XXI ENTAC – Encontro Nacional de Tecnologia do Ambiente Construído
14 a 16 de outubro de 2026 | Goiânia-Brasil
DOI: https://doi.org/10.46421/entac.v21i1.8864

Otimização Multiobjetivo de Concretos Geopoliméricos Ácidos Apoiada por Aprendizado de Máquina

Multi-objective Optimization of Acid Geopolymer Concretes Supported by Machine Learning

Lucas Paiva dos Santos
Universidade Federal de Juiz de Fora | Juiz de Fora | Brasil | lucaspaiva@live.com
Aldo Ribeiro de Carvalho
Universidade Federal de Ouro Preto | Ouro Preto | Brasil | aldorcarvalho@outlook.com
Júlia Castro Mendes
Universidade Federal de Juiz de Fora | Juiz de Fora | Brasil | juliacastro.mendes@ufjf.br
Luciana Conceição Dias Campos
Universidade Federal de Juiz de Fora | Juiz de Fora | Brasil | luciana.campos@ufjf.br

Resumo

Este estudo propõe uma abordagem baseada em aprendizado de máquina e otimização evolutiva para a dosagem de concretos geopoliméricos ácidos. Foram produzidos 44 traços com metacaulim e ácido fosfórico, cujas resistências à compressão alimentaram três modelos preditivos (*ANN*, *Random Forest* e *XGBoost*), avaliados por validação cruzada *leave-one-out*. O modelo *ANN* apresentou o melhor desempenho, com R^2 de até 0,86 e previsão de resistência à compressão de até 35,5 MPa (acima do máximo experimental de 30,3 MPa), sendo posteriormente integrado ao algoritmo *NSGA-II* para otimização multiobjetivo, considerando resistência, custo e emissões de CO_2. Os traços com melhor custo-benefício apresentaram resistência média de 32,4 MPa, aparecendo em 44% das iterações. Os resultados demonstram a capacidade da abordagem em reduzir ensaios experimentais e identificar traços mais eficientes, economizando tempo, recursos financeiros e materiais.

Palavras-chave: Concreto Geopolimérico Ácido. Aprendizado de Máquina. Dosagem. Otimização Multiobjetivo

Abstract

This study proposes an approach based on machine learning and evolutionary optimization for the mix design of acid-based geopolymer concretes. A total of 44 mixtures were produced using metakaolin and phosphoric acid, and their compressive strengths were used to train three predictive models (ANN, Random Forest, and XGBoost), evaluated through leave-one-out cross-validation. The ANN model achieved the best performance, with an R^2 of up to 0.86 and predicted compressive strength reaching 35.5 MPa (above the experimental maximum of 30.3 MPa), and was subsequently integrated into the NSGA-II algorithm for multi-objective optimization, considering strength, cost, and CO_2 emissions. The best cost-benefit mixtures showed an average strength of 32.4 MPa, appearing in 44% of the iterations. The results demonstrate the potential of the approach to reduce experimental testing and identify more efficient mixtures, saving time, financial resources, and materials.

Keywords: Acid Geopolymer Concrete. Machine Learning. Mix Design. Multi-objective Optimization.

INTRODUÇÃO

Os geopolímeros são ligantes constituídos de um material precursor sólido de aluminossilicato (rico em alumínio (Al) e silício (Si)) e um material ativador ácido ou alcalino [2]. Dentre os dois tipos, os geopolímeros de ativação básica são os mais consolidados na literatura [3]. Nesse caso, utiliza-se um meio alcalino, com pH elevado, que favorece a quebra e reorganização de materiais ricos em silício, alumínio, formando uma estrutura sólida e tridimensional. Esse processo resulta em um material de matriz densa e elevada resistência mecânica [2].

Os geopolímeros ácidos, por sua vez, representam uma linha mais recente e ainda pouco explorada da tecnologia [4]. Sua síntese consiste nas ligações estabelecidas entre o alumínio, silício e o PO_4 proveniente do ácido fosfórico, desenvolvendo estruturas cristalinas semelhantes a berlinita que conferem resistência ao material [2] [5]. Essa classe tem se mostrado promissora especialmente em aplicações que exigem resistência a ambientes agressivos, como altas temperaturas e exposição a agentes corrosivos [2,5].

