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.v21i1.8742

Inteligência computacional aplicada ao proporcionamento de pastas cimentícias com resíduos como materiais cimentícios suplementares

Computational intelligence applied to the proportioning of cementitious pastes with waste as supplementary cementitious materials

Melissa Pastorini Proença
Universidade Federal do Paraná e Instituto Federal do Paraná | Foz do Iguaçu | Brasil | melissa.proenca@ifpr.edu.br
Edna Possan
Universidade Federal da Integração Latino-Americana | Foz do Iguaçu | Brasil | epossan@gmail.com
Emerson Felipe Félix
Universidade Estadual Paulista | Guaratinguetá | Brasil | emerson.felix@unesp.br
Nayara Soares Klein
Universidade Federal do Paraná| Curitiba | Brasil | nayaraklein@gmail.com

Resumo

No contexto de utilizar o aprendizado de máquinas como estratégia para a dosagem de materiais cimentícios suplementares (MCS), considerando a ampla variabilidade de características destes materiais, este estudo desenvolveu e validou um modelo baseado em florestas aleatórias e algoritmo genético para o proporcionamento de pastas com resíduos como MCS. Foi utilizado um banco de dados com 135 amostras e 25 parâmetros relacionados às características físico-químicas dos materiais e das pastas. Os MCS analisados incluíram pó de concreto (PC), pó de resíduos de construção mistos (PM) e metacaulim (MK). O modelo foi estruturado a partir do mapeamento da classe de resistência, considerando três cenários com diferentes conjuntos de entrada (11, 18 e 24 variáveis). O cenário com 11 variáveis apresentou melhor desempenho, com acurácia de 93% no treinamento e 70% no teste. O modelo foi integrado a algoritmo genético para otimizar o proporcionamento, reduzindo o consumo de cimento e atendendo à resistência requerida. Na validação experimental, as pastas superaram a classe alvo, evidenciando o potencial da inteligência artificial para avaliação de MCS e redução de ensaios experimentais.

Palavras-chave: Cimentos ecoeficientes. Otimização. Florestas aleatórias. Baixo carbono. Pó de RCD.

Abstract

In the context of using machine learning as a strategy for the mix design of supplementary cementitious materials (SCM), considering the wide variability in their properties, this study developed and validated a model based on random forest and a genetic algorithm for proportioning cement pastes containing waste-derived SCM. A database comprising 135 samples and 25 parameters related to the physicochemical characteristics of the materials and pastes was used. The SCM analyzed included concrete powder (CP), mixed construction and demolition waste powder (MP), and metakaolin (MK). The model was structured based on strength class mapping, considering three scenarios with different input sets (11, 18, and 24 variables). The scenario with 11 variables showed the best performance, achieving an accuracy of 93% during training and 70% during testing. The model was integrated with a Genetic Algorithm to optimize mix proportions, reducing cement consumption while meeting the required strength. Experimental validation showed that the pastes exceeded the target strength class, demonstrating the potential of artificial intelligence as a tool for SCM evaluation and for reducing the need for experimental testing.

Keywords: Eco-efficient cement. Optimization. Random forests. Low carbon. CDW Powder.

PROENÇA, M.; POSSAN, E.; FÉLIX, E. F.; KLEIN, N. Inteligência computacional aplicada ao proporcionamento de materiais cimentícios suplementares: estudo em pastas. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. **Anais**... Goiânia: ANTAC, 2026.

DOI: https://doi.org/10.46421/entac.v21i1.8742

INTRODUÇÃO

A redução do fator clínquer através do uso de materiais cimentícios suplementares (MCS) é a principal estratégia para mitigar as emissões de carbono associadas à produção cimenteira [1,2]. Para se produzir uma tonelada de clínquer, são emitidas 0,84 a 1,05 toneladas de dióxido de carbono [3], o que torna a diminuição do teor de clínquer no cimento Portland uma meta central de descarbonização do setor. Atualmente, o fator clínquer médio mundial é de 0,76 [4] e para 2050 tem-se a previsão de 0,52 [5].

Os MCS atuam de diferentes formas na matriz cimentícia, sendo pozolânicos [6,7], hidráulicos [8] ou inertes (com efeito fíler) [9]. Convencionalmente, são mais explorados materiais ativos, como escórias de alto-forno, cinza volante, sílica ativa e metacaulim, que podem melhorar a durabilidade, a resistência e a trabalhabilidade da matriz [10]. Estima-se que, a longo prazo, a disponibilidade destes MCS convencionais será insuficiente para atender à indústria, reforçando a necessidade de novas fontes [9]. Consequentemente, observa-se uma crescente diversidade de materiais sendo estudados, com ampla variabilidade de características [11], sendo indispensável o correto proporcionamento destes, face às contribuições e prejuízos que podem causar à matriz [12]. Considerando a heterogeneidade, características físico-química e as diferentes interações associadas, atualmente a definição da quantidade de MCS na mistura cimentícia é complexa, exigindo extensas campanhas experimentais para o proporcionamento adequado do MCS [2,12].

Historicamente os processos de dosagem das misturas cimentícias consistem em modelos analíticos e fórmulas empíricas baseadas em testes físicos, porém essa abordagem tem dificuldade em capturar as relações complexas entre diferentes componentes das misturas [13]. Como solução, a utilização de técnicas de inteligência artificial pode ser estratégica na otimização, com capacidade de processar relações não lineares e captar padrões entre variáveis de grandes conjuntos de dados [14]. Assim, o presente estudo tem como proposito avaliar a eficiência do uso combinado de Florestas Aleatórias com a técnica de otimização com algoritmos genéticos no proporcionamento otimizado de pastas cimentícias com distintos MCS, buscando a redução do consumo de cimento Portland sem comprometer as propriedades mecânicas das matrizes.

MÉTODO

O estudo divide-se em 3 etapas: modelagem da classe de resistência das pastas, otimização multicritério por meio de algoritmos genéticos e análise da aplicabilidade da ferramenta, com validação experimental (Figura 1).

Figura 1: Etapas do método

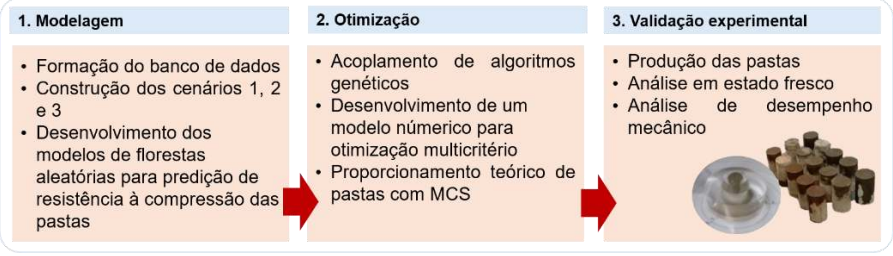

Fonte: os autores.

