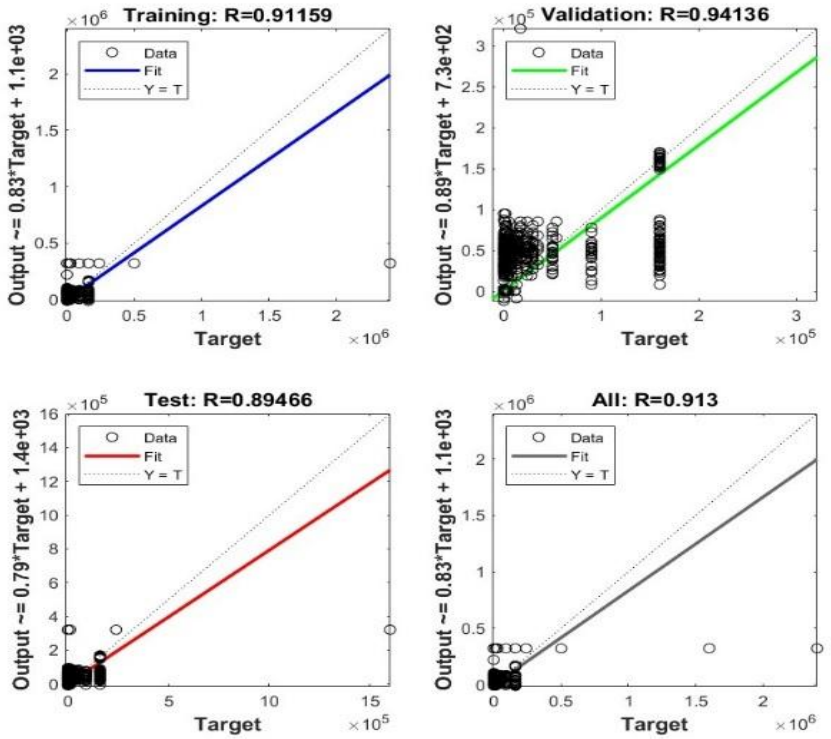

Fonte: Elaborado pelos autores, 2026.

A Tabela 1 apresenta a estatística descritiva dos parâmetros de entrada e saída modelados.

Tabela 1. Parâmetros estatísticos das entradas e saídas do sistema (1997–2025).

Variável	Mínimo	Máximo	Média	Mediana	Moda	Desvio Padrão
Ano	1997	2025	—	—	—	—
Mês	1	12	—	—	—	—
Arsênio Total (mg/L)	0,0005	0,1565	0,0077	0,0010	0,0010	0,0151
Condutividade (µS/cm)	1,04	3800	229,10	168	181	265,07
Cor Verdadeira (PtCo/L)	4	102	29,77	22	10	22,50
DBO (mg/L)	0,20	17,00	4,37	2,00	2,00	3,63
DQO (mg/L)	5,00	77,20	22,90	18,00	5,00	16,96
Ferro Dissolvido (mg/L)	0,005	0,592	0,168	0,128	0,030	0,133
Fósforo Total (mg/L)	0,010	0,660	0,157	0,100	0,020	0,156
Manganês (mg/L)	0,003	0,420	0,132	0,111	0,111	0,092
Nitrato (mg/L)	0,010	2,610	0,614	0,360	0,020	0,638
Óleos e Graxas (mg/L)	1,00	36,00	10,98	15,00	15,00	6,83
Oxigênio Dissolvido (mg/L)	0,20	11,50	5,82	6,10	6,50	2,41
pH	5,80	8,50	7,16	7,20	7,30	0,51
Sólidos Sedimentares (mg/L)	0,00	155,00	35,79	23,00	2,00	35,57
Sólidos Dissolvidos (mg/L)	3,00	354,00	116,49	102,00	48,00	74,34
Temperatura (°C)	15,10	32,60	23,82	24,00	25,00	3,22
Turbidez (NTU)	0,29	121,00	27,93	17,10	105,00	28,37
Altitude (m)	472	1322	724,17	727,00	742	145,94
Vazão Fluviométrica (m^3/s)	1,67	306,31	94,90	102,91	102,91	73,07
Densidade pop. (Hab./km^2)	2,02	6988.26	1487,31	213,67	6.988,26	2505,67

Fonte: Elaborado pelos autores. Adaptado de IGAM – Dados de Águas Superficiais (IGAM, 2025).

A análise dos dados revela concentrações médias elevadas de DBO (4,37 mg/L), DQO (22,90 mg/L) e fósforo Total (0,157 mg/L), associadas a episódios recorrentes de severa depleção de oxigênio. A ocorrência de pH mínimo em 5,80 (abaixo do limite inferior de 6,0 fixado pela Resolução CONAMA nº 357/2005 para corpos d'água de Classe 2) constitui um indicador de acidificação pontual, possivelmente associada à drenagem ácida de mina (DAM). Adicionalmente, os picos de Arsênio Total atingindo 0,1565 mg/L ultrapassam em mais de 15 vezes o limite regulatório de 0,01 mg/L, evidenciando o impacto crônico do escoamento e lixiviação sobre rejeitos e áreas de mineração histórica no Quadrilátero Ferrífero.

A presença de dados como a de vazão fluviométrica no conjunto primário ajuda no acoplamento estatístico rigoroso entre o efeito de carga poluidora (aporte) e o efeito de diluição hidráulica (regime de cheia/estiagem).

4.2 DINÂMICA ESPAÇO-TEMPORAL E SAZONALIDADE DOS PARÂMETROS CRÍTICOS

A simulação computacional por redes neurais, com previsões até 2030 revelou comportamentos distintos entre os contaminantes, fortemente influenciados pelo regime pluviométrico regional (estação chuvosa de outubro a março vs. estiagem de abril a setembro):

A Figura 3, obtida pela rede neural, mostra que os picos de concentração de arsênio se concentram entre os meses de janeiro a maio. Na seca, a falta de diluição mantém a contaminação crônica localizada.

Figura 3. Sazonalidade para a concentração de arsênio ao longo dos meses e anos.

