

## Previsão orientada por IA e avaliação laboratorial da resistência à compressão do concreto com agregados reciclados.

S. Gopal<sup>1\*</sup> , A. Kumar<sup>2</sup> 

\* Autor de Contato: [swatantragopal.const@gmail.com](mailto:swatantragopal.const@gmail.com)

DOI: <https://doi.org/10.21041/ra.v16i2.967>

Recebido: 04/12/2025 | Correções recebidas: 19/03/2026 | Aceito: 20/03/2026 | Publicado: 01/05/2026

### RESUMO

Este estudo tem como objetivo avaliar e prever a resistência à compressão do concreto com agregados reciclados (CAR) por meio de ensaios experimentais e técnicas de aprendizado de máquina. Foram investigadas vinte e cinco misturas de concreto com variação do teor de agregados reciclados, da relação água/cimento, da dosagem de aditivo plastificante e da resistência do concreto de origem. A resistência à compressão aos 28 dias variou de 31,8 a 45,2 MPa, reduzindo-se com o aumento do teor de agregados reciclados e da absorção de água. A Regressão por Vetores de Suporte (SVR) alcançou a maior precisão preditiva ( $R^2 = 0,998$ ), superando os demais modelos. O estudo é limitado pelo tamanho do conjunto de dados e pela expansão controlada desses dados. A originalidade está na integração da investigação experimental com a análise de aprendizado de máquina com múltiplos modelos. Os resultados demonstram que a IA pode apoiar, de forma efetiva, a dosagem sustentável de concretos com agregados reciclados.

**Palavras-chave:** concreto com agregados reciclados; resistência à compressão; aprendizado de máquina; regressão por vetores de suporte; construção sustentável; modelagem orientada por dad.

**Citar como:** Gopal, S., Kumar, A. (2026), “Previsão orientada por IA e avaliação laboratorial da resistência à compressão do concreto com agregados reciclados.”, Revista ALCONPAT, 16 (2), pp. 149 – 185, DOI: <https://doi.org/10.21041/ra.v16i2.967>.

<sup>1</sup> Pesquisador, Departamento de Engenharia Civil, Sandip University, Sijoul, Madhubani-847235, Bihar, Índia

<sup>2</sup> Professor Assistente, Departamento de Engenharia Civil, Sandip University, Sijoul, Madhubani-847235, Bihar, Índia.

#### Contribuição de cada autor

Neste trabalho, Swatantra Gopal contribuiu com a ideia original (70%), experimentação e coleta de dados (80%), desenvolvimento dos modelos baseados em aprendizado de máquina (75%), análise dos dados (70%) e redação do manuscrito (75%). Dr. Amrendra Kumar contribuiu com a supervisão conceitual (30%), validação da metodologia (25%), interpretação e discussão dos resultados (30%) e revisão crítica e edição do manuscrito (25%).

#### Licença Creative Commons

Copyright (2026) é propriedade dos autores. Este trabalho é um artigo de acesso aberto publicado sob os termos e condições de uma Licença Internacional Creative Commons Atribuição 4.0 ([CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)).

#### Discussões e correções pós-publicação

Qualquer controvérsia, incluindo as respostas dos autores, será publicada no primeiro número de 2027, desde que a informação seja recebida antes do fechamento do terceiro número de 2026.

## AI-driven forecasting and laboratory evaluation of compressive strength in recycled aggregate concrete.

### ABSTRACT

This study aims to evaluate and predict the compressive strength of recycled aggregate concrete (RAC) using experimental testing and machine learning techniques. Twenty-five concrete mixes with varying recycled aggregate content, water cement ratio, plasticizer dosage, and parent concrete strength were investigated. The 28-day compressive strength ranged from 31.8 to 45.2 MPa, decreasing with higher recycled aggregate content and water absorption. Support Vector Regression achieved the highest prediction accuracy ( $R^2 = 0.998$ ), outperforming other models. The study is limited by dataset size and controlled data expansion. The originality lies in integrating experimental investigation with multi-model machine learning analysis. The results demonstrate that AI can effectively support sustainable mix design of recycled aggregate concrete. **Keywords:** recycled aggregate concrete; compressive strength; machine learning; support vector regression; sustainable construction; data-driven modeling.

## Predicción y evaluación en laboratorio de la resistencia a compresión en hormigón con árido reciclado mediante IA.

### RESUMEN

Este estudio tiene como objetivo evaluar y predecir la resistencia a compresión del hormigón con árido reciclado (HAR) mediante ensayos experimentales y técnicas de aprendizaje automático. Se analizaron veinticinco mezclas de hormigón con diferentes contenidos de árido reciclado, relación agua-cemento, dosificación de plastificante y resistencia del hormigón base. La resistencia a compresión a los 28 días osciló entre 31,8 y 45,2 MPa, disminuyendo con un mayor contenido de árido reciclado y una mayor absorción de agua. La regresión de vectores de soporte ( $R^2$ ) alcanzó la mayor precisión predictiva ( $R^2 = 0,998$ ), superando a otros modelos. El estudio se ve limitado por el tamaño del conjunto de datos y la expansión controlada de los mismos. Su originalidad reside en la integración de la investigación experimental con el análisis de aprendizaje automático multimodelo. Los resultados demuestran que la IA puede contribuir eficazmente al diseño de mezclas sostenibles de hormigón con árido reciclado.

**Palabras clave:** hormigón con árido reciclado; resistencia a compresión; aprendizaje automático; regresión de vectores de soporte; construcción sostenible; modelado basado en datos.

### Informações legais

Revista ALCONPAT é uma publicação trimestral da Associação Latino-Americana de Controle de Qualidade, Patologia e Recuperação de Construção, Internacional, A.C., Km. 6, antiga estrada para Progreso, Merida, Yucatán, C.P. 97310, Tel. +52 1 983 419 8241, [alconpat.int@gmail.com](mailto:alconpat.int@gmail.com), Website: [www.alconpat.org](http://www.alconpat.org)

Reserva de direitos de uso exclusivo No.04-2013-011717330300-203, eISSN 2007-6835, ambos concedidos pelo Instituto Nacional de Direitos Autorais. Editor responsável: Dr. Pedro Castro Borges. Responsável pela última atualização deste número, Unidade de Informática ALCONPAT, Eng. Elizabeth Sabido Maldonado.

As opiniões expressas pelos autores não refletem necessariamente a posição do editor.

A reprodução total ou parcial do conteúdo e das imagens da publicação é realizada de acordo com o código COPE e a licença CC BY 4.0 da Revista ALCONPAT.

## 1. INTRODUÇÃO

O concreto é fundamental para a infraestrutura moderna, porém sua produção implica elevado custo ambiental. A fabricação de cimento, isoladamente, contribui de forma significativa para as emissões globais de carbono. Análises recentes mostram que a indústria cimenteira continua sendo uma fonte substancial de CO<sub>2</sub>, tanto pelo consumo de energia quanto pelos processos químicos, como a descarbonatação da matéria prima calcário (Akbar & Liew, 2020b; Khalil & AbouZeid, 2025). Ao mesmo tempo, as atividades de construção e demolição (C&D) geram grandes volumes de resíduos, provocando pressão sobre o uso do solo e desafios de disposição final. O descarte de resíduos de C&D não apenas sobrecarrega aterros, mas também acarreta perda de materiais e degradação ambiental (Cakiroglu et al., 2023; Pal & Singh, 2024).