MODELAGEM DA CLASSE DE RESISTÊNCIA

Nesta etapa, fez-se a coleta e compilação de 135 dados de pastas cimentícias com um ou mais MCS, oriundos dos trabalhos de Oliveira, 2022 [15], Campos, 2019 [16], Proença, 2023 [17], Vaiciukyniené *et al.* 2020 [18], Cyr *et al.* 2014 [19]. Após a catalogação dos dados, definiram-se 24 parâmetros de entrada que incluem as características físico-químicas do cimento Portland dos MCS e informações das pastas (Quadro 1). A variável de saída (resistência à compressão axial aos 28 dias) foi definida considerando variável discreta com 4 classes (0, 1, 2 e 3) com a divisão da resistência à compressão em intervalos de 10 MPa 0 (10 – 19 MPa), 1 (20 – 29 MPa), 2 (30 – 39 MPa) e 3 (>40 MPa) (Figura 2).

Quadro 1: Variáveis do estudo

Variáveis de entrada		Descrição	Mínimo	Máximo	Unidade	Variável de saída
Cimento Portland	CPMe	Massa específica	3.05	3.23	g/cm³	Classe de resistência à compressão
	CPd50	Diâmetro médio das partículas	6	10.5	µm	
	CPBlaine	Finura Blaine	3050	5750	cm²/g	
	CPBET	Área de superfície específica BET	3.14	4.5	m²/kg	
	CP%Cálcio	Percentual de óxido de cálcio	47.2	66	%	
	CP%Sílica	Percentual de dióxido de silício	16.47	21.36	%	
Material cimentício suplementar (1)	M1Me	Massa específica	0	2.96	g/cm³	
	M1d50	Diâmetro médio das partículas	0	58	µm	
	M1Blaine	Finura Blaine	0	6660	cm²/g	
	M1BET	Área de superfície específica BET	0	301	m²/kg	
	M1%Cálcio	Percentual de óxido de cálcio	0	50.12	%	
	M1%Sílica	Percentual de dióxido de silício	0	67.1	%	
Material cimentício suplementar (2)	M2Me	Massa específica	0	2679	g/cm³	
	M2d50	Diâmetro médio das partículas	0	75	µm	
	M2Blaine	Finura Blaine	0	11570	cm²/g	
	M2%Cálcio	Percentual de óxido de cálcio	0	30.3	%	
	M2%Sílica	Percentual de dióxido de silício	0	63.34	%	
Mistura	Classes granulares	Número de classes granulares, pastas com apenas 1 classe: 1, pastas com 2 classes: 2, e pastas com 3 classes: 3	1	3	–	
	SPConsumo	Consumo de superplastificante	0	28.26	kg/m³	
	Água/finos	Relação água/finos	0.07	0.57	–	
	CPConsumo	Consumo de cimento Portland	822	2600	kg/m³	
	M1Consumo	Consumo de material cimentício suplementar 1	0	1021	kg/m³	
	M2Consumo	Consumo do material cimentício suplementar 2	0	713.6	kg/m³	
	MixEmp	Densidade de empacotamento	0.5	0.66	–	

*1 e 2 referentes ao primeiro (1) e segundo (2) MCS (no caso de misturas ternárias).
Fonte: os autores.

Figura 2: Distribuição das classes de resistência das pastas de cimento Portland

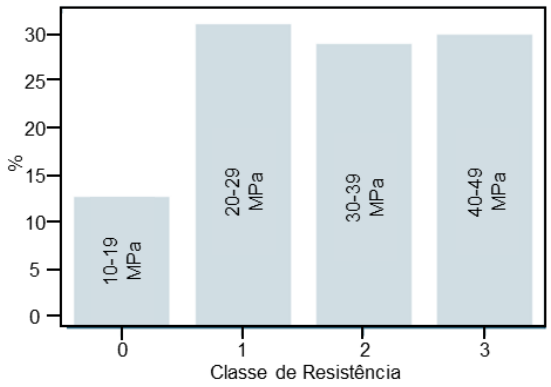

Fonte: os autores.

Foram definidos diferentes cenários de parâmetros de entrada utilizados nas modelagens, trabalhando-se com três diferentes condições. Primeiro cenário: a modelagem conduzida com todos os parâmetros compondo as entradas do modelo (24 variáveis de entrada). No segundo cenário, considera-se que o cimento Portland possui um processo produtivo padronizado, atendendo a requisitos pré-estabelecidos, sendo removidas as características físico-químicas do cimento Portland, abrangendo 18 variáveis de entrada. Para o cenário 3 (com 11 variáveis de entrada), manteve-se apenas os consumos de materiais, quantidade de classes granulares, relação água/finos, empacotamento da mistura, massa específica e d50 dos MCS.

Desenvolveu-se modelos de florestas aleatórias (FA) para os três cenários (FA1, FA2 e FA3), sendo os dados divididos em treinamento (70%) e teste (30%), com amostragem estratificada pela classe de resistência. A modelagem utilizou validação cruzada k-fold (k=5). Todo o processo de desenvolvimento dos modelos ocorreu na aplicação web denominada Jupyter Notebook, sendo desenvolvida em Python.

A Floresta Aleatória é uma técnica baseada em árvores de decisão que combina múltiplas árvores para melhorar a predição e reduzir o sobreajuste [20]. Cada árvore é treinada com subconjuntos aleatórios de dados e variáveis, e o resultado é obtido por votação majoritária. Neste estudo, o número de árvores variou de 1 a 100 (sendo criados 100 modelos para cada cenário). Foram fixados o critério Gini, profundidade máxima de 20 e semente aleatória 32 (Figura 3).

Figura 3: Arquitetura das florestas aleatórias

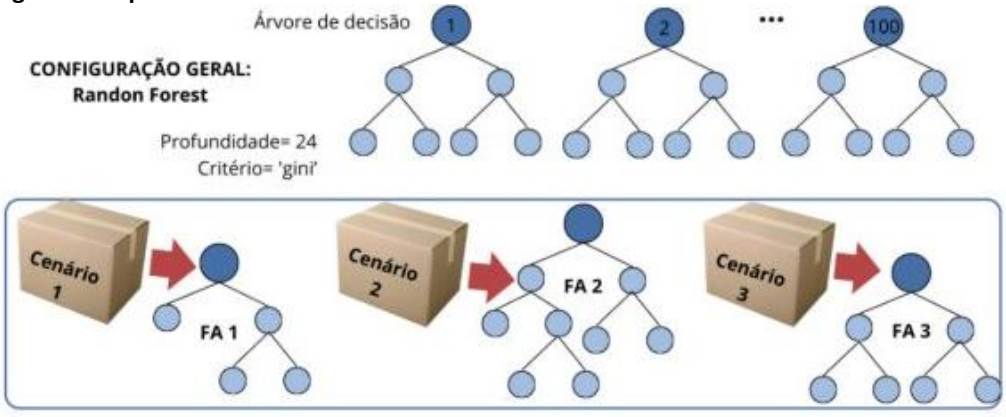

Fonte: os autores.