Dado ao ineditismo deste tipo de geopolímero, são escassos os estudos que realizam o seu desenvolvimento e, os poucos publicados, concentram-se na formulação de pastas [6]. Dessa forma, a literatura não dispõe de dados consistentes quanto a formulação ideal dos geopolímeros ácidos. Tal cenário decorre, principalmente, das dificuldades associadas à realização de ensaios experimentais envolvendo substâncias perigosas, bem como dos elevados custos dos insumos necessários. Nesse contexto, evidencia-se uma oportunidade promissora para a aplicação de simulações computacionais e algoritmos de inteligência artificial na modelagem e análise desses fenômenos complexos.

Em compósitos cimentícios no geral, a definição do traço é realizada com base em proporções empíricas, apoiando-se na experiência prática acumulada ao longo dos anos, frequentemente utilizando ábacos e tabelas.

Embora os métodos tradicionais de dosagem tenham sido amplamente validados ao longo dos anos, seu principal limite reside na dependência de extensiva experimentação física. Cada novo traço exige dezenas de ensaios para ajustar variáveis como relação água/ligante, tipo de agregado e dosagem de aditivos, um processo que consome tempo, custo operacional e materiais [7]. Em contraste, as técnicas de computação oferecem uma oportunidade de abordagem disruptiva: ao substituir parte dos ensaios laboratoriais por simulações, é possível reduzir significativamente o tempo de desenvolvimento, otimizar o uso de matérias-primas e obter traços com desempenho potencialmente superior.

O aprendizado de máquina destaca-se nesse cenário como uma ferramenta capaz de prever propriedades mecânicas do compósito com precisão. Esses modelos são treinados com dados históricos que relacionam composições de traços a resultados de resistência à compressão, absorção de água e outras características físicas [4,8]. Uma vez calibrados, esses modelos identificam padrões complexos e não lineares entre as variáveis, permitindo prever o comportamento de novos traços, reduzindo a dependência de testes empíricos.

Complementando essa abordagem preditiva, algoritmos bioinspirados, como os genéticos, são ferramentas poderosas de otimização multicritério utilizadas para a dosagem. Inspirados nos princípios da evolução biológica, esses algoritmos trabalham com uma população inicial de soluções (indivíduos), que representam diferentes composições de traços. Cada indivíduo é avaliado por uma função de aptidão, que mede o quão bem ele atende aos objetivos definidos. A partir dessa avaliação, parte dos indivíduos são selecionados para reprodução, passando por processos de cruzamento (combinação de características) e mutação (alterações aleatórias de características), gerando uma nova geração de soluções [9]. Esse ciclo se repete por várias gerações até que o algoritmo convirja para uma solução otimizada equilibrando os critérios estabelecidos [9].

Assim, este trabalho busca suprir lacunas existentes na literatura sobre geopolímeros ácidos por meio da proposição de um modelo de aprendizado de máquina integrado a um algoritmo de otimização, com o objetivo de auxiliar na dosagem de concretos geopoliméricos ácidos. A abordagem proposta visa permitir a otimização simultânea das propriedades mecânicas, do custo e das emissões de CO_2.

MATERIAIS E MÉTODOS

A presente pesquisa foi estruturada em quatro etapas. Inicialmente, foram desenvolvidos, em laboratório, 44 traços de concreto geopolimérico. Em seguida, os materiais foram caracterizados quanto à resistência à compressão, construindo um banco de dados. A terceira etapa consistiu em treinar e avaliar modelos de aprendizado de máquina para encontrar, aquele que consegue predizer a resistência à compressão dos corpos de prova com menor erro. Por último, para otimizar os objetivos utilizou-se o *NSGA-II*. Os objetivos de custo e emissão de CO_2 possuem uma fórmula de soma linear convencional, enquanto o modelo treinado na etapa anterior figura como função objetivo para a resistência à compressão. Não foram estabelecidos critérios mínimos ou máximos para as funções objetivo (ex. custo máximo de R$ 20/m³). Buscou-se apenas validar o modelo proposto, para uso futuro em ensaios laboratoriais.