O reaproveitamento de resíduos de construção e demolição para produzir agregados reciclados de concreto (ARCs) é uma solução viável para ambos os problemas. Esses agregados reciclados podem ser obtidos pela britagem e beneficiamento de concreto demolido, após a remoção de impurezas como madeira, plásticos e armaduras de aço (Chakradhara Rao et al., 2011). O material resultante, conhecido como concreto com agregados reciclados (CAR), pode apresentar propriedades técnico-mecânicas semelhantes às do concreto produzido com agregados naturais quando os agregados reciclados são incorporados ao concreto fresco. Entretanto, diversos fatores intrínsecos, como a resistência e a qualidade do concreto de origem, a quantidade de argamassa aderida, a porosidade das partículas recicladas e as propriedades de absorção de água, influenciam significativamente o desempenho do CAR. (Ajdukiewicz & Kliszczewicz, 2002; Khatib, 2005)

Uma das principais questões no uso do concreto com agregados reciclados é que esses agregados normalmente apresentam maior porosidade e maior absorção de água do que os agregados naturais. Essas características decorrem da argamassa antiga aderida e das microfissuras geradas durante o processo de britagem (P. Zhang et al., 2023). A elevada absorção de água dos agregados reciclados afeta a relação água/cimento efetiva, a trabalhabilidade, a resistência e a durabilidade do CAR (Khalil & AbouZeid, 2025). Além disso, concretos produzidos com agregados reciclados provenientes de concretos de origem de baixa resistência tendem a apresentar reduções mais expressivas de resistência à compressão do que aqueles derivados de concretos de origem de maior resistência, provavelmente porque as partículas recicladas incorporam fragilidades residuais, como microfissuras antigas, à nova mistura (Katz, 2003; Padmini et al., 2002)

Além da absorção de água e da qualidade do concreto de origem, outros parâmetros de dosagem, como o teor de substituição por agregado reciclado, a relação água/cimento ( $a/c$ ), a condição de umidade dos agregados e a qualidade mecânica dos agregados reciclados, por exemplo a resistência à abrasão, também afetam a resistência do CAR. Como essas variáveis frequentemente interagem de forma não linear, o comportamento do CAR é complexo e de difícil previsão (Bai & others, 2023; Huang & Yan, 2025). Essa complexidade exige programas extensos de ensaios laboratoriais, com moldagem de múltiplas bateladas de concreto, cura dos corpos de prova e realização de ensaios destrutivos de resistência. Tais programas experimentais exigem elevado consumo de recursos, tempo e custo.

A modelagem preditiva tornou-se uma alternativa robusta à dependência exclusiva de técnicas experimentais. Na pesquisa clássica em concreto, análises de regressão, como regressão linear múltipla ou multivariada, têm sido utilizadas para relacionar parâmetros de dosagem com resistência e outras propriedades. Contudo, quando os fatores interagem de maneira não linear ou quando o conjunto de dados é de alta dimensionalidade, essas abordagens frequentemente apresentam limitações. (Dantas et al., 2013; Shin & Kim, 2013; Yeh, 2007).

As técnicas de inteligência artificial (IA) e aprendizado de máquina (ML) demonstraram, na última década, potencial significativo para prever a resistência à compressão do concreto, especialmente quando lidam com espaços paramétricos complexos e interações não lineares. Entre os modelos

capazes de aprender a partir de dados e levar em consideração os efeitos complexos dos fatores de dosagem estão as Redes Neurais Artificiais (ANN), a Regressão por Vetores de Suporte (SVR), as Random Forest, o Gradient Boosting e o XGBoost (Bilim, Koksall, et al., 2009; Farhangi et al., 2021; Jahangir & Eidgahee, 2020). Essas técnicas já foram aplicadas ao CAR para prever a resistência à compressão considerando entradas como densidade, resistência do concreto de origem, absorção de água, relação água/cimento, teor de substituição por agregado reciclado e até resistência à abrasão dos agregados. (Khan & others, 2022; X. Zhang et al., 2023)

Apesar desses avanços, ainda persistem lacunas importantes. Muitos estudos existentes dependem de conjuntos de dados limitados em tamanho ou diversidade, concentram-se em poucos parâmetros de entrada ou avaliam apenas um ou dois modelos baseados em aprendizado de máquina. De forma crítica, poucos trabalhos combinam um programa experimental laboratorial abrangente, com múltiplos teores de agregados reciclados, diferentes resistências do concreto de origem e ensaios de qualidade dos agregados, com uma comparação ampla de modelos baseados em aprendizado de máquina. Sem essa integração, torna-se difícil validar as previsões dos modelos em um domínio experimental amplo e avaliar como alterações reais no projeto de dosagem podem influenciar o desempenho dos modelos.

As técnicas de inteligência artificial (IA) e aprendizado de máquina (ML) têm demonstrado, nos últimos anos, grande potencial para prever com precisão propriedades do concreto. Redes Neurais Artificiais (ANN), Regressão por Vetores de Suporte (SVR), Random Forest, Gradient Boosting e XGBoost estão entre os métodos que podem prever, de forma rápida e econômica, correlações complexas entre parâmetros de entrada e respostas de saída. Esses modelos funcionam especialmente bem para o CAR, cuja resistência à compressão é determinada pela interação não linear entre diversos componentes da mistura, propriedades dos agregados e condições de cura. (Bilim, Ozbakkaloglu, et al., 2009; Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

Neste estudo, os agregados reciclados foram cuidadosamente processados para assegurar composição predominantemente à base de concreto, minimizando a variabilidade associada a resíduos mistos de C&D. Embora redes neurais artificiais tenham sido amplamente utilizadas na previsão da resistência do concreto, o presente estudo foca abordagens alternativas de aprendizado de máquina para assegurar interpretabilidade e robustez com dados experimentais limitados. Essas lacunas são abordadas por meio de uma avaliação experimental sistemática e de modelagem preditiva aprimorada por IA para investigar a resistência à compressão aos 28 dias do CAR. Foram utilizadas misturas de concreto com diferentes teores de cimento, agregados miúdos e graúdos naturais e reciclados, água, superplastificantes e relações água/cimento. As variáveis importantes dos agregados reciclados incluem resistência do concreto de origem, valores de abrasão Los Angeles e absorção de água. As resistências à compressão aos 28 dias variaram aproximadamente de 31,8 MPa a 45,2 MPa.

Para melhorar o conjunto de dados para fins de modelagem, cada instância foi expandida por meio de variação controlada ( $\pm 10\%$ ) aplicada a parâmetros selecionados da mistura, resultando em 1.125 observações. Para validação experimental, uma série de corpos de prova correspondentes a cada modificação foi preparada e ensaiada, gerando 1.125 valores medidos de resistência. Diversas técnicas de aprendizado de máquina, incluindo Regressão por Vetores de Suporte (SVR), Random Forest (RF), K-Nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost), Gradient Boosting (GB), Regressão Linear (LR), Least Absolute Shrinkage and Selection Operator (Lasso), Regressão Ridge (Ridge) e Elastic Net (EN), foram implementadas para prever a resistência à compressão a partir dos parâmetros de entrada da mistura. Entre esses modelos, o SVR alcançou a maior precisão preditiva ( $R^2 = 0,998$ ), com erros mínimos (MAE = 0,008; RMSE = 0,011), demonstrando a efetividade das abordagens baseadas em IA para capturar relações complexas entre dosagem e resistência.

Este trabalho busca fornecer uma estrutura confiável para estimar a resistência à compressão do

CAR combinando previsões orientadas por IA com medições experimentais. O estudo apoia o uso sustentável de agregados reciclados no concreto, reduz custos experimentais e identifica os fatores de dosagem mais relevantes.

## 2. MATERIAIS E MÉTODOS

Água, plastificante, agregados naturais e reciclados e cimento Portland comum (OPC) foram os materiais empregados nesta investigação. O cimento atendeu às especificações normativas (International, 2024), fornecendo um ligante consistente para todas as misturas (Akbar & Liew, 2020a). De acordo com as normas ASTM C33 e C127, os agregados miúdos e graúdos naturais foram obtidos localmente e avaliados quanto à absorção de água, massa específica e distribuição granulométrica, cujos resultados são apresentados na Tabela 3.