As métricas utilizadas para medir o desempenho dos modelos foram a acurácia (equação 2), a precisão (equação 3), o recall (equação 4) e o F1-Score (equação 5).

$$Acurácia\ (A) = \frac{(VP+VN)}{N} \quad \text{equação 2}$$

$$Precision\ (P) = \frac{VP}{(VP+FP)} \quad \text{equação 3}$$

$$Recall\ (S) = \frac{VP}{(VP+FN)} \quad \text{equação 4}$$

$$F1Score = 2 * \frac{(P*S)}{(P+S)} \quad \text{equação 5}$$

Onde:
VP = Verdadeiros positivos; VN = Verdadeiros negativos; FN = Falsos negativos; FP = Falsos Positivos; S = Sensibilidade; P = Precisão; $F1Score$ = média harmônica entre precisão e sensibilidade.

OTIMIZAÇÃO

Com base nas métricas de desempenho no treinamento e no teste, o melhor modelo, considerando os 3 cenários, foi selecionado para a construção de uma ferramenta de otimização do proporcionamento de misturas usando dois critérios: classe de resistência e menor consumo de cimento. A otimização multicritério foi desenvolvida considerando o acoplamento com algoritmos genéticos. O método de otimização funciona criando uma população inicial de soluções possíveis, avaliando o desempenho de cada uma (função objetivo), aplicando cruzamento (combinação de soluções) e mutação (pequenas alterações aleatórias) selecionando as melhores, para gerar novas soluções. Esse processo se repete ao longo de 30 gerações, com 50 indivíduos em cada geração, as melhores soluções são armazenadas e apresentadas ao final do processo evolutivo [21]. A Figura 4 exemplifica o processo do algoritmo genético.

DOI: https://doi.org/10.46421/entac.v21i1.8742

Figura 4: Etapas do algoritmo genético

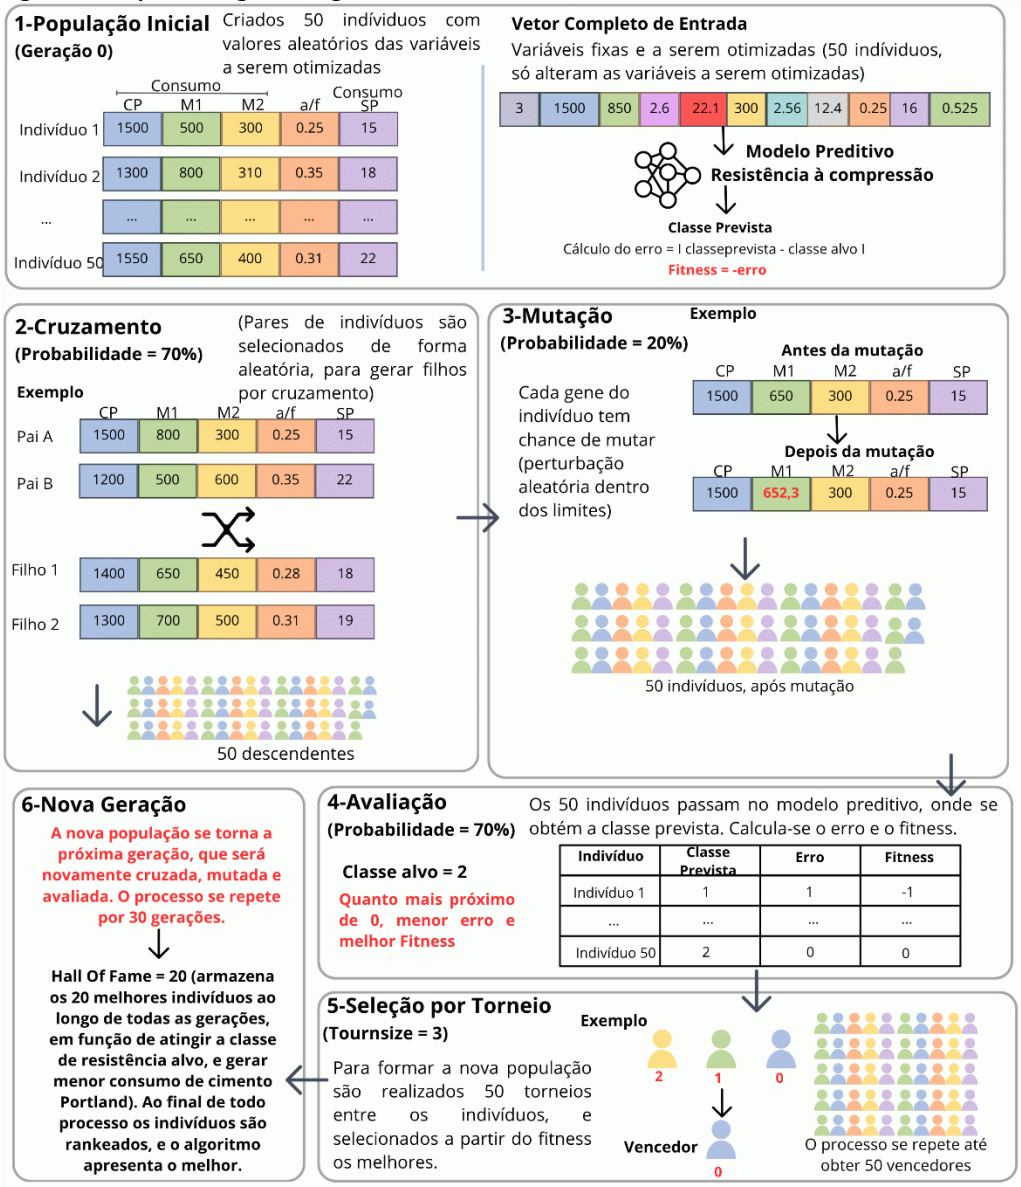

Fonte: os autores.

Neste estudo, considerando as características dos materiais (cimento Portland e MCS) e a classe de resistência desejada, o modelo retorna os consumos e a relação água/finos das pastas com 1 ou 2 MCS.

ANÁLISE DE APLICABILIDADE DA FERRAMENTA – CAMPANHA EXPERIMENTAL

Realizou-se uma campanha experimental, empregando como MCS: pó de concreto (PC), pó de resíduos de construção e demolição (RCD) mistos (PM), e metacaulim (MK). Na validação avaliou-se a capacidade em dosar pastas com classe de resistência 2, correspondendo a matrizes entre 30 e 39 MPa. Sendo solicitado o proporcionamento das seguintes misturas: uma pasta constituída somente de cimento Portland, três pastas binárias (cimento Portland + PC ou PM ou MK), e uma pasta ternária com cimento Portland + PC + MK. Como entrada, foram inseridas as informações da Tabela 1.