MATERIAIS

Os materiais utilizados na confecção dos concretos geopoliméricos são areia natural de Rio Preto, (Minas Gerais, brita 0, metacaulim, ácido fosfórico 85% e um Aditivo Incorporador de Ar baseado em Linear Alquil Benzeno Sulfonato de Sódio. O ácido fosfórico foi atenuado até obter uma concentração de 10 mol/L [5] com auxílio de um balão volumétrico e água deionizada. O aditivo incorporador de ar foi adotado para aumentar a trabalhabilidade do material e evitar segregação [10].

MOLDAGEM E CARACTERIZAÇÃO DOS CORPOS DE PROVA

Inicialmente, foram preparados os traços do concreto geopolimérico, em massa, conforme apresentado na Tabela 1.

Tabela 1: Apresentação dos traços desenvolvidos

Identificador	Precursor : areia : brita 0 : L/S	Melhor Resistência (Mpa)	Identificador	Precursor : areia : brita 0 : L/S	Resistência Média (Mpa)
T1	1 : 1 : 0.5 : 0.24	14,8	T23	1 : 1 : 2.5 : 0.32	14,3
T2	1 : 1 : 1 : 0.24	30,3	T24	1 : 1 : 3 : 0.32	15,94
T3	1 : 1 : 1.5 : 0.24	23,1	T25	1 : 2 : 0.5 : 0.32	15,33
T4	1 : 1 : 2 : 0.24	22,3	T26	1 : 2 : 1 : 0.32	20,14
T5	1 : 1 : 2.5 : 0.24	18	T27	1 : 2 : 1.5 : 0.32	18,61
T6	1 : 1 : 3 : 0.24	17,6	T28	1 : 2 : 2 : 0.32	15,33
T7	1 : 2 : 0.5 : 0.24	11,3	T29	1 : 2 : 2.5 : 0.32	15,22
T8	1 : 2 : 1 : 0.24	18	T30	1 : 2 : 3 : 0.32	14,1
T9	1 : 2 : 1.5 : 0.24	15,7	T31	1 : 3 : 0.5 : 0.32	13,35
T10	1 : 2 : 2 : 0.24	14,1	T32	1 : 3 : 1 : 0.32	17,17
T11	1 : 2 : 2.5 : 0.24	11,8	T33	1 : 3 : 1.5 : 0.32	14,98
T12	1 : 2 : 3 : 0.24	5,2	T34	1 : 3 : 2 : 0.32	13,45
T13	1 : 3 : 0.5 : 0.24	8,1	T35	1 : 3 : 2.5 : 0.32	8,26
T14	1 : 3 : 1 : 0.24	10,8	T36	1 : 3 : 3 : 0.32	4,96
T15	1 : 3 : 1.5 : 0.24	9,4	T37	1 : 1 : 0.5 : 0.4	9,3
T16	1 : 3 : 2 : 0.24	8,1	T38	1 : 1 : 1 : 0.4	9,9
T17	1 : 3 : 2.5 : 0.24	6,2	T39	1 : 1 : 1.5 : 0.4	7,7
T18	1 : 3 : 3 : 0.24	3,3	T40	1 : 1 : 2 : 0.4	7,2
T19	1 : 1 : 0.5 : 0.32	13,08	T41	1 : 1 : 2.5 : 0.4	5,1
T20	1 : 1 : 1 : 0.32	23,17	T42	1 : 1 : 3 : 0.4	4,8
T21	1 : 1 : 1.5 : 0.32	20,64	T43	1 : 2 : 0.5 : 0.4	2,9
T22	1 : 1 : 2 : 0.32	15,74	T44	1 : 2 : 1 : 0.4	6,2

Fonte: os autores.