### 2.1 Propriedades físicas dos agregados

As propriedades físicas dos agregados miúdos e graúdos naturais foram determinadas de acordo com normas ASTM aplicáveis, incluindo ASTM C127 e ASTM C128 para massa específica e absorção de água, e ASTM C33 para distribuição granulométrica. Essas propriedades são essenciais para avaliar a qualidade dos agregados e sua influência no desempenho do concreto. Os valores experimentais de massa específica, absorção de água e módulo de finura dos agregados naturais são apresentados na Tabela 1.

Tabela 1. Propriedades físicas dos agregados naturais utilizados neste estudo.

Propriedade	Agregado miúdo	Agregado graúdo
Massa específica relativa	2.62	2.68
Absorção de água (%)	1.2	0.8
Módulo de finura	2.7	-
Dimensão máxima característica (mm)	4.75	20
Grading Zone (as per ASTM C33)	Zona II	-

### 2.2 Propriedades físicas e mecânicas dos agregados reciclados

As propriedades físicas e mecânicas do agregado miúdo reciclado (RFA) e do agregado graúdo reciclado (RCA) foram determinadas para avaliar sua adequação à produção de concreto e sua influência no desenvolvimento da resistência. Propriedades-chave, como massa específica, absorção de água, massa unitária e porosidade, foram avaliadas de acordo com normas ASTM pertinentes.

De modo geral, os agregados reciclados apresentaram menor massa específica e maior absorção de água em comparação aos agregados naturais, devido à presença de argamassa aderida e microfissuras formadas durante o processo de britagem. Essas variáveis influenciam significativamente a zona de transição interfacial (ZTI) entre o agregado e a pasta de cimento, afetando o desempenho mecânico global do concreto com agregados reciclados.

A Tabela 2 resume as propriedades físicas medidas do RCA e do RFA utilizados neste estudo. Os resultados indicam aumento de porosidade e absorção de água, o que contribui para a redução da resistência em níveis mais elevados de substituição.

Tabela 2. Propriedades físicas e mecânicas dos agregados reciclados.

Propriedade	RFA	RCA
Massa específica relativa	2.4	2.55
Absorção de água (%)	5.5	4.5
Massa unitária (kg/m <sup>3</sup> )	1400	1500
Porosidade (%)	12	9
Abrasão Los Angeles (%)	-	25
Módulo de finura	2.6	-

*Nota: esses valores refletem variáveis típicas dos agregados reciclados, nos quais maior porosidade e absorção de água estão associadas à argamassa aderida e a defeitos microestruturais.*

Os agregados reciclados, tanto miúdos quanto graúdos, foram obtidos de resíduos de construção e demolição (C&D) compostos predominantemente por concreto britado coletado em atividades locais de demolição na mesma região geográfica. Embora o material não tenha sido proveniente de um único local de demolição, buscou-se assegurar consistência mediante a seleção de resíduos predominantemente à base de concreto.

O resíduo coletado foi submetido a triagem manual cuidadosa para remover impurezas como madeira, plásticos, armaduras de aço e outros constituintes não cimentícios. Fragmentos visíveis de alvenaria e materiais indesejáveis foram minimizados durante o processamento para assegurar que os agregados reciclados fossem predominantemente à base de concreto.

O material processado foi então britado e peneirado para obtenção das frações granulométricas necessárias ao agregado miúdo reciclado (RFA) e ao agregado graúdo reciclado (RCA). Embora pequenos traços de argamassa aderida sejam inerentes aos agregados reciclados, foram adotados esforços para manter a consistência da qualidade do material em todas as misturas, por meio de condições uniformes de processamento.

A resistência do concreto de origem associada aos agregados reciclados variou de 25 MPa a 45 MPa, conforme considerado no programa experimental. Essa abordagem controlada de seleção e processamento assegurou variáveis relativamente consistentes dos agregados, dando suporte à confiabilidade dos resultados experimentais e das previsões dos modelos baseados em aprendizado de máquina.

Conforme mostrado na Tabela 3, foram utilizados diferentes teores de cimento, agregados naturais e reciclados, água, superplastificante e relações água/cimento para produzir as misturas de concreto. Os níveis de substituição por agregados reciclados variaram de 0% a 100% tanto para agregados miúdos quanto graúdos. As relações água/cimento variaram de 0,35 a 0,55, e as resistências do concreto de origem ficaram entre 25 MPa e 45 MPa. O projeto de dosagem também considerou a absorção de água dos agregados reciclados e seus valores de abrasão Los Angeles, que influenciam a resistência à compressão. Cada mistura foi preparada em ambiente laboratorial controlado e curada sob condições padronizadas. A resistência à compressão aos 28 dias variou de 31,8 MPa a 45,2 MPa, ilustrando os efeitos do teor de agregados reciclados, da absorção de água e da qualidade do concreto de origem no desempenho mecânico. (Katz, 2003; Padmini et al., 2002)


Tabela 3. Proporções de mistura e variáveis dos materiais dos concretos ensaiados.

Mistura	Cimento (kg/m <sup>3</sup> )	Areia (kg/m <sup>3</sup> )	Agregado miúdo natural (kg/m <sup>3</sup> )	Agregado miúdo reciclado (kg/m <sup>3</sup> )	Agregado graúdo natural (kg/m <sup>3</sup> )	Agregado graúdo reciclado (kg/m <sup>3</sup> )	Água (kg/m <sup>3</sup> )	Aditivo plastificante (kg/m <sup>3</sup> )	a/c (-)	RCA %	RC	Absorção RCA (%)	Abrásão LA	fc,28d
M1	300	650	700	0	900	0	105	1.50	0.35	0	45	2.00	18	45.20
M2	320	640	600	100	800	100	110	2.56	0.40	25	40	3.00	21	42.80
M3	340	630	550	150	750	150	115	3.40	0.40	25	35	3.50	22	41.30
M4	360	620	500	200	700	200	120	4.32	0.45	50	35	4.00	24	38.60
M5	380	610	450	250	650	250	125	5.32	0.45	50	30	4.20	25	37.90
M6	400	600	400	300	600	300	130	6.40	0.50	75	30	5.00	26	35.50
M7	420	590	350	350	550	350	135	7.56	0.50	75	28	5.50	27	34.70
M8	440	580	300	400	500	400	140	8.80	0.55	100	25	6.00	28	32.50
M9	460	570	250	450	450	450	145	8.28	0.55	100	25	6.50	29	31.80
M10	480	560	200	500	400	500	150	7.68	0.50	75	30	5.80	28	34.00
M11	500	550	150	550	350	550	155	7.00	0.45	50	35	4.50	26	37.40
M12	450	570	100	600	300	600	150	5.40	0.40	25	40	3.50	24	40.80
M13	430	580	50	650	250	650	145	4.30	0.40	25	40	3.00	23	41.20
M14	410	590	0	700	200	700	140	3.28	0.35	0	45	2.50	20	44.70
M15	390	600	100	600	250	650	130	3.90	0.40	25	38	3.00	22	42.10
M16	370	610	150	550	300	600	125	4.44	0.45	50	35	4.00	24	39.50
M17	350	620	200	500	350	550	120	4.90	0.45	50	30	4.50	26	38.20
M18	330	630	250	450	400	500	115	5.28	0.50	75	28	5.00	27	35.60
M19	310	640	300	400	450	450	110	5.58	0.55	100	25	6.00	29	33.00
M20	300	650	350	350	500	400	105	6.00	0.55	100	25	6.50	30	32.20
M21	420	600	400	300	550	350	130	5.04	0.45	50	35	4.00	25	38.80
M22	440	590	450	250	600	300	135	6.16	0.45	50	30	4.50	26	38.00
M23	460	580	500	200	650	250	140	7.36	0.50	75	30	5.00	27	36.00
M24	480	570	550	150	700	200	145	8.64	0.50	75	28	5.50	28	34.50
M25	500	560	600	100	750	150	150	10.00	0.55	100	25	6.00	29	32.80


*Nota:* w/c = relação água/cimento; RCA = agregado graúdo reciclado; RFA = agregado miúdo reciclado.