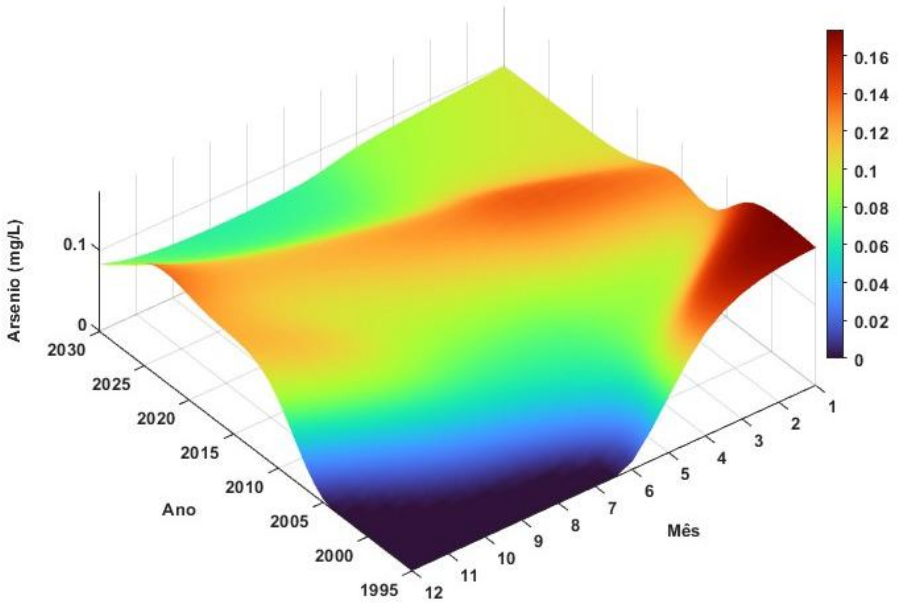

Fonte: Elaborado pelos autores, 2026.

Figura 4. Concentração de arsênio por estação de coleta e ao longo dos anos.

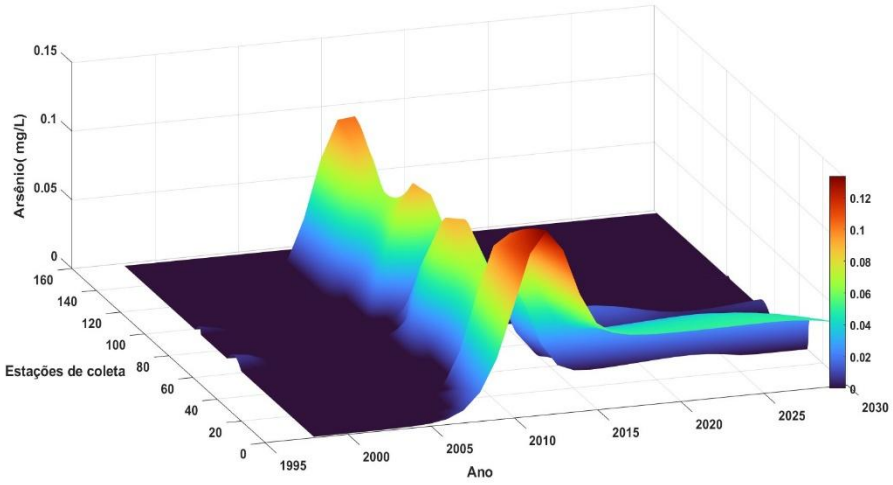

Fonte: Elaborado pelos autores, 2026.

A Figura 4, obtida pela rede neural, possui um pico de arsênio em 2014, possivelmente devido à mineração e ao garimpo na região do alto e médio da Bacia do Rio das Velhas, próximo a Ouro Preto, Itabirito e outros pontos críticos de mineração e garimpo, além de Belo Horizonte, Curvelo e Montes Claros. A partir de 2015, a concentração de arsênio reduziu significativamente.

As Figuras 5 e 6 são relativas à demanda bioquímica de oxigênio (DBO) e à demanda química de oxigênio (DQO) e apresentam platôs elevados e crônicos entre os anos 2000 e 2015 no trecho correspondente ao Alto Rio das Velhas (estações 80 a 120/140 Pirapora, Belo Horizonte e Ribeirão das Neves). Contudo, as projeções até 2030 apontam uma tendência gradual de estabilização em patamares inferiores, sugerindo reflexos positivos da expansão da infraestrutura de saneamento na Região Metropolitana de Belo Horizonte (RMBH).

Figura 5. Estações de coleta para DBO ao longo dos meses e anos.

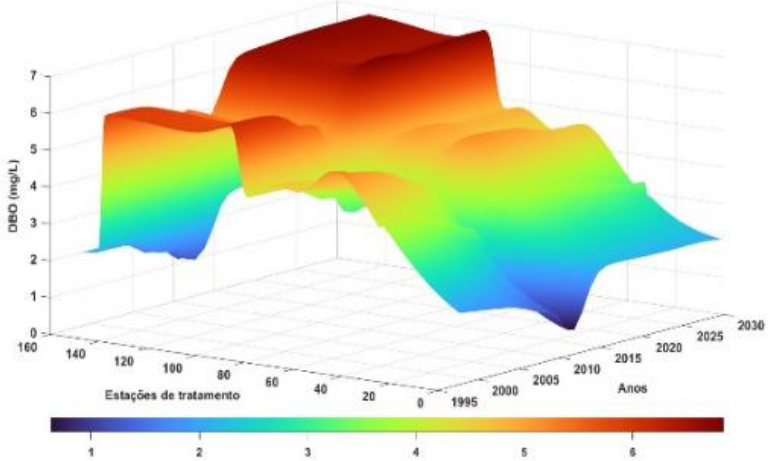

Fonte: Elaborado pelos autores, 2026.

Figura 6. Concentração de DQO por estação de coleta e ao longo dos anos.