Esses traços foram pensados como pontos de amostragem de grade, para posterior busca dos algoritmos de otimização dos traços intermediários. Mantendo-se o precursor (metacaulim) como referência (1), de forma análoga ao cimento Portland, foi variada a proporção de areia entre 1; 2 e 3; de brita entre 0,5; 1; 1,5; 2; 2,5 e 3; e de relação L/S em 0,24; 0,32 e 0,40. Esses valores foram definidos conforme protótipos testados anteriormente, e resultaram em resistências variando entre 2,2 e 30,3 MPa. Os corpos de prova foram moldados em formas cilíndricas de PVC (devido ao caráter ácido do compósito) com dimensões de 5x10 cm. Para os ensaios de resistência à compressão foi utilizado uma prensa hidráulica aos 28 dias, seguindo a ABNT NBR 13279 [11].

PROCEDIMENTO COMPUTACIONAL

Para a condução dos experimentos, desenvolveu-se um programa principal em Python, estruturado de forma modular para avaliar múltiplos modelos de aprendizado de máquina e distintos objetivos de otimização. Os modelos preditivos foram implementados com o auxílio da biblioteca *scikit-learn*, enquanto os procedimentos de otimização foram conduzidos por meio da biblioteca *pymoo*. O código-fonte encontra-se disponível aqui.

Durante a execução, definem-se dois elementos principais: o modelo de aprendizado de máquina para predição da resistência à compressão e o conjunto de objetivos de otimização. Inicialmente, o programa carrega o conjunto de dados e executa o treinamento do modelo selecionado. A qualidade do modelo é avaliada por meio do método leave-one-out, calculando-se as métricas de desempenho R^2 e *RMSE*.

Foram avaliados três algoritmos de aprendizado supervisionado para predição da resistência à compressão: *Artificial Neural Networks* (*RNA*), *Random Forest* (*RF*) e *Extreme Gradient Boosting* (*XGBoost*). Destaca-se que o escopo metodológico não incluiu a busca pela otimização da parametrização de cada algoritmo. Em vez disso, optou-se por estabelecer uma base de comparação entre eles a partir do uso de parâmetros deliberadamente simples e genéricos.

VALIDAÇÃO DOS MODELOS

Para cada um dos algoritmos desenvolvidos foi empregada a *Leave-One-Out Cross Validation* (*LOOCV*), abordagem viável devido ao pequeno tamanho do banco de dados utilizado neste estudo, na qual cada amostra é utilizada individualmente como conjunto de teste enquanto todas as demais compõem o conjunto de treinamento.

Uma vez treinado e validado, o modelo preditivo passa a atuar como função objetivo dentro do processo de otimização, enquanto, o(a) usuário(a) pode selecionar os objetivos de minimização do custo e das emissões de CO_2, calculados por meio de expressões determinísticas baseadas nas proporções dos materiais que compõem o traço; (Fórmulas 1 e 2). Não foram atribuídos pesos específicos para cada objetivo, eles foram considerados equivalentes.

O metacaulim passa por processos industriais em sua produção, entre eles, a etapa de calcinação, que emite CO_2 em função da energia demandada. Para considerar essa etapa na análise do processo, foi usada a base EcoInvent e observado que o uso de cada quilograma de metacaulim emite 0,265 kg de CO_2 equivalente. A partir desta mesma base foram obtidos os valores de emissão de CO_2 equivalente por kg da areia natural (0,00524 kg), da brita (0,00533 kg) e do ácido fosfórico (1,39 kg). Os custos associados a unidade funcional de 1 kg foram obtidos por meio de sites de varejo com base no mês de março de 2026. O metacaulim custa R$ 4,00 por kg; enquanto a areia custa R$ 0,15; a brita, R$ 0,15 e o ácido fosfórico R$ 61,52.

Fórmula 1 e 2: fórmulas da emissão de CO_2 e custo.

$$Emissão = 0{,}265 \cdot metacaulim + 0{,}000524 \cdot areia + 0{,}00533 \cdot brita + 1{,}39 \cdot ácido$$

$$Custo = 4 \cdot metacau\,lim + 0{,}15 \cdot areia + 0{,}15 \cdot brita + 61{,}52 \cdot ácido$$

OTIMIZAÇÃO

Para a otimização foi utilizado o algoritmo *NSGA-II* (*Non-dominated Sorting Genetic Algorithm II*), um método evolutivo amplamente aplicado em problemas de otimização multiobjetivo. O algoritmo trabalha com uma população de soluções candidatas que evolui ao longo de diversas gerações por meio de operadores genéticos como seleção, cruzamento e mutação. A classificação das soluções é realizada com base no conceito de dominância de Pareto, organizando os indivíduos em diferentes níveis de não dominância.