Para cada mistura de concreto, foram preparados corpos de prova para avaliar a resistência à compressão aos 28 dias segundo as normas aplicáveis. Cubos com dimensões de  $150 \times 150 \times 150$  mm foram moldados para cada mistura, adensados em mesa vibratória padrão para assegurar densidade uniforme e cobertos com manta úmida para evitar perda de umidade durante a cura inicial. Em seguida, os corpos de prova foram submersos em água a  $23 \pm 2$  °C por 28 dias para alcançar hidratação completa. Os resultados demonstraram redução gradual da resistência à compressão com o aumento da substituição por agregados reciclados, especialmente em níveis mais elevados de absorção de água, destacando a influência da qualidade do concreto de origem e das variáveis dos agregados reciclados no desempenho do CAR. (International, 2024; Zain et al., 2002)(Ajdukiewicz & Kliszczewicz, 2002; Khatib, 2005)(Katz, 2003; Padmini et al., 2002)

(a) Variação da resistência entre os níveis de RCA



(b) Teor de cimento vs Resistência



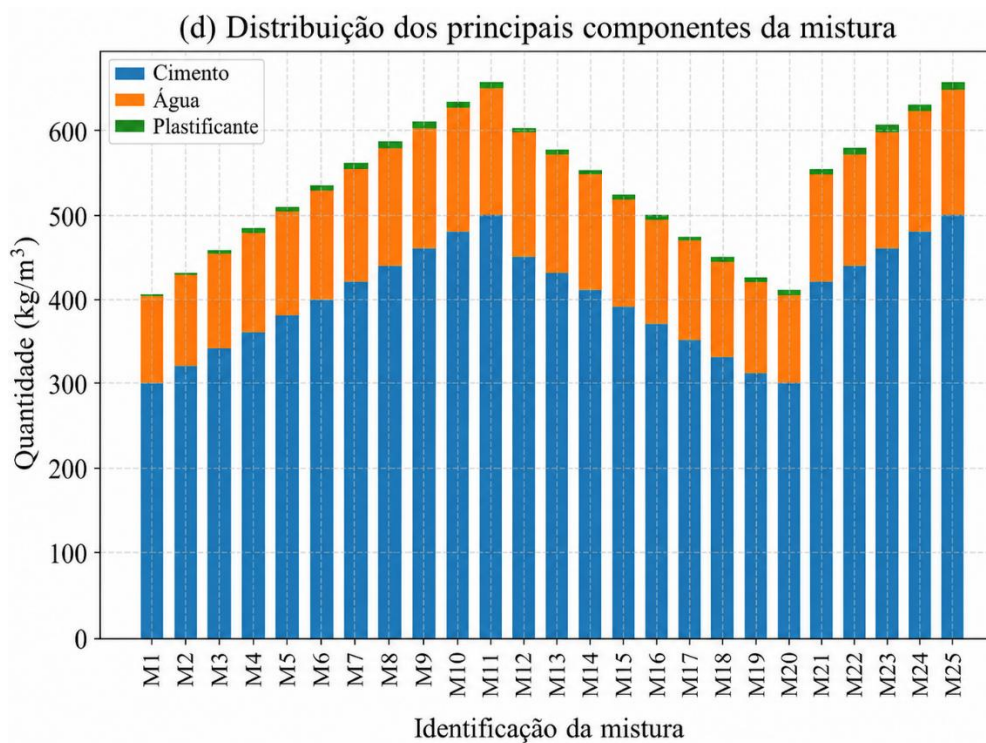
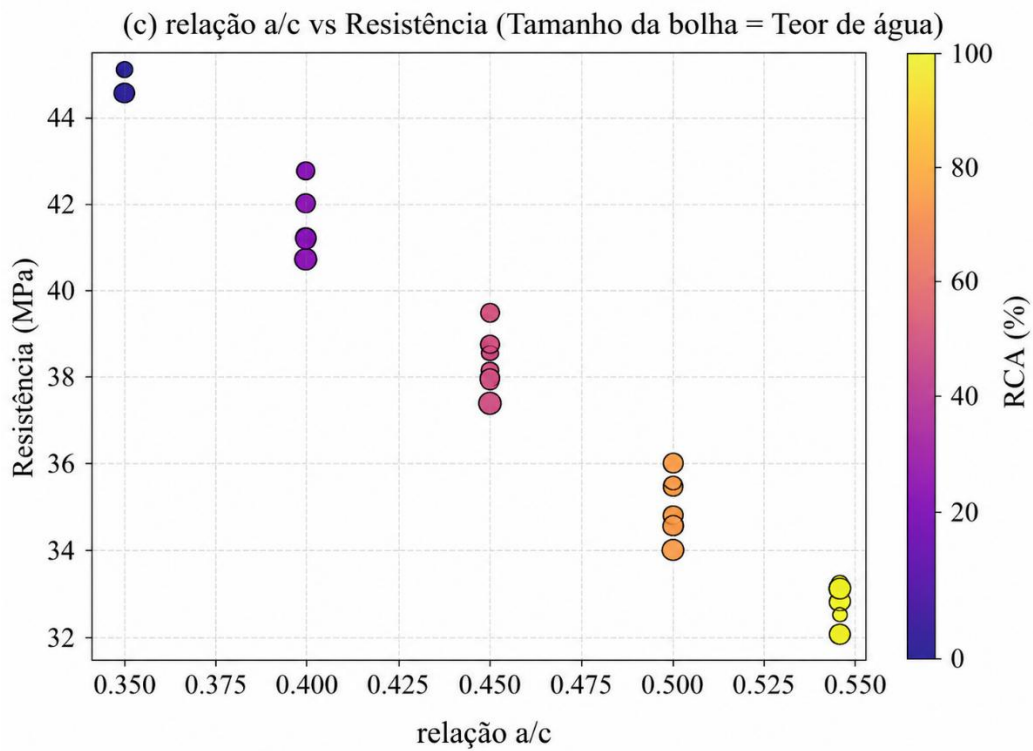


Figura 1. Visualização estatística do conjunto de dados do CAR, mostrando a distribuição dos principais constituintes da mistura e a resistência à compressão dos traços. (a) Variação da resistência em diferentes níveis de RCA, (b) teor de cimento versus resistência, (c) a/c versus resistência, (d) distribuição dos principais componentes da mistura.