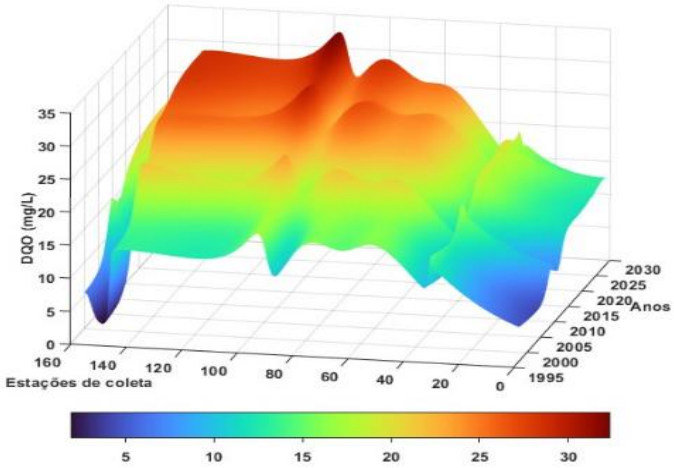

Fonte: Elaborado pelos autores, 2026.

O parâmetro fósforo total obtido pela rede neural, conforme Figura 7 apresenta uma das trajetórias de recuperação mais expressivas. Picos históricos na ordem de 0,60 mg/L no ano de 2014. Após o ano 2015 as projeções indicaram níveis residuais homogêneos até 2030, minorando o risco de eutrofização sistêmica na calha principal.

Figura 7. Concentração de fósforo por estação de coleta e ao longo dos anos.

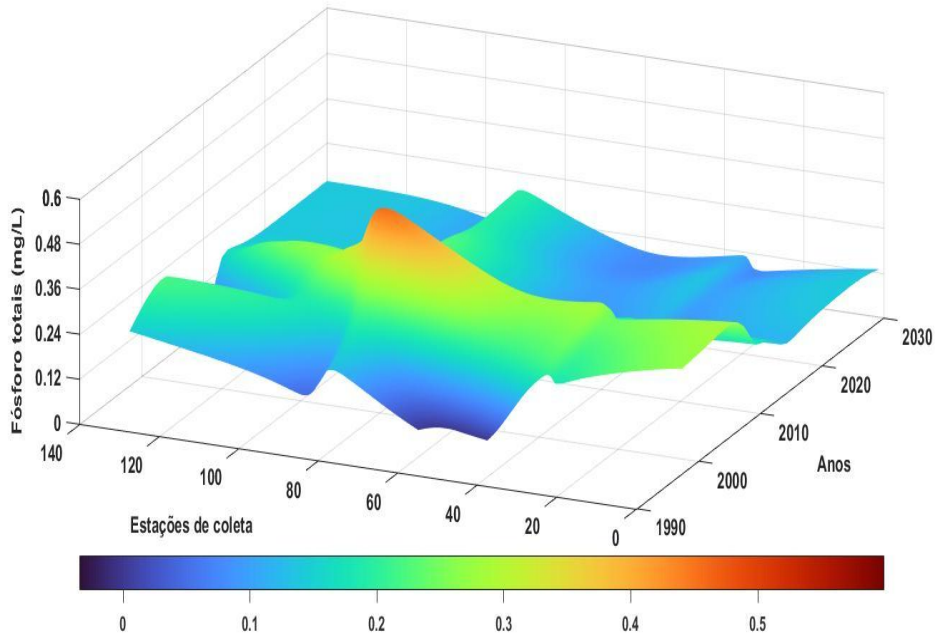

Fonte: Elaborado pelos autores, 2026.

O parâmetro nitrato diferentemente do fósforo, conforme Figura 8, projeta uma tendência de elevação contínua, atingindo valores próximos a 0,90 mg/L nas projeções mais recentes e futuras (2025–2030). As concentrações máximas ocorrem no período de estiagem por menor capacidade de diluição, agravadas por descargas contínuas de efluentes domésticos e agrícolas.

Figura 8. Concentração de nitrato por estação de coleta e ao longo dos anos.

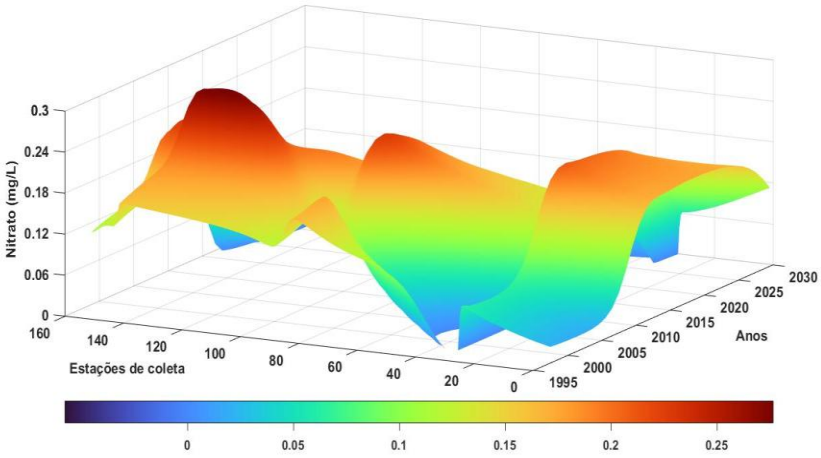

Fonte: Elaborado pelos autores, 2026.

O parâmetro óleos e graxas, obtido pela rede neural conforme Figura 9, registra um aumento abrupto de concentração a partir de 2010 para 15 mg/L, com projeções de estabilização no mesmo valor.

Figura 9. Concentração de óleos e graxas por estação de coleta e ao longo dos anos.