Durante esse processo evolutivo, o sistema registra o histórico das soluções não dominadas encontradas em cada geração, armazenando as sucessivas fronteiras de Pareto obtidas ao longo da execução em um arquivo .json para análise subsequente.

RESTRIÇÕES APLICADAS AOS MODELOS

Devido à natureza estocástica dos algoritmos de aprendizado de máquina empregados na predição da resistência à compressão, o experimento não resulta em uma única fronteira de Pareto contendo as soluções ótimas. Em vez disso, cada execução produz fronteiras ligeiramente distintas entre si. Assim, torna-se necessária a aplicação de critérios de restrição, com o objetivo de identificar os traços mais relevantes para estudos futuros.

Dessa forma, foram adotadas duas restrições: Primeiramente, consideram-se válidos apenas os modelos que atingem um coeficiente de determinação (R^2) mínimo de 0,8. Em segundo lugar, são considerados válidos apenas os traços que são encontrados em pelo menos 20% das execuções do experimento.

Para a primeira restrição, o programa utiliza um parâmetro configurável que define o valor mínimo de R^2. Esse parâmetro é empregado como critério de parada durante a etapa de treinamento: o programa treina um modelo utilizando uma semente aleatória. Caso o modelo atinja o valor mínimo de R^2 estabelecido, o fluxo do programa segue para a etapa de otimização. Caso contrário, uma nova semente é sorteada e o processo é repetido, até que o desempenho desejado seja alcançado ou seja atingido o limite de 100 tentativas.

O valor de $R^2 = 0,8$ se baseia na análise da literatura realizada por Carvalho et al. [4], na qual o coeficiente de determinação é apontado como uma das principais métricas para avaliar modelos preditivos aplicados a materiais geopoliméricos. Assim, adotou-se esse valor como limite mínimo por representar um desempenho satisfatório, indicando que o modelo explica parte majoritária da variabilidade dos dados antes de ser utilizado na etapa de otimização, conforme aferido por Carvalho et al. [4]. O fluxo descrito está representado na Figura 1.

Figura 1: Fluxograma do programa principal.

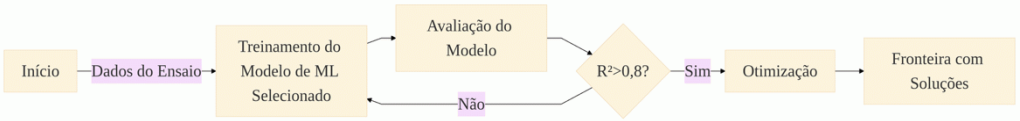

Fonte: os autores.

Para a aplicação da segunda restrição, foi necessário registrar a frequência de ocorrência de cada traço ao longo das execuções. Para isso, as proporções dos componentes foram arredondadas com precisão de uma casa decimal.

RESULTADOS

AVALIAÇÃO DOS MODELOS DE APRENDIZADO DE MÁQUINA

Durante os experimentos, observou-se que o algoritmo *Random Forest* apresentou o pior desempenho, não atingindo o limiar mínimo estabelecido. Ao longo de 50

execuções independentes, o modelo alcançou um R^2 máximo de 0,74, mesmo após 100 tentativas de treinamento em cada execução, não alcançando o R^2 mínimo estipulado, de 0,80. Em função disso, o *Random Forest* foi descartado das etapas de otimização. Em contrapartida, os modelos *Extreme Gradient Boosting* (*XGBoost*) e a rede *Multilayer Perceptron* (*MLP*) apresentaram desempenho satisfatório, com coeficientes superiores ao critério estabelecido, sendo, portanto, selecionados para a etapa seguinte. A Tabela 2 apresenta os valores de R^2 obtidos por cada modelo avaliado.