Tabela 1: Variáveis das pastas para validação experimental

Variáveis	CP	PC	PM	MK	PC+MK
	Cimento	Cimento + Pó de concreto	Cimento + Pó misto	Cimento + Metacaulim	Cimento + Pó de concreto + Metacaulim
ClassesGranulares	1	2	2	2	3
CPMe (g/cm³)	3,13	3,13	3,13	3,13	3,13
CPd50 (µm)	10,05	10,05	10,05	10,05	10,05
CPBlaine (cm²/g)	3800	3800	3800	3800	3800
CP%Cálcio (%)	59,52	59,52	59,52	59,52	59,52
CP%Sílica (%)	17,78	17,78	17,78	17,78	17,78
CPBET (m²/g)	3,14	3,14	3,14	3,14	3,14
M1Me (g/cm³)	0	2,60	2,47	2,53	2,60
M1d50 (µm)	0	22,18	21,00	12,40	22,18
M1Blaine (cm²/g)	0	3100	3550	3054	3100
M1BET (m²/g)	0	7,50	23,80	16,70	7,50
M1%Cálcio (%)	0	21,36	16,68	0,30	21,36
M1%Sílica (%)	0	47,20	39,55	59,40	47,20
M2Me (g/cm³)	0	0	0	0	2,53
M2d50 (µm)	0	0	0	0	12,4
M2Blaine (m²/g)	0	0	0	0	167
M2%Cálcio (%)	0	0	0	0	0,3
M2%Sílica (%)	0	0	0	0	59,4
MixEmp	0,55	0,54	0,54	0,53	0,50

Fonte: os autores.

O procedimento de mistura (Figura 5- 1) das pastas foi desenvolvido conforme Proença *et al*. 2024 [22], avaliando a consistência das pastas no estado fresco (Figura 5 - 2). Para o ensaio em estado endurecido (Figura 5 - 3) as pastas foram vertidas em moldes cilíndricos de 2.5x5.0 cm (3a) (sendo 7 amostras por pasta), mantidas em cura submersa por 28 dias (3b). O ensaio de resistência à compressão (3c) foi realizado em prensa elétrica com capacidade de 100 tf.

Figura 5: Procedimento experimental para validação do modelo

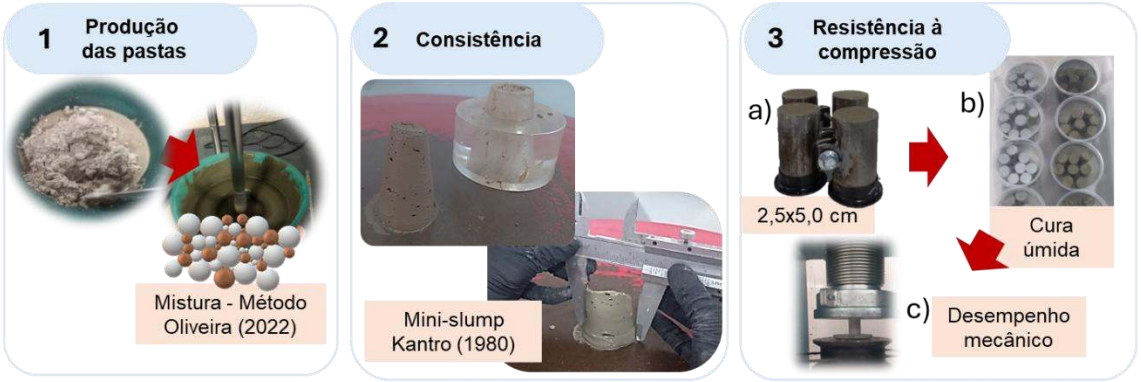

Fonte: os autores.

RESULTADOS E DISCUSSÕES

ANÁLISE DOS MODELOS

Para os três cenários de modelagem, foram desenvolvidos 100 modelos de florestas aleatórias treinadas para cada um, inicialmente foi avaliado qual modelo proporciona a

melhor acurácia e predição da classe de resistência. Através da Figura 6, pode-se observar que os melhores modelos obtiveram acurácias de treinamento de 0,99, 0,93 e 0,93 para os cenários 1, 2 e 3 respectivamente. Já no teste as acurácias foram de 0,60, 0,70 e 0,70 para as mesmas topologias. A acurácia é uma métrica comumente utilizada em problemas de classificação, quanto mais próxima de 1 maior a capacidade preditiva do modelo [23]. A busca inicial pela melhor arquitetura baseou-se na quantidade de árvores, resultando em 26, 24 e 21 árvores para os cenários 1, 2 e 3, respectivamente.

Figura 6: Acurácias cenários 1, 2 e 3, busca pela melhor topologia

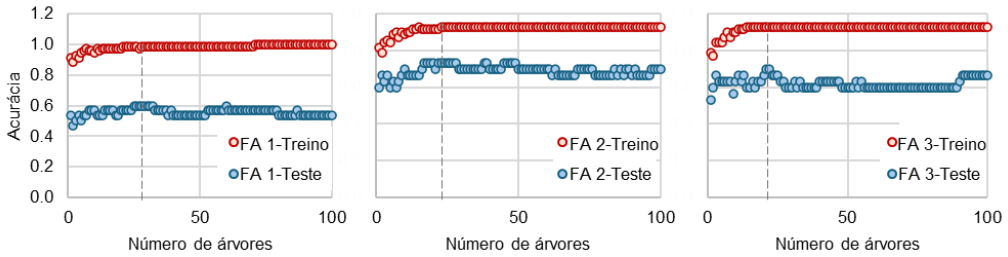

Fonte: os autores.

Considerando o desempenho nas fases de treinamento e de teste, verifica-se que os cenários 2 e 3 apresentam a mesma acurácia. Assim, foi selecionado como melhor modelo, e o modelo que será acoplado ao método de otimização a floresta aleatória 3 (FA 3), por possuir um número menor de variáveis de entrada. O desempenho no treinamento da FA 3 é elevado, com predominância de acertos na diagonal principal da matriz de confusão (Figura 7), indicando que a maior parte das amostras foi corretamente classificada. Já no teste, ocorre redução da acurácia, indicando maior dificuldade do modelo. Como o modelo foi treinado com 70% do banco de dados e avaliado com apenas 30%, isso pode impactar negativamente as métricas, especialmente se o conjunto de teste não representar de forma equilibrada todas as classes [24].

Considerando o desempenho por classe de resistência, o modelo FA 3 apresenta maior eficiência nas classes intermediárias 1 e 2, com altos valores de precisão, sensibilidade (0,95 e 0,905) e F1-score (0,905 e 0,905), indicando baixo nível de erro. O erro entre classes adjacentes em problemas de predição de classe de resistência, ainda que penalizado nas métricas de desempenho, como ocorrido em todas as classes no treinamento, e nas classes 1, 2 e 3 no teste, não é tão grave, pois apesar de errar o valor se aproxima do real, e pode inclusive ser devido à dificuldade do modelo distinguir em regiões limítrofes [25].