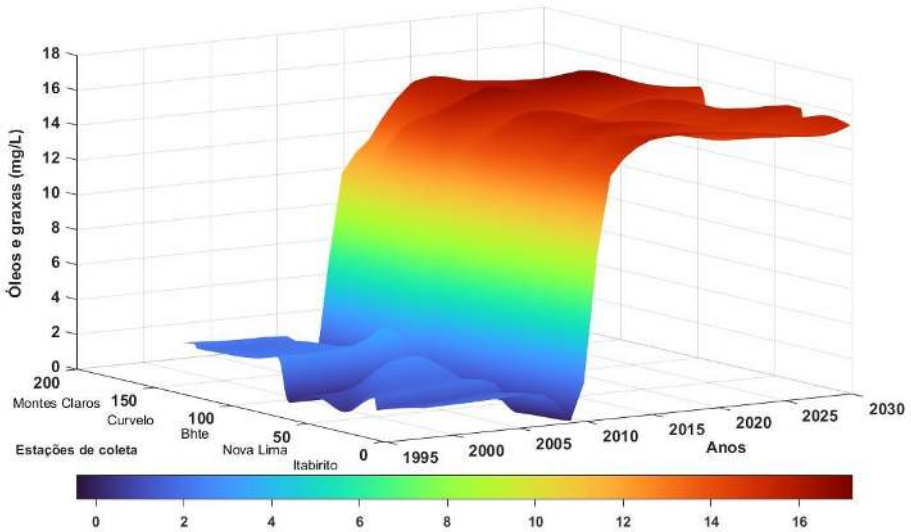

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para o parâmetro oxigênio dissolvido (OD), conforme Figura 10, apresenta uma curva de recuperação histórica a partir de 2015, saindo de patamares críticos de anóxia no Alto Rio das Velhas para uma reoxigenação progressiva em direção à jusante.

Figura 10. Concentração de oxigênio dissolvido por estação de coleta e ao longo dos anos.

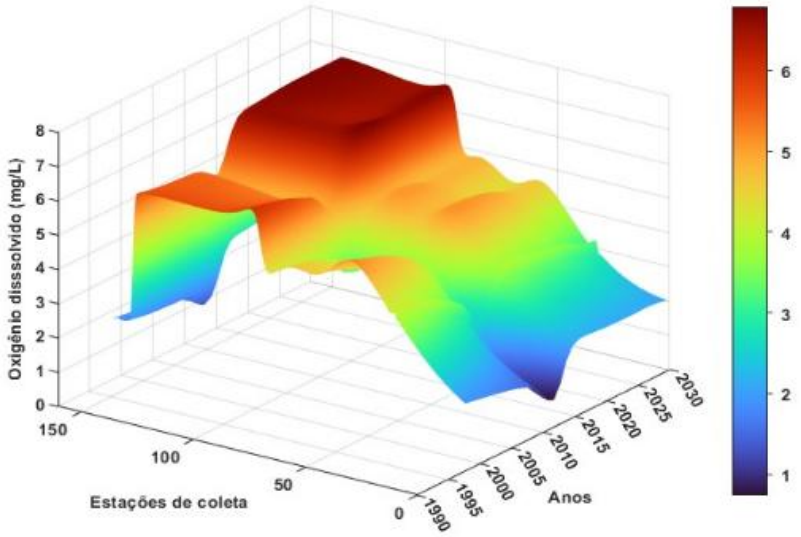

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para o parâmetro coliformes fecais, conforme Figura 11, apresentou valores acima do padrão recomendado (<1000 NMP/100 mL), devido à descarga de poluentes e de esgoto diretamente na bacia do Rio das Velhas.

Figura 11. Estações de coleta para concentração de coliformes fecais.

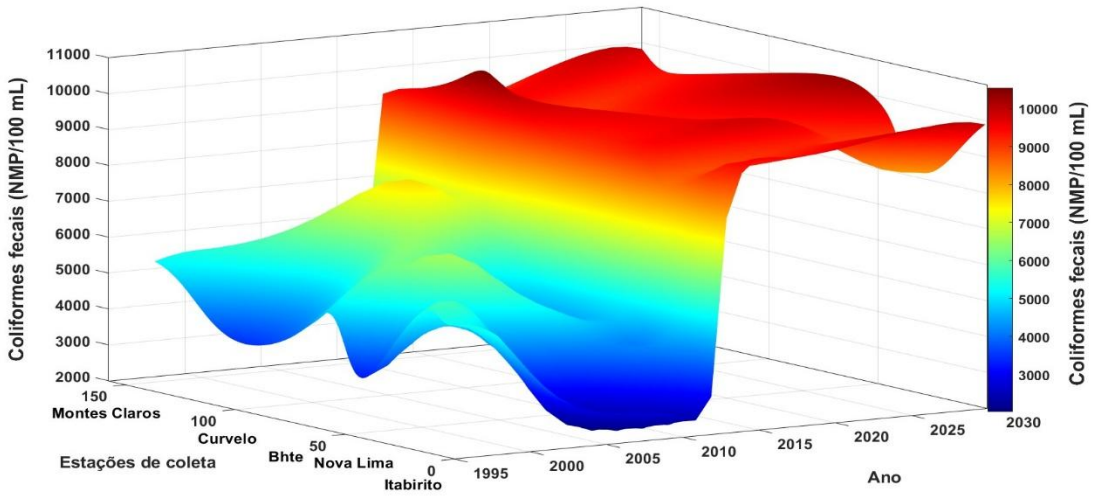

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para o parâmetro ferro, conforme Figura 12, apresentou picos próximos à estação de coleta número 80 (região de Belo Horizonte), com valores próximos a 0,35 mg/L, e para as estações posteriores apresentou redução desses valores para 0,2 mg/L.

Figura 12. Estações de coleta para concentração de ferro.