Tabela 2: Comparativo entre os modelos avaliados

Nome	R^2 Máximo	RMSE Mínimo	Pontos na Fronteira de Pareto
Random Forest	0,74	3,02	Modelo Descartado
Xgboost	0,82	2,51	2
Rede Neural (ANN)	0,86	2,32	10

Fonte: os autores.

A comparação com estudos voltados à previsão de resistência em geopolímeros de ativação básica é particularmente relevante por tratar de materiais de natureza semelhante, embora com diferenças fundamentais nos mecanismos de ligação e na disponibilidade de dados. Li et al. desenvolveram um *framework* para concreto geopolimérico de escória e cinza volante, combinando quatro algoritmos, *GPR*, *Random Forest*, *Gradient Boosting* e *BPNN,* treinados sobre 143 amostras. O *Random Forest* alcançou R^2 entre 0,554 e 0,80 dependendo da configuração, resultado consistente com o desempenho insatisfatório observado para o mesmo algoritmo nesta pesquisa [12]. Essa convergência de resultados sugere que o *Random Forest* apresenta limitações para este contexto quando aplicado a bases de dados de dimensão reduzida, independentemente do tipo de ativação utilizado.

Os resultados preditivos obtidos neste trabalho também podem ser confrontados com estudos análogos voltados ao tradicional concreto de cimento Portland. Nesses contextos, a disponibilidade de bases de dados consolidadas e extensas permite que os modelos de aprendizado de máquina operem em condições consideravelmente mais favoráveis. Mondal desenvolveu um framework para dosagem de concreto de alta resistência com adição de cinza de casca de arroz, empregando múltiplos algoritmos [13]. Com base em 80 traços, foi possível alcançar coeficientes de determinação superiores a 0,95 com erros consistentemente baixos. Comparativamente, o presente estudo avaliou esses algoritmos com apenas 44 amostras experimentais alcançando, em dois casos, o R^2 de 0,80 como critério de aceitação [5].

OTIMIZAÇÃO MULTIOBJETIVO

Na etapa de otimização multiobjetivo, os modelos selecionados (*XGBoost* e *MLP*) foram integrados ao algoritmo *NSGA-II* para a construção de fronteiras de Pareto, considerando simultaneamente os três objetivos.

Observou-se que o modelo *XGBoost*, com parametrização simples, apresentou limitações na exploração do espaço de soluções, convergindo consistentemente para uma fronteira de Pareto composta por apenas duas soluções não dominadas. Ambas

já eram conhecidas e correspondem a traços apresentados na Tabela 1 e na Tabela 3: uma solução associada à minimização de custo e emissões (traço T1) e outra voltada à maximização da resistência à compressão (traço T2).

Tabela 3: Fronteira de Pareto encontrados pelo XGboost

Identi-ficador	Precursor : areia : brita 0 : L/S	Resistência Média (Mpa)	Identi-ficador	Precursor : areia : brita 0 : L/S	Resistência Média (Mpa)
T1	1 : 1 : 0.5 : 0.24	14,2	T23	1 : 1 : 2.5 : 0.32	13,84
T2	1 : 1 : 1 : 0.24	28,35	T24	1 : 1 : 3 : 0.32	14,77

Fonte: os autores.

Por outro lado, a *MLP* gerou, em cada execução, fronteiras de Pareto mais diversificadas, compostas por 10 soluções não dominadas (um exemplo é apresentado na Tabela 4), além de resistências superiores à maior resistência experimental, indicando uma melhor previsão da tendência geral de comportamento dos dados. Esse aumento no número de soluções em relação ao *XGBoost* indica uma maior exploração do espaço de busca por parte da rede neural, permitindo a identificação de múltiplas alternativas ao longo do *trade-off* entre os objetivos considerados.