Figura 7: Matriz de confusão FA 3

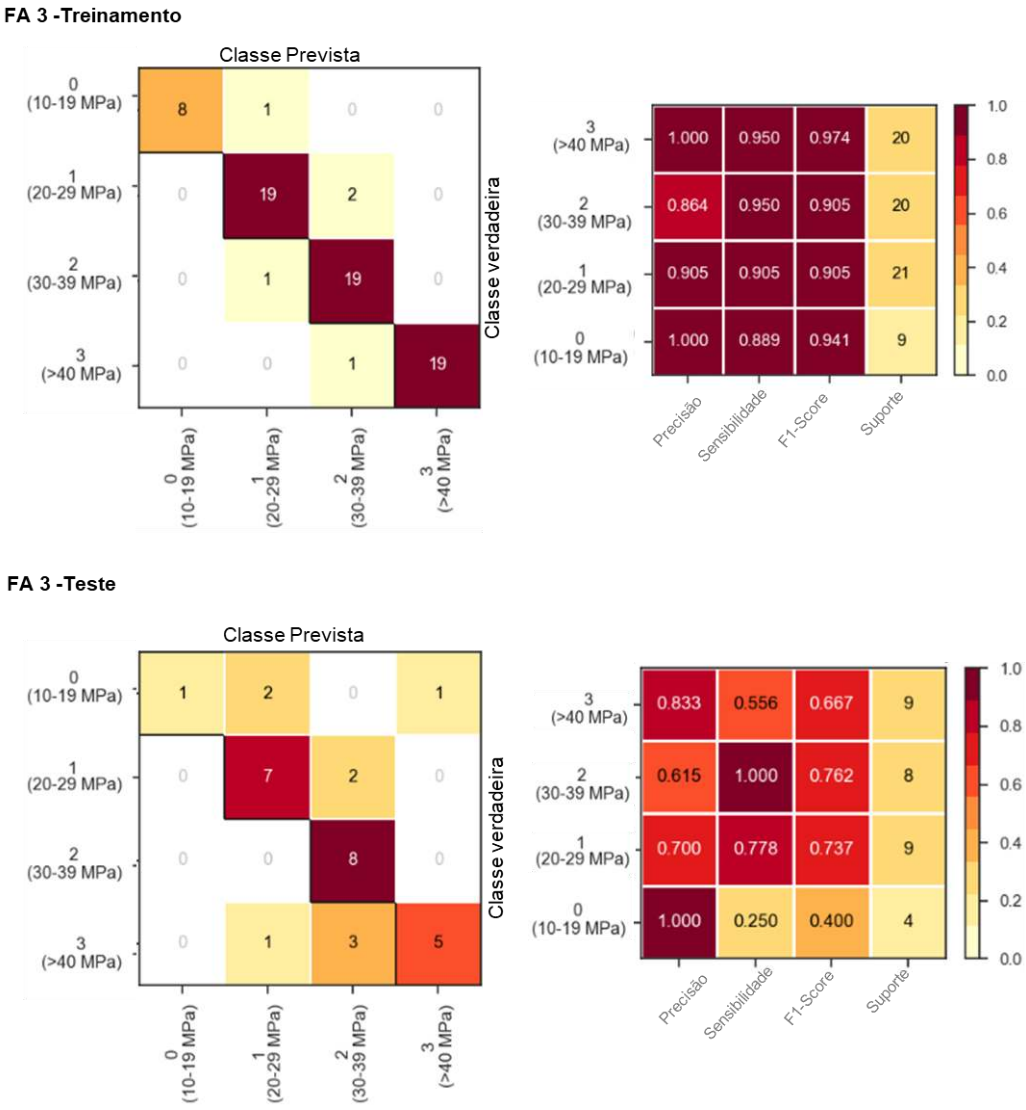

Fonte: os autores.

OTIMIZAÇÃO E CAMPANHA EXPERIMENTAL

Com a otimização da FA 3 e os dados de entrada referentes aos materiais propostos na Tabela 1, foram obtidas as composições de misturas (Tabela 2), sendo que o modelo otimizado poderá fornecer até 3 possíveis soluções, se houver, denominadas “a”, “b” e “c”.

Tabela 2: Proporcionamento das pastas com modelo FA 3 otimizado

Pasta		Consumo Cimento (kg/m³)	Consumo M1 (kg/m³)	Consumo M2 (kg/m³)	água/ finos	água/finos (corrigida)	Consumo de SP (kg/m³)	Classe alvo
CP (Cimento Portland)	a	1220,76			0,11	0,13	16,26	2
PC (Cimento Portland + Pó de concreto)	a	1695,63	303,98		0,31		25,39	2
	b	1425,75	709,03		0,14	0,22	14,52	2
	c	1720,74	431,29		0,36		23,53	2
PM (Cimento Portland + Pó misto)	a	1402,20	484,42		0,15	0,19	17,87	2
	b	1485,77	941,27		0,12	0,16	25,16	2
	c	1368,65	809,26		0,35		14,99	2
MK (Cimento Portland + metacaulim)	a	1743,41	425,24		0,22		27,12	2
	b	1029,27	507,71		0,14	0,18	22,83	2
	c	1388,76	305,53		0,12	0,17	16,37	2
PC+MK (Cimento Portland + pó de concreto + metacaulim)	a	1001,81	1016,53	658,49	0,16		26,46	2
	b	1286,20	713,92	56,51	0,10	0,16	24,36	2
	c	1715,51	327,68	441,82	0,30		20,00	2

Fonte: os autores.

Em algumas pastas foi preciso corrigir relações água/finos (a/f), em favor da possibilidade de moldar os corpos de prova, esta foi adicionada de forma incremental apenas para condicionar a mistura.

Quanto à consistência das pastas observa-se (Figura 8) que não houve um padrão a ser obtido, visto que essa propriedade não se trata de uma variável do banco de dados. Ao comparar as composições com metacaulim, com a/f entre 0,22 e 0,17, e a pasta apenas com cimento Portland (CP), com 0,13, nota-se a alta coesão das pastas contendo metacaulim, o que se deve à maior finura do material, demandando mais água para manter a fluidez. O mesmo ocorre com PC(b), PM(a) e PM(b).