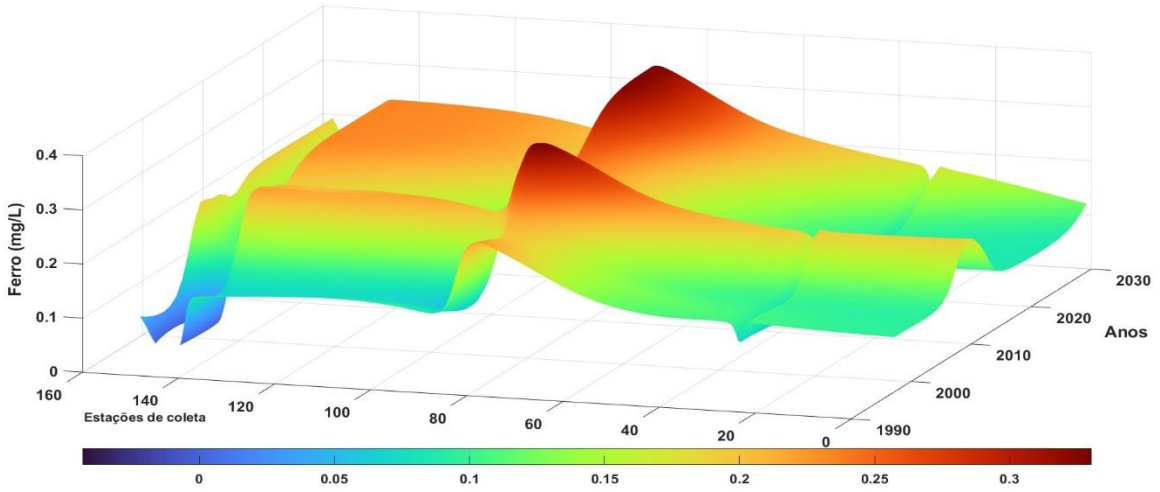

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para os parâmetros sólidos totais dissolvidos, sólidos suspensos e turbidez, conforme Figura 13, apresentaram um aumento significativo no decorrer dos pontos de coleta, possivelmente devido à atividade industrial, à densidade populacional e às descargas de resíduos sólidos e de águas residuais.

Figura 13. Estações de coleta para os parâmetros sólidos totais dissolvidos, sólidos suspensos e turbidez.

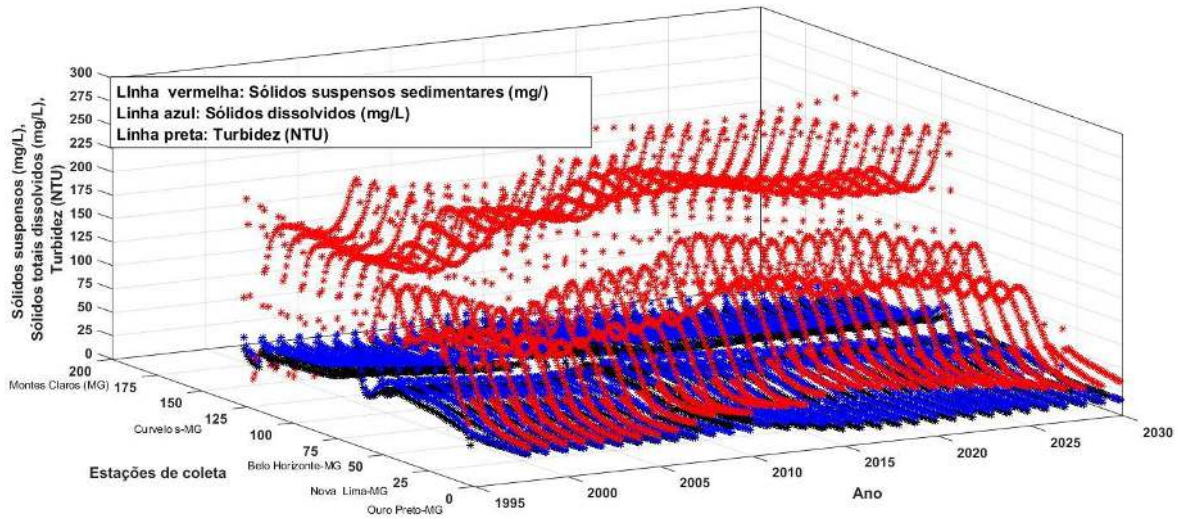

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para o parâmetro temperatura, conforme Figura 14, apresentou baixos valores durante o período do inverno, com temperatura média mínima de 20,5 °C, e máxima de aproximadamente 27,5 °C em média no verão.

Figura 14. Sazonalidade para o parâmetro temperatura.

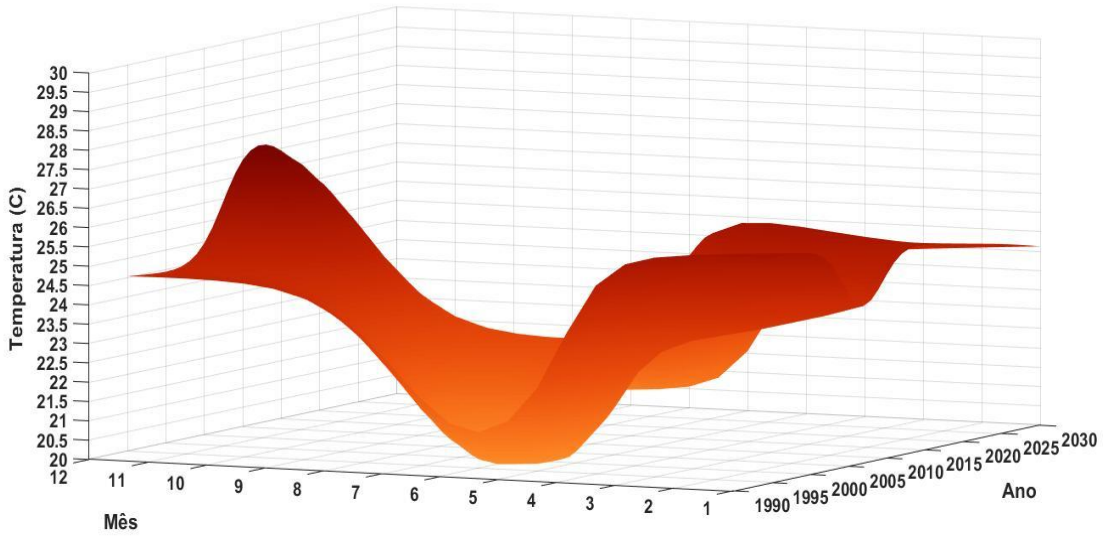

Fonte: Elaborado pelos autores, 2026.

A modelagem preditiva por redes neurais para o parâmetro pH, conforme Figura 15, revela que o pH vem aumentando com o passar dos anos, de 6,8 em média no ano de 1995 para uma previsão de 7,4 em média em 2030, possivelmente devido à atividade industrial, à densidade populacional e às descargas de resíduos sólidos e de águas residuais.