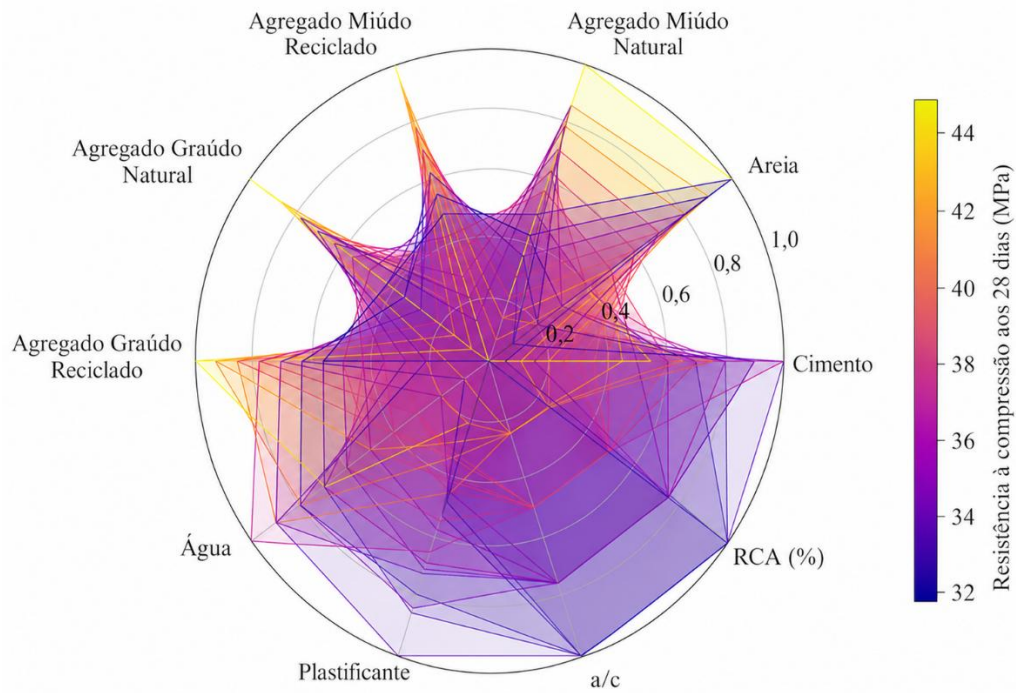


Figura 2. Gráfico radar dos parâmetros normalizados de dosagem para todas as 25 misturas experimentais de concreto com agregados reciclados (CAR).




Figura 3. Gráfico de coordenadas paralelas para o conjunto experimental completo de CAR.

A distribuição estatística dos principais componentes de mistura no conjunto de dados do CAR, que compreende concretos produzidos com diferentes proporções de agregados naturais e reciclados, é apresentada na Figura 1. Os boxplots ilustram a variabilidade dos teores de cimento, areia, agregados graúdos e miúdos, agregados reciclados, água e aditivo plastificante, juntamente com as correspondentes resistências à compressão aos 28 dias. A distribuição da resistência em diferentes níveis de RCA mostra redução consistente à medida que a proporção de agregados reciclados aumenta. Essa tendência reflete a influência da argamassa aderida, da maior porosidade

e da menor rigidez geralmente associadas aos agregados reciclados. A dispersão observada em cada grupo de RCA também indica a variabilidade introduzida pelas alterações na composição da mistura. A figura evidencia a sensibilidade do desempenho mecânico à incorporação de RCA e fornece uma base estatística para a modelagem preditiva subsequente.

A Figura 2 apresenta um gráfico radar das misturas de concreto, mostrando valores normalizados de todos os parâmetros de dosagem, incluindo cimento, agregados naturais e reciclados, água, aditivo plastificante, relação água/cimento e teor de RCA. Cada polígono representa uma mistura, enquanto a intensidade da cor reflete a resistência à compressão correspondente. O gráfico fornece uma visão integrada das interações multivariáveis no conjunto de dados e esclarece como variações na composição dos agregados, na demanda de água e no teor de RCA se relacionam com o desenvolvimento da resistência. Antes da aplicação dos modelos baseados em aprendizado de máquina, essa visualização fornece uma leitura clara da variabilidade dos parâmetros.

A Figura 3 apresenta o gráfico de coordenadas paralelas do conjunto experimental, no qual cada mistura é representada por uma polilinha que conecta todos os parâmetros de entrada. Esse formato permite a comparação direta de tendências dos parâmetros, especialmente o efeito do percentual de RCA, do teor de água e das proporções de agregados sobre a resistência à compressão. A figura enfatiza as relações multivariáveis no conjunto de dados e apoia a identificação de padrões relevantes para o desenvolvimento dos modelos e a avaliação de desempenho.

A maior porosidade e absorção de água dos agregados reciclados afetam diretamente a zona de transição interfacial (ZTI), que normalmente é a região mais fraca do concreto. A presença de argamassa aderida e defeitos microestruturais no RCA conduz a uma ZTI mais porosa, resultando em menor aderência entre agregado e pasta de cimento. Esse fenômeno torna-se mais pronunciado em níveis mais elevados de substituição, contribuindo para a redução observada da resistência à compressão.

### 3. MODELAGEM POR APRENDIZADO DE MÁQUINA

O conjunto experimental de dosagens de concreto foi utilizado como entrada para a modelagem baseada em aprendizado de máquina, visando prever a resistência à compressão aos 28 dias do concreto com agregados reciclados (CAR). A quantidade de cimento, as proporções de agregados miúdos e grãos naturais e reciclados, a relação água/cimento, a dosagem de aditivo plastificante, a resistência do concreto de origem, a absorção de água dos agregados reciclados e os valores de abrasão Los Angeles (LA) foram utilizados para definir cada mistura. Para aumentar a robustez do conjunto de dados, adotou-se uma abordagem de expansão controlada por meio da introdução de variação limitada de  $\pm 10\%$  em parâmetros selecionados da mistura. Essa variação foi aplicada dentro de limites realistas de engenharia para simular pequenas flutuações que normalmente ocorrem nas propriedades dos materiais e nas condições de campo, em vez de duplicar artificialmente observações idênticas.

Diferentemente de métodos puramente sintéticos de geração de dados, essa abordagem preserva as relações físicas subjacentes entre as variáveis, ao mesmo tempo em que permite que os modelos baseados em aprendizado de máquina generalizem melhor em um espaço paramétrico realista. Contudo, reconhece-se que essa forma de aumento de dados pode introduzir algum grau de tendência; portanto, os resultados devem ser interpretados com a devida cautela. Essa abordagem permitiu melhor generalização dos algoritmos de aprendizado de máquina e reduziu o risco de superajuste. (Farhangi et al., 2021; Jahangir et al., 2021)

Técnicas mais avançadas de aumento de dados, como Synthetic Minority Over-sampling Technique (SMOTE) ou Generative Adversarial Networks (GANs), não foram empregadas neste estudo, pois o conjunto de dados não representa um problema de classificação nem um cenário de dados desbalanceados. Além disso, o foco do presente trabalho é preservar relações fisicamente

interpretáveis, e não gerar amostras inteiramente sintéticas. Estudos futuros podem explorar essas técnicas avançadas para melhorar ainda mais a generalização e a robustez dos modelos.

Nove técnicas de aprendizado de máquina foram implementadas para modelar a relação entre as variáveis de entrada da mistura e a resistência à compressão. Essas técnicas incluíram Regressão por Vetores de Suporte (SVR), Random Forest (RF), K-Nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost), Gradient Boosting (GB), Regressão Linear (LR), Regressão Lasso, Regressão Ridge e Elastic Net (EN). Modelos não lineares, como SVR, RF e métodos ensemble (XGBoost e GB), foram selecionados por sua capacidade de capturar interações complexas e não lineares entre múltiplas variáveis, comuns no CAR devido à variabilidade da qualidade dos agregados reciclados, da absorção de água e da resistência do concreto de origem. (Bilim, Atis, et al., 2009; Deng et al., 2018; Naderpour et al., 2018)

Embora propriedades físicas detalhadas dos agregados reciclados, como absorção de água e abrasão Los Angeles, tenham sido incorporadas ao conjunto de dados, outras variáveis, como porosidade e densidade, não foram explicitamente incluídas como variáveis independentes de entrada. Entretanto, sua influência é refletida de forma inerente por meio de parâmetros correlacionados, como absorção de água e resistência do concreto de origem, fortemente associados à porosidade e à qualidade dos agregados.