Figura 8: Consistências pastas otimizadas

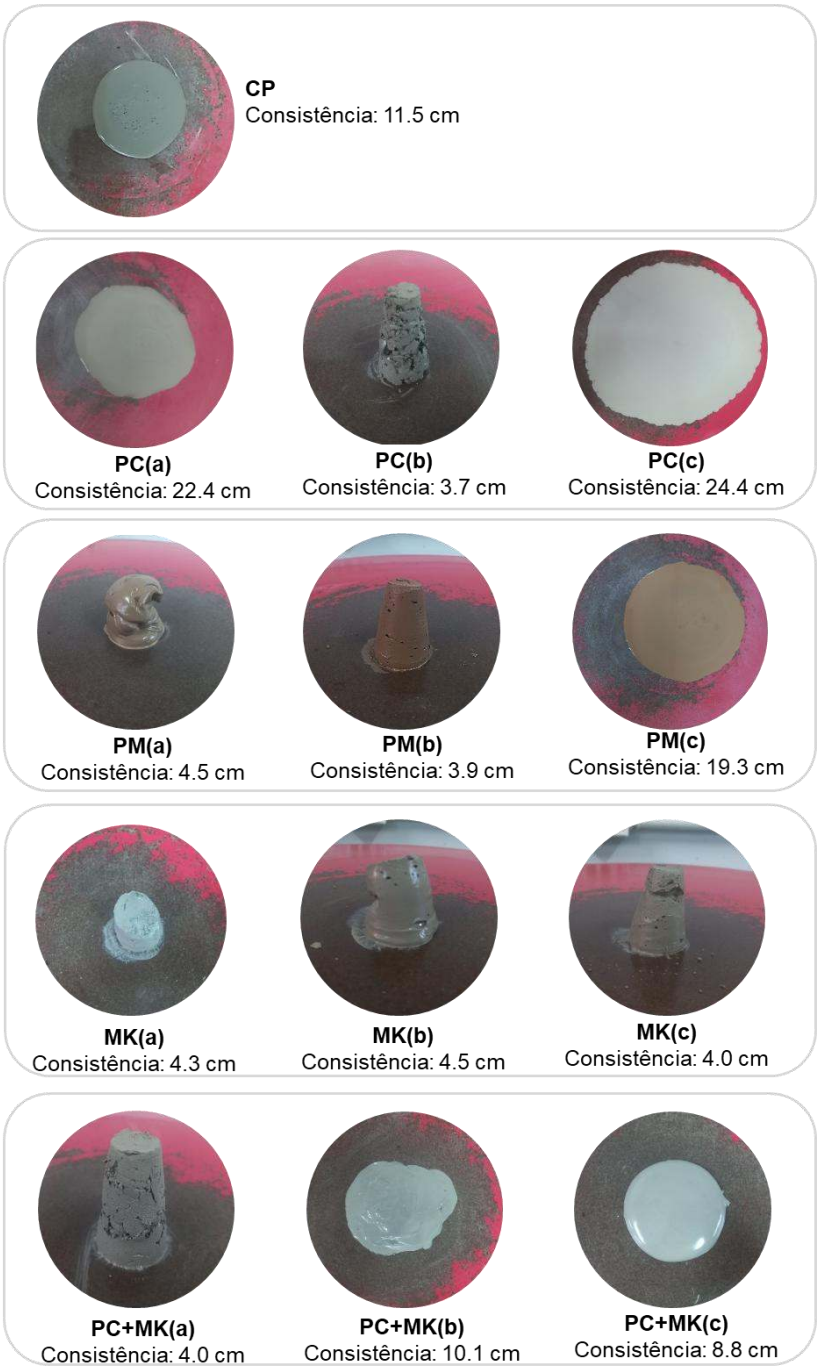

Fonte: os autores.

Para misturas de pastas com superplastificante, Oliveira *et al*. (2025) atingiram espalhamentos da ordem de 5,2 cm para uma relação a/f de 0,07. Em pastas com 25% de pó de concreto e pó misto de RCD, obtiveram-se 16,1 cm e 15,8 cm, com relações água/finos de 0,19 e 0,18, respectivamente [26]. Proença *et al*. (2024) obtiveram espalhamentos de ~12 cm em pastas contendo 25% de pó misto, e pó de concreto, com relação água/finos de 0,48 sem uso de aditivo [22].

A partir da análise visual das misturas, pode-se afirmar que uma consistência adequada para manipular, adensar e moldar corpos de prova fica entre 8,8 e 22 cm, misturas com espalhamentos maiores estão associadas à segregação.

Aos 28 dias, foram obtidas resistências à compressão axial entre 28 e 87 MPa (Figura 9), sendo a classe solicitada para o modelo Classe 2 (30 a 39 MPa) (Figura 10). Diante dos valores obtidos, percebe-se que mais de 50% das misturas ficaram em classe superior à resistência solicitada; nesse sentido, entende-se que poderia ser reduzido o consumo de cimento Portland, potencializando a incorporação dos MCS, e ainda ser aumentada a relação água/finos, para maior trabalhabilidade das pastas.

Figura 9: Resistência à compressão das pastas aos 28 dias

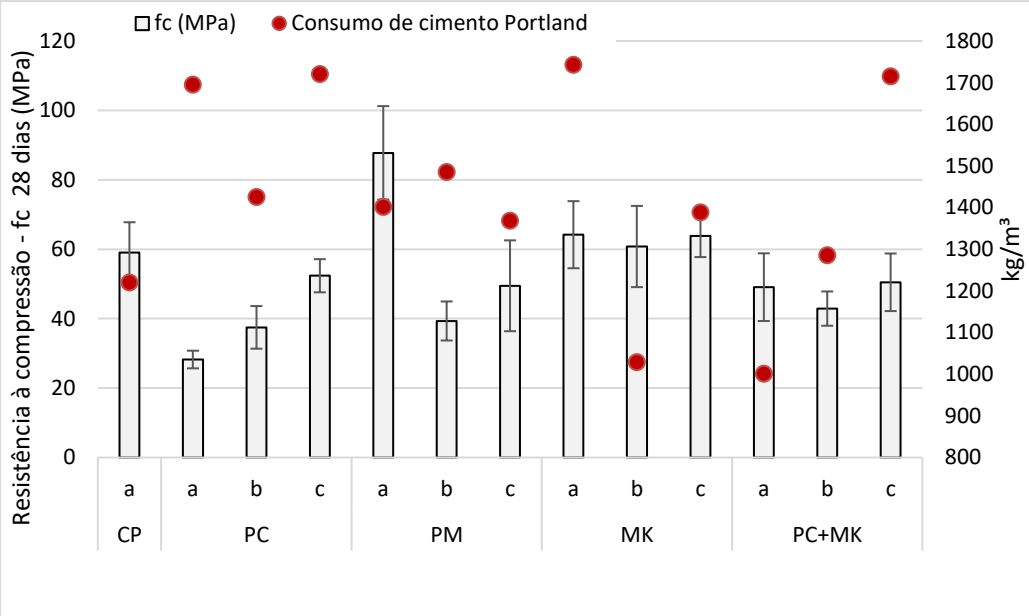

Fonte: os autores.

A mistura contendo pó misto PM(a), com um consumo de cimento Portland de 1402,20 kg/m³ obteve 87 MPa de resistência aos 28 dias, com um teor de 26% em massa de pó misto de RCD. As pastas PM(b) e PM(c) com 39% e 37% de pó misto, alcançaram 39 e 49 MPa. Pastas com metacaulim MK (a), (b) e (c), se concentraram e obtiveram resistências de 60 a 65 MPa, com teores de 20%, 33% e 18% em massa metacaulim.

Cabe destacar a mistura PC+MK(a) com o menor consumo de 1001,81 kg de cimento/m³, 63% da massa de sólidos na mistura é constituída por pó de concreto (38%) e metacaulim (25%), alcançando resistência de 49 MPa aos 28 dias. A mistura apresentou uma relação água/finos relativamente baixa (0,16), o que implicou em uma baixa consistência.

Ao analisar o consumo de cimento em função da resistência mecânica para a pasta contendo apenas cimento Portland obteve-se um índice de 20,69 kg de cimento/m³/MPa. Com a incorporação de MCS em misturas binárias foram obtidos valores de 16,93 e 16,11 kg de cimento/m³/MPa para MK(b) e PM(a), respectivamente. Na pasta ternária PC+MK(a) com 63% de MCS o índice foi de 20,39 kg de cimento/m³/MPa, apesar de similar a pasta apenas com cimento cabe destacar que a mistura possui apenas 37% de cimento Portland em massa, o que reduz significativamente as emissões de carbono associadas a esta matriz, e demonstra o potencial da ferramenta desenvolvida neste estudo.