Figura 15. Estações de coleta para o parâmetro pH.

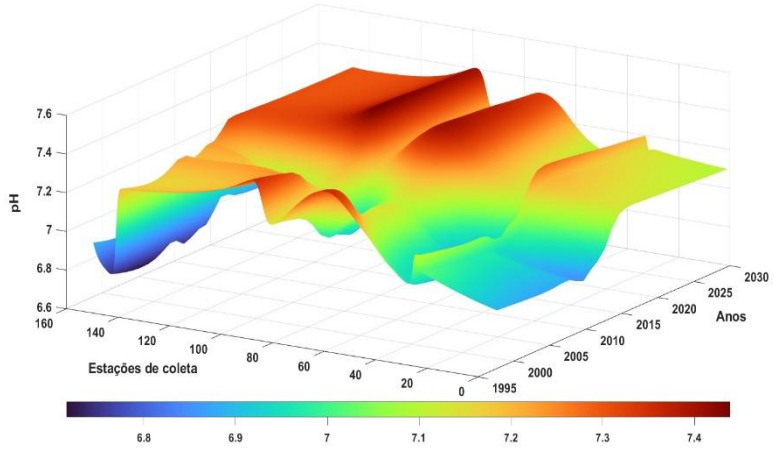

Fonte: Elaborado pelos autores, 2026.

4.3 MAPEAMENTO GEOESPACIAL E MACROZONAS ECOLÓGICAS

A integração do mapeamento geoespacial via rotinas automatizadas em Python com a ordenação das 158 estações ao longo do gradiente altimétrico (da nascente em Ouro Preto à foz em Várzea da Palma/Rio São Francisco) permitiu caracterizar o comportamento do Rio das Velhas como um Reator Bioquímico Linear de Fluxo Contínuo (Plug Flow Reactor).

Figura 16. Mapeamento espacial consolidado do status de oxigenação e macrozonas ecológicas da Bacia do Rio das Velhas.

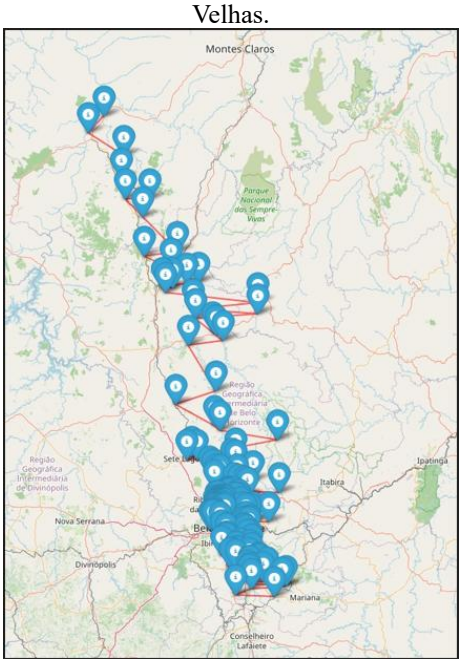

Fonte: Elaborado pelos autores, 2026.

Figura 17. Mapeamento espacial consolidado do status de oxigenação da bacia do Rio das Velhas (médias históricas 1997–2025; não inclui projeção 2026–2030).

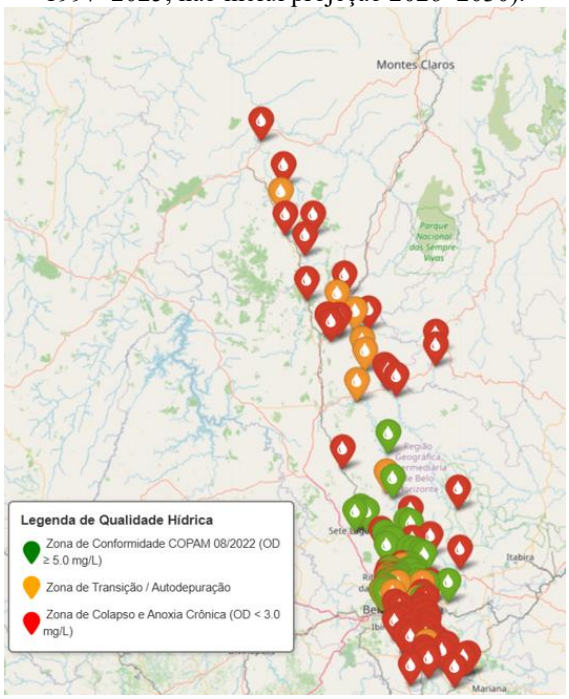

Fonte: Elaborado pelos autores, 2026.

Com base nos parâmetros operacionais de Oxigênio Dissolvido (OD) e DBO, estipulados pela Deliberação Normativa Conjunta COPAM-CERH/MG nº 08/2022 para águas de Classe 2, o sistema hídrico foi segmentado em três macrozonas de comportamento ecológico: a) Zona de Impacto e Colapso Crônico (Alto Rio das Velhas). Abrangência: representa 13,9% das estações de monitoramento, estendendo-se de Ouro Preto e Itabirito, atravessando o eixo da RMBH até a jusante de Sabará e Nova Lima. Diagnóstico: caracteriza-se por estado severo de anóxia ou hipóxia (OD médio < 3,0 mg/L e picos de DBO > 10,0 mg/L); nesta zona, a taxa de desoxigenação bioquímica por esgoto doméstico e efluentes industriais supera expressivamente o coeficiente global de reaeração atmosférica (K2). A transição geomorfológica da Reserva da Biosfera da Serra do Espinhaço e Serra do Gandarela para os centros urbanizados consolida este trecho como o principal receptor de carga poluidora da bacia; b) Zona de Influência da Confluência Cipó-Paraúna (Efeito de Aporte e Diluição). Abrangência: representa 63,9% das estações (zonas de transição e autodepuração). Diagnóstico: a avaliação pontual das estações na calha principal imediatamente anteriores e posteriores à confluência com a sub-bacia do Rio Cipó/Paraúna (região de Curvelo/Presidente Juscelino) comprova empiricamente o papel amortecedor do tributário. Para isolar o efeito real desse aporte sem distorções temporais, analisou-se o período comum de amostragem (2012–2025) entre as 10 estações da calha principal (grupo BV): Sete Lagoas, Pirapora, Ouro Preto, Nova Lima, Brumadinho, Sabará, Belo Horizonte, Ribeirão das Neves, Vespasiano e Curvelo, situadas na vizinhança da confluência, conforme as Tabelas 2 e 3.