Tabela 4: Exemplo de Fronteira de Pareto encontrada pela ANN

Identificador	Resistência (MPa)	Custo (R$)	Emissão CO_2 ($KgCO_{2eq}$)	Traço apontado (Precursor : areia : brita 0 : L/S)
P1	**32.11**	**19.91**	**0.63**	**1 : 1.1 : 0.9 : 0.25**
P2	14.81	18.98	0.60	1 : 1 : 0.5 : 0.24
P3	**32.10**	**19.91**	**0.62**	**1 : 1 : 0.91 : 0.25**
P4	24.37	19.02	0.60	1 : 1 : 0.75 : 0.24
P5	31.31	19.38	0.61	1 : 1 : 0.98 : 0.24
P6	31.52	19.64	0.62	1: 1 : 0.99 : 0.25
P7	30.20	19.06	0.60	1 : 1 : 0.97 : 0.24
P8	18.13	18.99	0.60	1 : 1 : 0.55 : 0.24
P9	**31.63**	**19.71**	**0.62**	**1 : 1 : 0.91 : 0.25**
P10	30.77	19.15	0.61	1 : 1 : 0.98 : 0.24

Fonte: os autores.

Também é observado um resultado relevante no que tange a frequência de ocorrência dos traços otimizados. Em particular, os traços correspondentes aos pontos P1, P3 e P9 da Tabela 4 não surgem de forma ocasional, mas estão presentes em 44% das execuções do algoritmo. A recorrência indica que tais soluções são estáveis, e não decorrentes de flutuações estocásticas do processo de otimização, reforçando sua relevância pratica para ensaios futuros.

O traço de maior resistência observado experimentalmente apresentou resistência de 30,3 MPa, com custo de R$ 19,06 e emissão de 0,61 kg CO_2, por kg de material produzido. Em comparação, o traço otimizado destacado atinge resistência média de 32,40 MPa, representando um aumento de aproximadamente 6,9%, enquanto o custo se eleva para cerca de R$ 19,70 (+3,4%) e a emissão para aproximadamente 0,62 kg CO_2 (+1,6%).

Em termos de métricas de eficiência, a eficiência custo-resistência (MPa/R$) evolui de aproximadamente 1,59 no melhor traço experimental para cerca de 1,64 no traço otimizado, enquanto a eficiência ambiental aumenta de aproximadamente 49,7 para 52,3 MPa/kgCO_2. Por fim, ao considerar o ganho relativo em relação à base experimental, observa-se que o modelo foi capaz de extrapolar o espaço de soluções originalmente ensaiado, obtendo um incremento de 6,9% na resistência à compressão, mantendo aumentos marginais de custo e impacto ambiental.

Adicionalmente, a diversidade de soluções viáveis e inéditas sugere que a MLP, mesmo com configuração deliberadamente simples, conseguiu generalizar o comportamento do material sem memorizar os dados de treinamento. Durante o processo de otimização, identificou-se a presença de máximos locais distintos para os objetivos avaliados, o que justifica a distribuição e a acomodação dos pontos ao longo da curva. Não foi identificado na literatura, até o momento, estudos de otimização da dosagem de concretos geopoliméricos ácidos. Expandindo a análise para os compósitos baseados em cimento Portland, observa-se que a adoção de estratégias multiobjetivo tem trazido benefícios significativos. Em estrutura metodológica próxima à deste trabalho, Afshan & Ramezanianpour propuseram a otimização da substituição de zeólita em concreto estrutural integrando uma Rede Neural Artificial ao algoritmo *NSGA-II*, com os objetivos simultâneos de resistência, custo e potencial de aquecimento global [14]. A otimização multiobjetivo elevou o nível ótimo de substituição de zeólita de 15,5% (foco único na resistência) para 24% quando os três critérios foram ponderados conjuntamente.

CONCLUSÃO

O estudo demonstrou a eficácia da integração da rede neural MLP com algoritmos de otimização evolutiva, como o *NSGA-II*, oferecendo uma alternativa à dependência exclusiva de métodos empíricos tradicionais na dosagem de geopolímeros ácidos. Durante a etapa de otimização, o traço que mais se destacou na pesquisa foi o de proporções de [1:1:0.9:0.25]. Esse traço evidenciou um *trade-off* bastante favorável a composição tem sua resistência prevista média de 32,40 MPa, o que representa um incremento de 6,9% em relação ao melhor traço experimental. O ganho expressivo na propriedade mecânica foi obtido com um aumento marginal e proporcionalmente inferior nos outros objetivos, elevando o custo em apenas 3,4% (R$ 19,70) e as emissões em 1,6% (0,62 kgCO_2), por kg de material produzido.