Estudos futuros podem incorporar um conjunto mais amplo de propriedades físicas e microestruturais dos agregados como variáveis diretas de entrada, a fim de ampliar a interpretabilidade e a capacidade preditiva dos modelos.

O conjunto de dados foi dividido em subconjuntos de treinamento (80%) e teste (20%) para avaliar o desempenho preditivo. As métricas de avaliação dos modelos incluíram coeficiente de determinação ( $R^2$ ), erro absoluto médio (MAE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro percentual absoluto médio (MAPE) e erro médio de tendência (MBE). O SVR alcançou a maior precisão preditiva, com  $R^2 = 0,998$ , MAE = 0,008 e RMSE = 0,011, indicando excelente concordância entre os valores previstos e experimentais de resistência à compressão. O Random Forest foi o segundo melhor modelo, com  $R^2 = 0,996$  e erros ligeiramente maiores (MAE = 0,128; RMSE = 0,179). Os modelos KNN e XGBoost apresentaram desempenho moderado, com valores de  $R^2$  de 0,947 e 0,942, respectivamente, enquanto o Gradient Boosting e os modelos lineares (LR, Lasso, Ridge, Elastic Net) demonstraram menor precisão preditiva ( $R^2$  variando de 0,842 a 0,904), destacando a superioridade dos algoritmos não lineares para esse tipo de conjunto de dados. (Farhangi et al., 2021; Ghanizadeh et al., 2019)

Foi realizada análise de importância das variáveis para compreender a influência de cada entrada na resistência à compressão do CAR. A relação água/cimento, o teor de agregado graúdo reciclado e a resistência do concreto de origem foram identificados como os parâmetros mais críticos que influenciam a resistência à compressão, enquanto a dosagem de aditivo plastificante e as proporções de agregados miúdos tiveram efeito comparativamente menor. Essa abordagem reduz a necessidade de longos programas experimentais ao orientar a otimização da dosagem para aplicações reais, além de validar os dados experimentais.




Figura 4. Resistência à compressão prevista versus real aos 28 dias usando parâmetros de entrada combinados.

A Figura 4 mostra a relação entre as resistências à compressão previstas e medidas aos 28 dias, obtidas a partir do modelo desenvolvido com todos os parâmetros de entrada. Os pontos apresentam alinhamento próximo à linha de previsão perfeita, indicando forte concordância entre valores experimentais e estimados. As bandas de desvio de  $\pm 10\%$  fornecem uma referência visual clara para a precisão do modelo, com a maioria dos pontos situada dentro dessa faixa. O elevado coeficiente de determinação ( $R^2 = 0,990$ ) confirma ainda mais a confiabilidade do modelo e sua capacidade de capturar os principais fatores que governam o desenvolvimento da resistência.

A combinação da modelagem baseada em aprendizado de máquina com dados experimentais cria uma ferramenta robusta para prever com eficiência as propriedades do CAR. A abordagem minimiza o trabalho experimental com elevado consumo de recursos, garantindo estimativas de resistência confiáveis e precisas. Esses resultados reforçam o potencial dos métodos orientados por IA no projeto sustentável de concretos, em que múltiplos níveis de agregados reciclados e qualidades variáveis de materiais precisam ser considerados simultaneamente. (Deng et al., 2018; Jahangir et al., 2021; Naderpour et al., 2018)

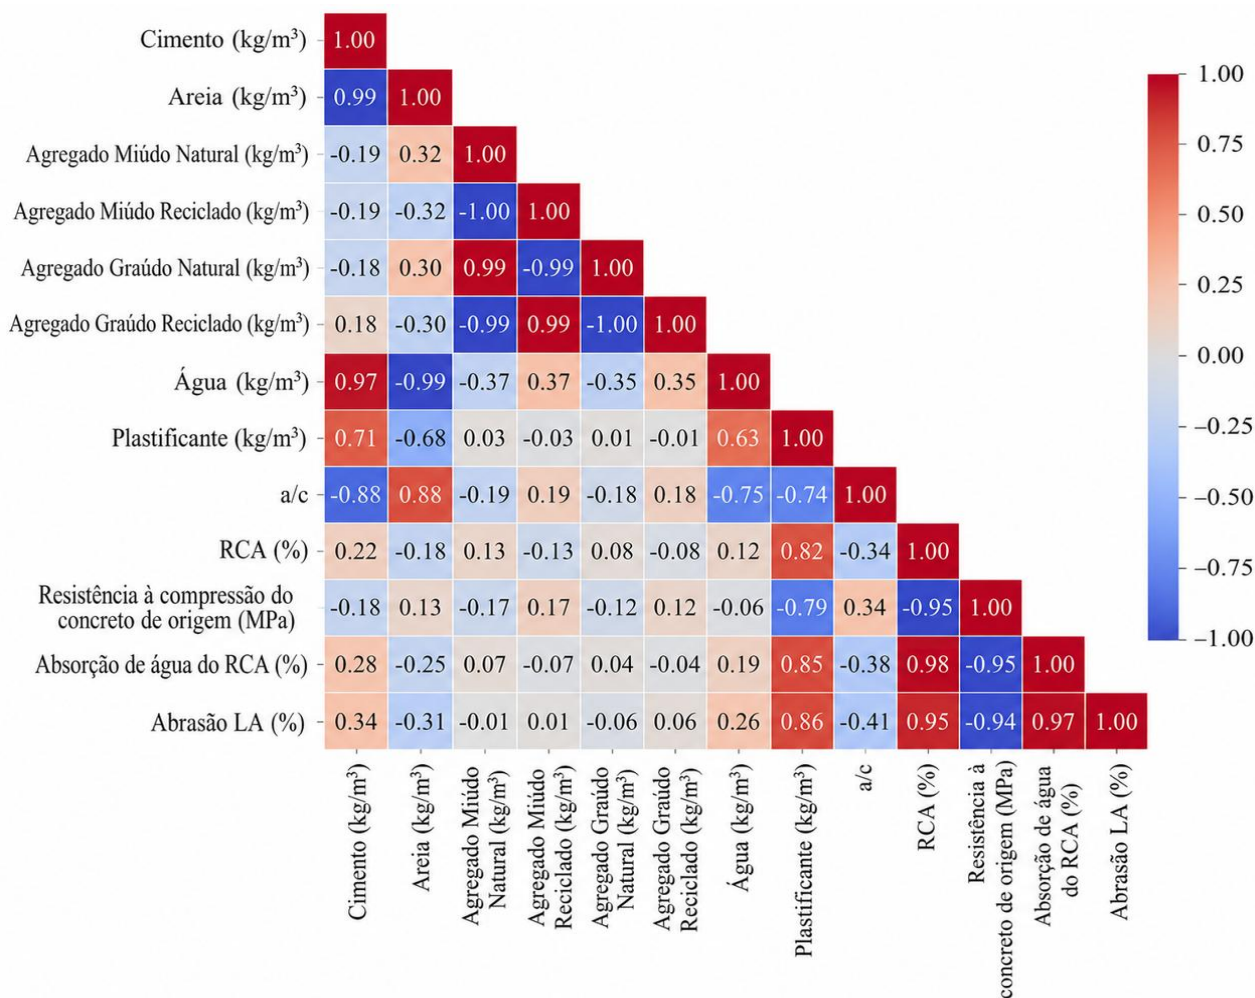


Figura 5. Mapa de calor de correlação mostrando as relações entre os parâmetros de dosagem do concreto.