Tabela 2. Estações da calha principal utilizadas na avaliação do efeito de confluência.

Estação	Zona de Análise	Município	Altitude (m)
BV156, BV140, BV141	Antes da Confluência	Sete Lagoas	631 – 616
BV162, BV143, BV161	Na Confluência	Curvelo	568 – 557
BV157, BV145, BV150, BV152	Depois da Confluência	Pirapora / Curvelo	551 – 527

Fonte: Elaborado pelos autores, 2026. Adaptado dos pontos de coleta 2012-2025.

Tabela 3. Efeito do aporte de diluição na calha principal do Rio das Velhas (Médias do Período Comum 2012–2025).

Parâmetro	Antes	Na Confluência	Depois	Variação na Confluência	Impacto Imediato
Oxigênio Dissolvido (mg/L)	3,32	4,08	3,53	+22,9%	Melhora expressiva
Arsênio Total (mg/L)	0,245	0,198	0,237	-19,0%	Diluição efetiva
DBO (mg/L)	8,81	8,36	8,70	-5,1%	Redução de carga
Nitrato (mg/L)	1,85	1,73	1,85	-6,0%	Diluição
Fósforo Total (mg/L)	0,699	0,653	0,682	-6,5%	Melhora
DQO (mg/L)	20,55	19,89	20,45	-3,2%	Melhora
Turbidez (NTU)	25,81	26,35	25,96	+2,1%	Ligeiro acréscimo
Óleos e Graxas (mg/L)	16,59	17,64	16,71	+6,3%	Ligeiro acréscimo
Condutividade (µS/cm)	212,1	244,7	217,8	+15,4%	Aumento de sais

Fonte: Elaborado pelos autores, 2026. Adaptado dos dados do IGAM, pontos de coleta 2012-2025.

Os dados comprovam estatisticamente que o aporte de águas de melhor qualidade na confluência promove uma elevação imediata de +22,9% no Oxigênio Dissolvido e atenua as concentrações de Arsênio (-19,0%) e DBO (-5,1%). No entanto, a análise longitudinal a jusante (coluna "Depois") demonstra a reversão parcial desses ganhos, provando que o efeito atenuador do tributário é estritamente local e não substitui a necessidade de controle de fontes poluidoras na calha principal.

c) Frente de Autodepuração e Conformidade Legal (Médio e Baixo Rio das Velhas). Abrangência: representa 22,2% das estações de monitoramento, estendendo-se em direção ao norte do Estado. Diagnóstico: à medida que a massa d'água se afasta do adensamento urbano da RMBH, o decaimento da matéria orgânica por rotas cinéticas heterotróficas, combinado à reaeração natural e aportes diluidores, permite a recuperação dos níveis de oxigenação (OD ≥ 5,0 mg/L), restabelecendo os padrões de Classe 2 da DN COPAM-CERH/MG nº 08/2022 antes do deságue no Rio São Francisco.

A melhoria pontual observada no grupo de estações associadas à bacia da Pampulha alinha-se aos esforços recentes de ampliação do esgotamento sanitário estabelecidos entre BH, Contagem e Copasa (BELO HORIZONTE; COMPANHIA DE SANEAMENTO DE MINAS GERAIS; CONTAGEM, 2022). Contudo, como cobre apenas a fase final da série temporal (1997–2025), a tendência de longo prazo reflete predominantemente a dinâmica de autodepuração do próprio sistema.

A espacialização e as projeções derivadas da RNA fornecem subsídios diretos para a gestão pública e a tomada de decisão em saneamento básico. A delimitação precisa da Zona de Impacto Crônico (13,9% da bacia) fornece respaldo técnico para priorizar investimentos de universalização da

coleta e tratamento de esgoto previstos pelo Novo Marco Legal do Saneamento (Lei Federal nº 14.026/2020), com foco no trecho entre Ouro Preto e a saída da RMBH.

A ocorrência de picos de arsênio em até 0,1565 mg/L e episódios de acidificação (pH < 6,0) reforça a necessidade urgente de bacias de contenção de sedimentos e de fiscalização rigorosa sobre drenagens ácidas de mina no Quadrilátero Ferrífero, evitando o remanejamento de metais pesados durante eventos chuvosos intensos.

A proteção rigorosa de mananciais doadores com a comprovação do ganho de +22,9% em OD promovido pelo complexo Cipó-Paraúna justifica a criação de zonas de proteção ambiental estrita em sua sub-bacia, preservando as matas ciliares e a vazão como mecanismo natural essencial para manter a resiliência hídrica do Rio das Velhas até 2030.

5 CONCLUSÃO

A aplicação da rede neural artificial (RNA), *feedforward* otimizada (R = 0,90) e erro médio quadrático (MSE) de 50,51, provou ser uma ferramenta preditiva eficiente e robusta para a análise integrada da qualidade da água na Bacia do Rio das Velhas no horizonte 1997–2030.

A análise das séries temporais e das projeções do modelo revela que a bacia atravessa um processo de estresse ambiental crônico, caracterizado pela perturbação do seu equilíbrio biogeoquímico. O adensamento metropolitano da Região Metropolitana de Belo Horizonte (RMBH) exerce pressão contínua na calha principal, evidenciada pela convergência entre altos aportes de DBO, DQO, condutividade elétrica e desequilíbrios na dinâmica de nutrientes (fósforo e nitrato). Simultaneamente, a contaminação persistente por metais pesados (arsênio, ferro e manganês) nas sub-bacias tributárias consolida um passivo ambiental associado às atividades minerárias históricas e à remobilização de sedimentos.

O deslocamento da fronteira de impacto em direção às nascentes situadas em áreas de sensibilidade ecológica como a Reserva da Biosfera da Serra do Espinhaço e a Serra do Gandarela sinaliza que a capacidade natural de autodepuração da calha principal atingiu limites críticos.