Como pesquisa pioneira na aplicação de inteligência artificial a geopolímeros ácidos, a metodologia viabiliza o avanço tecnológico desse ligante sustentável ao identificar traços mais eficientes e reduzir a necessidade de ensaios laboratoriais dispendiosos. No futuro, a equipe de pesquisa pretende validar experimentalmente os traços obtidos por meio do modelo desenvolvido.

DECLARAÇÃO

Durante a confecção deste artigo os autores utilizaram o ChatGPT para verificação e aperfeiçoamento gramatical. Após a utilização da(s) ferramenta/serviço, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado.

REFERÊNCIAS

[1] TURKOGLU, M. et al. Effect of cement clinker type, curing regime and activator dosage on the performance of one-part alkali-activated hybrid slag/clinker composites. Journal of Building Engineering, 2023. DOI: https://doi.org/10.1016/j.jobe.2023.106164

[2] KAZE, C. R. et al. Mechanical and physical properties of inorganic polymer cement made of iron-rich laterite and lateritic clay: A comparative study. Cement and Concrete Research, 2021. DOI: https://doi.org/10.1016/j.cemconres.2020.106320

[3] DAVIDOVITS, J. Geopolymer: Chemistry and Applications. Geopolymer Institute, 2020.

[4] CARVALHO, A. R. D. et al. Exploratory literature review and scientometric analysis of artificial intelligence applied to geopolymeric materials. Engineering Applications of Artificial Intelligence, 2025. DOI: https://doi.org/10.1016/j.engappai.2025.110210

[5] CARVALHO, A. R. D. et al. Proposition of geopolymers obtained through the acid activation of iron ore tailings with phosphoric acid. Construction and Building Materials, 2023. DOI: https://doi.org/10.1016/j.conbuildmat.2023.133078

[6] LOUATI, S. et al. Geopolymers Based on Phosphoric Acid and Illito-Kaolinitic Clay. Advances in Materials Science and Engineering, 2016. DOI: https://doi.org/10.1155/2016/2359759

[7] PAIXÃO, R. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. Revista IBRACON de Estruturas e Materiais, 2022. DOI: https://doi.org/10.1590/s1983-41952022000500003

[8] PAIXÃO, R. et al. Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. Revista IBRACON de Estruturas e Materiais, 2022. DOI: https://doi.org/10.1590/s1983-41952022000500003

[9] SCHMITT, L. M. Theory of genetic algorithms. Theoretical Computer Science, 2001. DOI: https://doi.org/10.1016/S0304-3975(00)00406-0

[10] MENDES, J. C. et al. Mechanical, rheological and morphological analysis of cement-based composites with a new LAS-based air entraining agent. Construction and Building Materials, 2017. DOI: https://doi.org/10.1016/j.conbuildmat.2017.04.024

[11] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCINICAS – NBR:13279 Argamassa para assentamento e revestimento de paredes e tetos – Determinação da resistência à tração na flexão e à compressão. Rio de Janeiro, 2005.

[12] LI, Y. et al. Optimization design for alkali-activated slag-fly ash geopolymer concrete based on artificial intelligence considering compressive strength, cost, and carbon emission. Journal of Building Engineering, 2023. DOI: https://doi.org/10.1016/j.jobe.2023.106929

[13] MONDAL, A. Optimized mix design of rice husk ash blended high-strength concrete through machine learning models. Next Research, 2026. DOI: https://doi.org/10.1016/j.nexres.2026.101567

[14] AFSHAN, A. G. et al. Optimization of zeolite replacement in concrete mix design based on mechanical, economic, and environmental criteria using machine learning and metaheuristic algorithms. Engineering Applications of Artificial Intelligence, 2026. DOI: https://doi.org/10.1016/j.engappai.2026.114343