A Figura 5 apresenta a matriz de correlação de Pearson para as variáveis de entrada utilizadas no conjunto de dados das misturas de concreto. O mapa de calor destaca a intensidade e a direção das relações lineares entre os parâmetros. Correlações positivas relevantes são observadas entre cimento e água, bem como entre teor de aditivo plastificante e absorção de água do RCA. Em contraste, correlações negativas fortes aparecem entre cimento e areia e entre a relação água/cimento e o teor de cimento. Esses padrões refletem interações fundamentais no projeto de dosagem e fornecem orientação útil para compreender dependências entre parâmetros, melhorar estratégias de otimização da mistura e apoiar a seleção de variáveis para a modelagem preditiva da resistência à compressão.

Este estudo utilizou uma variedade de métodos de aprendizado de máquina (ML) para prever a resistência à compressão do concreto com agregados reciclados (CAR). Ao todo, nove modelos foram implementados, abrangendo regressão linear, modelos lineares regularizados, modelos baseados em núcleo, vizinhos mais próximos, métodos ensemble baseados em árvores e abordagens de gradient boosting. O desempenho preditivo de cada modelo foi avaliado por múltiplas métricas estatísticas, incluindo coeficiente de determinação (R<sup>2</sup>), erro absoluto médio (MAE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro percentual absoluto médio (MAPE), erro médio de tendência (MBE) e estatística t. Para assegurar comparabilidade, todos os modelos foram treinados usando divisão treino-teste 80/20 com variáveis numéricas padronizadas. (Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

Tabela 4. Faixa das variáveis consideradas para a construção do modelo.

Parâmetro de entrada	Mín.	Máx.	Média	Desv. padrão	Variância
Cimento (kg/m <sup>3</sup> )	300	500	401.27	61.9	3831.31
Areia (kg/m <sup>3</sup> )	550	650	599.75	28.88	834.16
Agregado miúdo (kg/m <sup>3</sup> )	0	700	337.95	187.92	35315.6
Agregado miúdo reciclado (kg/m <sup>3</sup> )	0	700	362.05	187.92	35315.6
Agregado graúdo (kg/m <sup>3</sup> )	200	900	515.86	188.2	35418.1
Agregado graúdo reciclado (kg/m <sup>3</sup> )	0	700	384.14	188.2	35418.1
Água (kg/m <sup>3</sup> )	105	155	130.73	14.94	223.16
Plastificante (kg/m <sup>3</sup> )	1.5	10	5.72	2.05	4.19
a/c (-)	0.3	0.35484	0.33	0.02	0
RCA (%)	0	100	56.97	30.49	929.64
Concreto de origem (MPa)	25	45	32.49	6.09	37.07
Absorção de água do RCA (%)	2	6.5	4.52	1.25	1.56
Abrasão LA (%)	18	30	25.35	3.02	9.13
Resistência à compressão aos 28 dias (MPa)	28.74	49.45	37.53	4.35	18.9

A Tabela 4 resume a faixa estatística e a variabilidade dos parâmetros de entrada utilizados para construir o modelo. A tabela apresenta cimento, areia, agregados naturais e reciclados, água, aditivo plastificante, relação água/cimento, teor de RCA e propriedades associadas, como resistência do concreto de origem, absorção de água do RCA e abrasão Los Angeles, com seus respectivos valores mínimo, máximo, média, desvio padrão e variância. Os dados evidenciam a ampla faixa de valores considerada, refletindo a diversidade das misturas de concreto. Essa caracterização detalhada apoia a avaliação do efeito e das interações dos parâmetros e oferece uma base sólida para a modelagem preditiva da resistência à compressão aos 28 dias.

Embora parâmetros como densidade e porosidade dos agregados não tenham sido explicitamente incluídos como variáveis independentes de entrada, sua influência é representada indiretamente por parâmetros correlacionados, como absorção de água dos agregados reciclados, abrasão Los Angeles e resistência do concreto de origem. Esses parâmetros são amplamente reconhecidos como indicadores da qualidade, porosidade e integridade mecânica dos agregados.

A absorção de água reflete a estrutura interna de poros e a permeabilidade dos agregados reciclados, enquanto a abrasão Los Angeles fornece indicação de sua resistência à degradação mecânica. Em conjunto, essas variáveis capturam variáveis intrínsecas dos agregados reciclados que governam o comportamento da zona de transição interfacial (ZTI) e a resistência à compressão global do concreto.

Entretanto, reconhece-se que a inclusão direta de propriedades físicas adicionais, como massa unitária e porosidade, como variáveis independentes de entrada poderia ampliar a interpretabilidade e a capacidade preditiva do modelo. Esse aspecto é identificado como escopo para pesquisas futuras.

Tabela 5. Indicadores de desempenho utilizados para avaliar os modelos de regressão.

Métrica	Fórmula	Descrição	Valor padrão/de referência
Coeficiente de determinação (R <sup>2</sup> )	$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$	Indica o quanto os valores previstos correspondem aos dados observados; mede o ajuste global.	0 a 1; valores mais altos indicam melhor ajuste (R <sup>2</sup> ≥ 0,8 considerado bom)
Erro quadrático médio (MSE)	$MSE = \frac{1}{N} \sum (y_i - \hat{y}_i)^2$	Média das diferenças quadráticas entre valores previstos e reais.	Quanto mais próximo de 0, melhor; sem padrão absoluto (depende da escala dos dados)
Raiz do erro quadrático médio (RMSE)	$RMSE = \sqrt{\frac{1}{N} \sum (y_i - \hat{y}_i)^2}$	Raiz quadrada do MSE; quantifica a magnitude típica dos erros de previsão.	Quanto mais próximo de 0, melhor; deve ser comparado em relação à faixa da variável-alvo
Erro absoluto médio (MAE)	$MAE = \frac{1}{N} \sum  y_i - \hat{y}_i $	Média das diferenças absolutas entre valores previstos e observados.	Quanto mais próximo de 0, melhor; recomenda-se comparação relativa
Erro percentual absoluto médio (MAPE)	$MAPE = \frac{100}{N} \sum \left  \frac{y_i - \hat{y}_i}{y_i} \right $	Desvio percentual médio das previsões em relação aos valores medidos.	<10% excelente, 10–20% bom, 20–50% aceitável, >50% ruim
Erro médio de tendência (MBE)	$MBE = \frac{1}{N} \sum (y_i - \hat{y}_i)$	Diferença média com sinal entre valores previstos e observados, indicando tendência sistemática.	0 ideal; positivo indica subestimação, negativo superestimação
Estatística t (t)	$t = \sqrt{\frac{(N-1)MBE^2}{RMSE^2 - MBE^2}}$	Estatística usada para avaliar se o tendência médio é significativamente diferente de zero.	

Aqui,  $N$  representa o número de amostras em cada dobra da validação cruzada. A estatística  $t$  é empregada para determinar se a diferença média entre erros pareados de previsão é estatisticamente significativa. As notações  $y_i$  e  $\hat{y}_i$  referem-se, respectivamente, aos valores observados e previstos.