Neste cenário, a modelagem espaço-temporal do Oxigênio Dissolvido (OD) altera o paradigma tradicional de gestão da bacia ao evidenciar três achados fundamentais com implicação direta para as políticas públicas:

A delimitação da Zona de Impacto e Colapso Crônico no eixo metropolitano concentra o maior déficit de OD da bacia, fornecendo o embasamento técnico para direcionar os investimentos prioritários de expansão do esgotamento sanitário e tratamento de efluentes.

A contaminação crônica por arsênio e metais pesados em sub-bacias específicas exige redes de monitoramento com amostragem ecotoxicológica direcionada e estratégias de contenção de sedimentos, superando a abordagem de monitoramento genérico/agregado.

A manutenção da resiliência hídrica nos trechos médios e baixos depende criticamente da preservação da qualidade d'água de tributários limpos, com destaque para o Rio Cipó. A conservação destes afluentes deixa de ser apenas uma meta preservacionista para se consolidar como um requisito técnico e estratégico de infraestrutura natural para a segurança hídrica de toda a bacia.

Reafirma-se que a modelagem por inteligência artificial via RNAs constitui um instrumento viável, altamente replicável e de elevado valor estratégico para o apoio à tomada de decisão e suporte a políticas públicas em bacias hidrográficas sob múltiplas pressões antrópicas.

Para garantir o uso responsável dos resultados em políticas públicas e a contínua evolução do modelo preditivo, apontam-se as seguintes limitações metodológicas do presente trabalho:

A presença integrada da vazão fluviométrica auxilia na previsão estatística rigorosa entre a variação real de carga poluidora e os efeitos de diluição/concentração causados pela sazonalidade de estiagem e cheias.

A projeção até 2030 baseia-se na tendência espaço-temporal das entradas (ano e mês). Recomenda-se que versões futuras incorporem variáveis exógenas de pressão antrópica (crescimento populacional, uso e ocupação do solo) e estruturas autorregressivas (ex.: arquiteturas NARX).

Identificou-se a necessidade de refinamento prévio da base de dados primária/interpolada para eliminação de eventuais ruídos estatísticos e padronização do cálculo de índices compostos (como o IQA) segundo metodologias oficiais (IGAM/CETESB).

Sugere-se a incorporação sistemática de bandas de incerteza e métricas explícitas de erro (RMSE, MAE) em trabalhos subsequentes, fortalecendo a transparência estatística exigida por corpos revisores e órgãos gestores.

REFERÊNCIAS

BELO HORIZONTE (Município); COMPANHIA DE SANEAMENTO DE MINAS GERAIS (COPASA); CONTAGEM (Município). Plano de Ação para o Sistema de Esgotamento Sanitário da Bacia da Lagoa da Pampulha. Belo Horizonte: Prefeitura Municipal de Belo Horizonte / COPASA, 2022. 33 p. Disponível em: https://prefeitura.pbh.gov.br/sites/default/files/estrutura-de-governo/obras-e-infraestrutura/plano-de-acao-bacia-da-pampulha.pdf. Acesso em: 25 jul. 2026.

GUIMARÃES, A. S.; SILVA, M. C.; PEREIRA, R. F. Aplicação de análise estatística multivariada na avaliação da qualidade da água superficial. Revista Brasileira de Recursos Hídricos, Porto Alegre, v. 25, n. 2, p+. 115-128, abr. 2020.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, v. 5, n. 6, p. 989-993, 1994. DOI: https://doi.org/10.1109/72.329697.

INSTITUTO MINEIRO DE GESTÃO DAS ÁGUAS (IGAM). Boletim Anual de Qualidade das Águas na Bacia Hidrográfica do Rio das Velhas (Ano-base 2022). Belo Horizonte: IGAM, 2023. Disponível em: http://repositorioigam.meioambiente.mg.gov.br/. Acesso em: 27 maio 2026.

INSTITUTO MINEIRO DE GESTÃO DAS ÁGUAS (IGAM). Boletim Anual de Qualidade das Águas na Bacia Hidrográfica do Rio das Velhas (Ano-base 2024). Belo Horizonte: IGAM, 2025. Disponível em: http://repositorioigam.meioambiente.mg.gov.br/. Acesso em: 27 maio 2026.

IRANI, T.; MOSTAFAZADEH, R.; MOUSAVI MOGHANJOGHI, S. Changes in water quality condition at sequential monitoring stations based on IRWQI along the Little Zab River in Northwestern Iran. Scientific Reports, v. 15, n. 1, p. 29583, 2025. DOI: https://doi.org/10.1038/s41598-025-14982-1. Acesso em: 7 jun. 2026.

RAHAT, S. H. et al. Remote sensing-enabled machine learning for river water quality modeling under multidimensional uncertainty. Science of the Total Environment, v. 898, p. 165504, 2023. DOI: https://doi.org/10.1016/j.scitotenv.2023.165504.

SANTOS, J. M.; CARVALHO, L. A.; LIMA, T. O. Técnicas computacionais aplicadas à identificação de padrões e correlações de variáveis físico-químicas em bacias hidrográficas. Engenharia Sanitária e Ambiental, Rio de Janeiro, v. 28, n. 1, p. 45-56, jan./fev. 2023. DOI: https://doi.org/10.1590/S1413-415220220015.

TRINDADE, A. L. C.; ALMEIDA, K. C. B.; BARBOSA, P. E.; OLIVEIRA, S. M. A. C. Tendências temporais e espaciais da qualidade das águas superficiais da sub-bacia do Rio das Velhas, Estado de Minas Gerais. Engenharia Sanitária e Ambiental, Rio de Janeiro, v. 22, n. 1, p. 13-24, jan./fev. 2017. DOI: https://doi.org/10.1590/S1413-41522016143922.

ZHU, M. et al. A review of the application of machine learning in water quality evaluation. Eco-Environment & Health, v. 1, n. 2, p. 107-116, 2022. DOI: https://doi.org/10.1016/j.eehl.2022.06.001.