Com 25% de substituição de cimento Portland por pó de concreto Oliveira *et al.* (2023) [8] obteve 29 MPa, porém utilizando relação água/finos de 0,48. Proença *et al*. (2024) [22] também com relações água/finos fixas de 0,48 atingiu resistências de 20 e 12,5 MPa, em

pastas contendo 25% de pó de concreto e pó misto de RCD, respectivamente. Em misturas proporcionadas por empacotamento de partículas com pó misto de RCD Oliveira *et al.* (2024) obtiveram 42 MPa, em uma pasta com teor de 25% de pó misto, com a/f de 0,25 e uso de superplastificante [27].

Wang *et al*. (2019) [28] analisando pastas com 10% de metacaulim, e relação água/finos de 0,4, com superplastificante observou um aumento de 15% na resistência à compressão quando comparado a pasta apenas com cimento Portland. Subasi e Emiroglu (2015) [29] atingiram resistências de 32 MPa em pastas com incorporação de 30% de massa de metacaulim e 0,5 de relação água/finos.

Figura 10: Classe indicada x Classe obtida

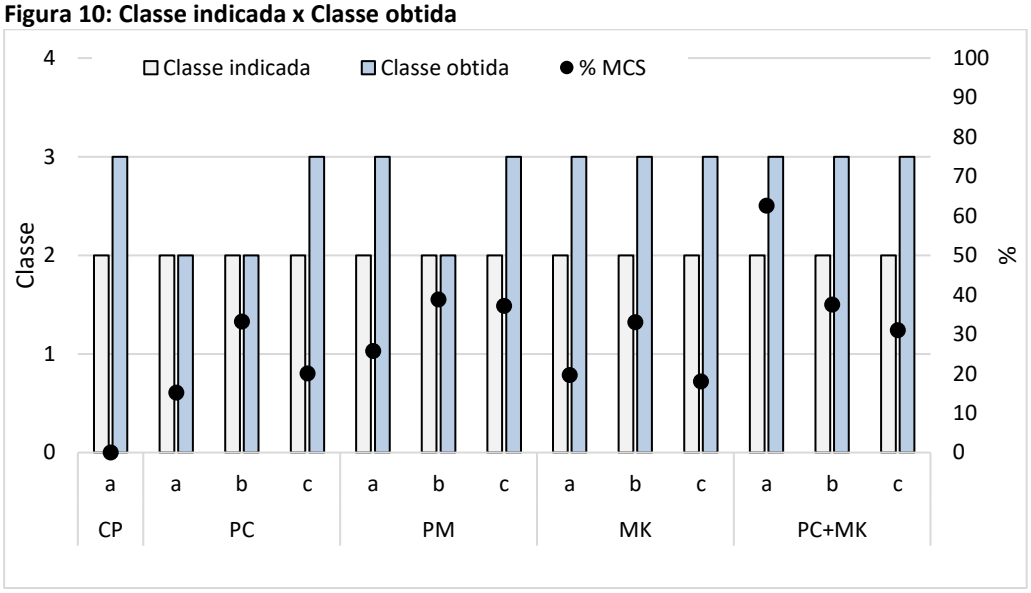

Fonte: os autores.

Nota-se que os desempenhos obtidos nas pastas fornecidas neste estudo resultaram em misturas com teores consideráveis de incorporação do MCS, entre 33 e 38%, em pelo menos uma das composições (a, b e c) para cada tipo de MCS. Destaca-se a pasta ternária com metacaulim e pó de concreto, que alcançou 63% em massa de MCS.

De modo geral o modelo otimizado fornece composições que garantem que a resistência solicitada seja alcançada, entretanto proporciona materiais que chegam à classe superior, o que acaba sendo pouco interessante quando se objetiva otimizar consumos de materiais, visto que com uma maior capacidade resistente seria possível reduzir consumo de cimento Portland por exemplo, ou obter misturas mais fluidas. Entretanto este fato não deve ser entendido com uma dificuldade de generalização com novos dados, visto que ele entrega no mínimo composições que atendem a resistência solicitada, demonstrando que o processo de seleção do algoritmo genético é eficiente. É importante considerar também que os valores referentes aos consumos de cimento Portland, ficam dentro do domínio de informações do banco de dados para o consumo de cimento Portland entre 822 e 2600 kg/m³ de pasta, apesar de haver uma margem ampla, a quantidade de dados é limitada. Também é notória a importância do estado fresco no processo de dosagem de pastas, o que será aprimorado em estudos futuros.

CONCLUSÕES

Diante do objetivo de desenvolver e validar uma ferramenta para proporcionar pastas cimentícias com distintos MCS, podem ser elencadas as conclusões:

- O modelo de proporcionamento desenvolvido é eficiente, pois atende à classe solicitada e define composições adequadas. Como este prioriza o desempenho mecânico, resulta em resistências superiores à exigida (3 das 13 pastas testadas atingiram exatamente a classe solicitada, as demais obtiveram resistências superiores) e relações água/finos significativamente baixas, elevando o desempenho à compressão, mas limitando a sustentabilidade em termos de incorporação do MCS;
- O modelo preditivo da classe de resistência apresentou acurácia de aprendizagem de 93%, sendo que a análise de aplicabilidade e generalização resultou em acurácia de 100%, em que todas as pastas atenderam à classe de resistência solicitada;
- A incorporação de MCS reduziu o índice de ligante em até cerca de 22% nas misturas binárias em relação à pasta de cimento. A mistura ternária foi proporcionada com apenas 37% de cimento Portland. Isso representa uma redução potencial de até 63% nas emissões de carbono associadas ao ligante. Os resultados evidenciam a eficácia da ferramenta para otimizar desempenho e reduzir o consumo de cimento.

De modo geral, o estudo traz uma contribuição científica, demonstrando a possibilidade de utilizar o aprendizado de máquina para reduzir ensaios laboratoriais e ampliar o uso de MCS, contribuindo para menor consumo de clínquer. Para estudos futuros será desenvolvido um banco de dados com coleta de dados padronizada acerca dos diferentes tipos de MCS, para aprimoramento dos modelos de otimização, além da consideração de propriedades em estado fresco das pastas no desenvolvimento dos modelos.

DECLARAÇÃO

Durante a preparação deste artigo, a autora Melissa P. Proença autores utilizou a ferramenta ChatGPT (OpenAI, modelo GPT-5.5), para auxílio na elaboração da Figura 4. Após a utilização da ferramenta, o conteúdo foi editado e ajustado conforme necessário. Os autores assumem total responsabilidade pelo conteúdo do artigo publicado.

AGRADECIMENTOS

À CAPES pela bolsa de doutorado concedida à autora Melissa Pastorini Proença (código CAPES 0001).

REFERÊNCIAS

[1] HILLOULIN, B.; TRAN, V. Q. Interpretable machine learning model for autogenous shrinkage prediction of low-carbon cementitious materials.

Construction and Building Materials, v. 396, p. 132343, set. https://doi.org/10.1016/j.conbuildmat.2023.132343.

[2] DEGEFA, A. B. et al. Machine learning applied to predicting phase assemblages of hardened cementitious systems. **Ceramics International**, v. 50, n. 10, p. 17783–17795, maio 2024. https://doi.org/10.1016/j.ceramint.2024.02.268.

[3] SIDAC. **Dados Do Produto - Clínquer**. Disponível em: <https://sidac.org.br/produtos/45>. Acesso em: 8 jan. 2024.

[4] GANGOTRA, P. A.; WEST, J.; PHOTO, A. S. **The US Needs to Lower Cement Emissions — 'Blended Cement' Can Help**. Disponível em: <https://www.wri.org/insights/lower-carbon-blended-cement>. Acesso em: 14 mar. 2025.

[5] GCCA. Concrete Future - Roadmap to Net Zero. **Global Cement and Concrete Association**, p. 1–48, 2021.

[6] HOPPE FILHO, J. et al. Red ceramic waste as supplementary cementitious material: Microstructure and mechanical properties. **Construction and Building Materials**, v. 296, p. 123653, 2021. https://doi.org/10.1016/j.conbuildmat.2021.123653.

[7] JUENGER, M. C. G.; SIDDIQUE, R. Recent advances in understanding the role of supplementary cementitious materials in concrete. **Cement and Concrete Research**, v. 78, p. 71–80, 1 dez. 2015. https://doi.org/10.1016/J.CEMCONRES.2015.03.018.

[8] OLIVEIRA, D. R. B. et al. Concrete powder waste as a substitution for Portland cement for environment-friendly cement production. Construction and Building Materials, v. 397, p. 132382, set. 2023. https://doi.org/10.56238/methfthaofinterv12023.

[9] SNELLINGS, R.; SURANENI, P.; SKIBSTED, J. Future and emerging supplementary cementitious materials. **Cement and Concrete Research**, v. 171, p. 107199, set. 2023. https://doi.org/10.1016/j.cemconres.2023.107199.

[10] NAZEER, M.; KAPOOR, K.; SINGH, S. P. Strength, durability and microstructural investigations on pervious concrete made with fly ash and silica fume as supplementary cementitious materials. **Journal of Building Engineering**, v. 69, n. February, p. 106275, 2023. https://doi.org/10.1016/j.jobe.2023.106275.

[11] JUENGER, M. C. G.; SNELLINGS, R.; BERNAL, S. A. Supplementary cementitious materials: New sources, characterization, and performance insights. **Cement and Concrete Research**, v. 122, p. 257–273, ago. 2019. https://doi.org/10.1016/j.cemconres.2019.05.008.

[12] KURNIATI, E. O. et al. Machine learning for predicting compressive strength of sustainable cement paste incorporating copper mine tailings as supplementary cementitious materials. **Case Studies in Construction Materials**, v. 21, p. e03373, dez. 2024. https://doi.org/10.1016/j.cscm.2024.e03373.

[13] ELHISHI, S.; ELASHRY, A. M.; EL-METWALLY, S. Unboxing machine learning models

for concrete strength prediction using XAI. **Scientific Reports**, v. 13, n. 1, p. 1–20, 2023. https://doi.org/10.1038/s41598-023-47169-7.

[14] CHAJEC, A. The role of particle size optimisation of waste granite powder in cementitious composites. **Archives of Civil and Mechanical Engineering**, v. 25, n. 5, p. 1–21, 2025. https://doi.org/10.1007/s43452-025-01330-3.

[15] OLIVEIRA, D. R. B. **Aproveitamento Da Fração Fina De Resíduo De Concreto Como Substituto Ao Cimento Portland**, Tese de Doutorado - Universidade Federal do Paraná, 2022.

[16] CAMPOS, H. F. **Dosagem de concreto sustentável e de alta resistência, otimizada por modelos de empacotamento de partículas, com substituição parcial do cimento Portland por pó de pedra e sílica ativa**, Tese de Doutorado. Universidade Federal do Paraná, 2019.

[17] PROENÇA, M. P, **Pós de RCD tratados por processos físico-químicos para a composição de matrizes cimentícias de baixo carbono**, Dissertação de Mestrado. Universidade Federal da Integração Latino-Americana, 2023.

[18] VAIČIUKYNIENĖ, D. et al. Synergistic effect of dry sludge from waste wash water of concrete plants and zeolitic by-product on the properties of ternary blended ordinary Portland cements. **Journal of Cleaner Production**, v. 244, p. 118493, jan. 2020. https://doi.org/10.1016/j.jclepro.2019.118493.

[19] CYR, M. et al. Effect of cement type on metakaolin efficiency. **Cement and Concrete Research**, v. 64, p. 63–72, 2014. https://doi.org/10.1016/j.cemconres.2014.06.007

[20] RASCHKA, S. et al. **Machine learning with Pytorch and Scikit-Learn : develop machine learning and deep learning models with scikit-learn and PyTorch**, 2022.

[21] THOMPSON, J. Genetic Algorithms and Applications. **Handbook of Formal Optimization**, p. 981–1006, 2023. https://doi.org/10.1007/978-981-97-3820-5_30.

[22] PROENÇA, M. P. et al. CDW Powder Activated by Mechanical, Thermal and Tannic Acid Treatment: An Option for Circularity in Construction. **Waste and Biomass Valorization**, n. 0123456789, 2024. https://doi.org/10.1007/s12649-024-02802-y.

[23] RAINIO, O.; TEUHO, J.; KLÉN, R. Evaluation metrics and statistical tests for machine learning. **Scientific Reports**, v. 14, n. 1, p. 1–14, 2024. https://doi.org/10.1038/s41598-024-56706-x.

[24] MOHAMMED, S. et al. The effects of data quality on machine learning performance on tabular data. **Information Systems**, v. 132, n. March, p. 102549, 2025. https://doi.org/10.1016/j.is.2025.102549.

[25] ALSAADAWI, M. M.; ELSHAARAWY, M. K.; HAMED, A. K. Concrete compressive strength classification using hybrid machine learning models and interactive GUI. **Innovative Infrastructure Solutions**, v. 10, n. 5, p. 1–29, 2025.

https://doi.org/10.1007/s41062-025-01983-2.

[26] OLIVEIRA, D. R. B. et al. Optimized cementitious matrices with activated CDW fines: A sustainable path to low carbon cement. **Construction and Building Materials**, v. 483, n. April, 2025. https://doi.org/10.1016/j.conbuildmat.2025.141719.

[27] OLIVEIRA, D. R. B. et al. Mixed construction and demolition powder as a filler to Portland cement: study on packaged pastes. **Ambiente Construído**, v. 24, dez. 2024. https://doi.org/10.1590/s1678-86212024000100715.

[28] JIA, L. et al. Influence of different supplementary cementitious materials on water distribution and rheological behavior of blended cement paste. **Construction and Building Materials**, v. 443, n. February, p. 137705, 2024. https://doi.org/10.1016/j.conbuildmat.2024.137705.

[29] SUBAŞI, A.; EMIROⱢLU, M. Effect of metakaolin substitution on physical, mechanical and hydration process of White Portland cement. **Construction and Building Materials**, v. 95, p. 257–268, 2015. https://doi.org/10.1016/j.conbuildmat.2015.07.125.