As métricas estatísticas utilizadas para avaliar o desempenho preditivo dos modelos de regressão estão compiladas na Tabela 5. O coeficiente de determinação (R<sup>2</sup>) fornece uma medida global da qualidade do ajuste, representando a parcela da variância da resistência à compressão medida que é capturada pelas previsões do modelo. Enquanto o erro percentual absoluto médio (MAPE) reflete desvios em relação aos valores observados, métricas baseadas em erro, como MSE, RMSE e MAE, quantificam a magnitude dos erros de previsão em termos absolutos e quadráticos. O erro médio de tendência (MBE) é incluído para identificar tendências sistemáticas de superestimação ou subestimação. A estatística  $t$  pareada é usada para avaliar se o tendência médio é estatisticamente

significativo. Esses indicadores são amplamente adotados em aplicações de regressão e aprendizado de máquina para modelagem do comportamento de materiais e desempenho estrutural, assegurando avaliação rigorosa e interpretável da precisão preditiva. (Chicco & Warrens, 2021; Emmert-Streib & Dehmer, 2019; Miller & others, 2024; Plevris et al., 2022; Steurer et al., 2021)

O processo de aprendizado de máquina utilizado para prever a resistência à compressão do concreto com agregados reciclados é mostrado na Figura 6. Na primeira etapa são descritos os parâmetros de entrada e os procedimentos de pré-processamento dos dados, como normalização e divisão do conjunto de dados em subconjuntos de treinamento e teste. A criação dos modelos preditivos e a otimização de hiperparâmetros para algoritmos como regressão por vetores de suporte, random forest, XGBoost e variações de regressão linear são abordadas na segunda etapa. Na terceira etapa, métricas estatísticas, como coeficiente de determinação, erro absoluto médio e raiz do erro quadrático médio, são utilizadas para avaliar o desempenho do modelo, e a influência das variáveis é interpretada por meio de análise baseada em SHAP. A etapa final informa a resistência à compressão prevista, completando uma estrutura organizada e transparente para avaliação e interpretação dos modelos.

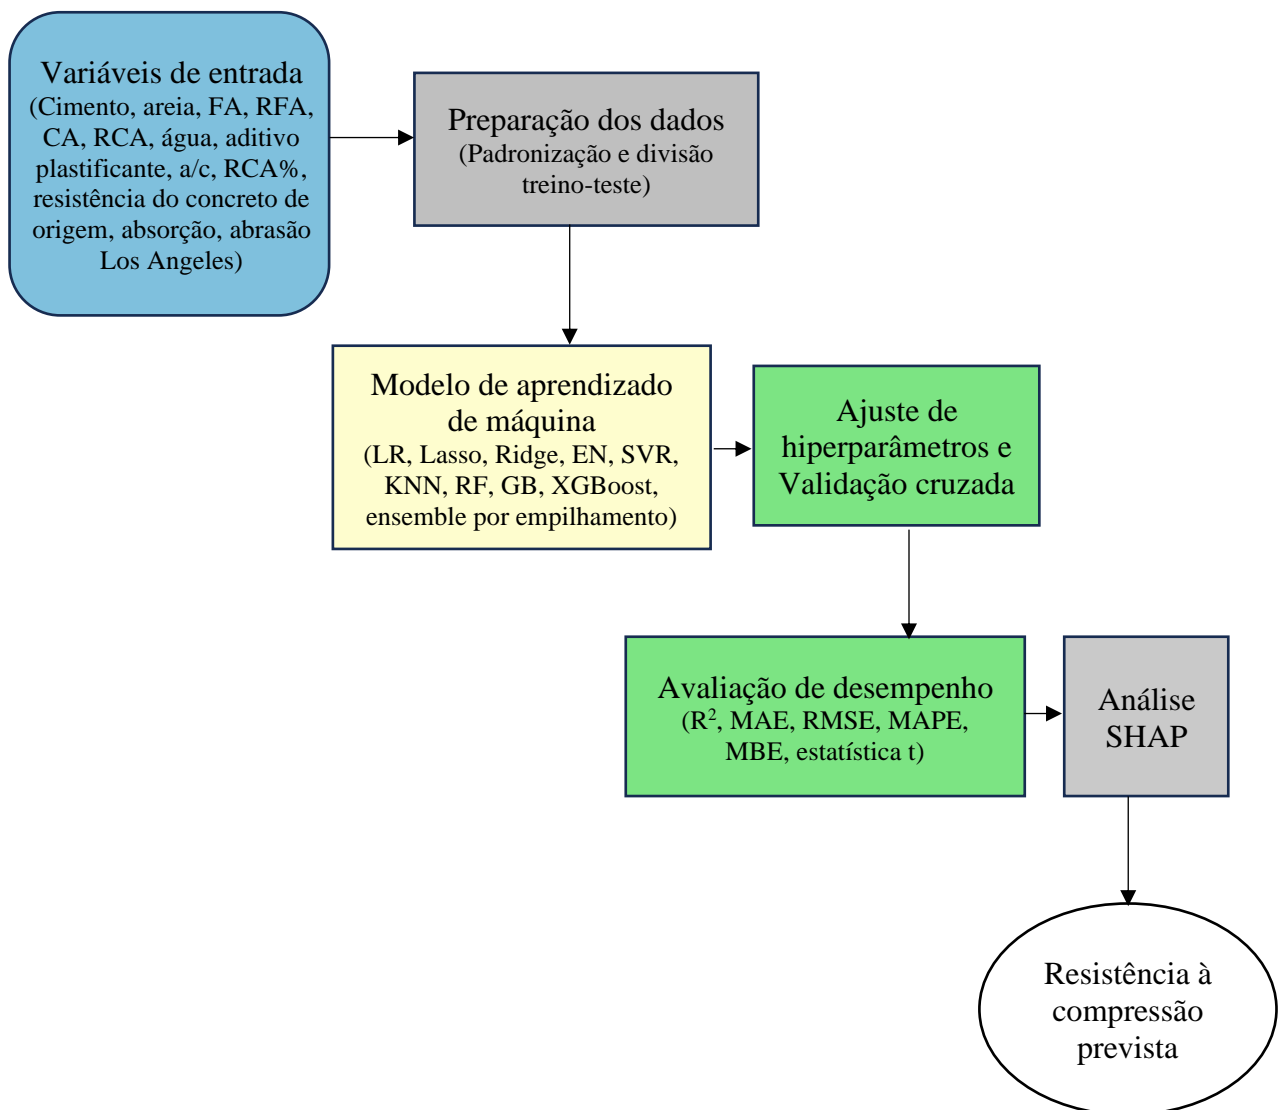


Figura 6. Fluxo de trabalho da estrutura de aprendizado de máquina para previsão da resistência à compressão do concreto com agregados reciclados.

### 3.1 Modelos de aprendizado de máquina utilizados neste estudo

#### 3.1.1 Regressão por Vetores de Suporte (SVR)

A Regressão por Vetores de Suporte (SVR) foi implementada com núcleo de função de base radial (RBF) para modelar dependências não lineares entre as variáveis de entrada e a resistência à compressão. Hiperparâmetros, incluindo o parâmetro de penalização C e a função de perda insensível a  $\epsilon$ , foram ajustados para minimizar o erro de previsão. O SVR alcançou a maior precisão preditiva entre os modelos individuais ( $R^2 = 0,998$ ), com erros mínimos (MAE = 0,008; RMSE = 0,011). Isso demonstra a eficiência das técnicas baseadas em kernel para capturar interações complexas entre variáveis e resposta no CAR. (Smola & Scholkopf, 2004)

Figura 6. Fluxo de trabalho da estrutura de aprendizado de máquina para previsão da resistência à compressão do concreto com agregados reciclados.

#### 3.1.2 Random Forest

Modelos de aprendizado de máquina utilizados neste estudo (Breiman, 2001; Geurts et al., 2006) Regressão por Vetores de Suporte (SVR).

#### 3.1.3 k-Vizinhos Mais Próximos (KNN)

O regressor KNN estima o valor-alvo como uma função da média das k instâncias de treinamento mais próximas no espaço de variáveis. Neste estudo, k foi definido como 5, e a distância euclidiana foi utilizada para identificar os vizinhos. O KNN apresentou desempenho moderadamente bom ( $R^2 = 0,947$ ), mas é sensível ao escalonamento das variáveis e a valores atípicos, evidenciando a importância do pré-processamento e da padronização. Sua abordagem de aproximação local pode modelar efetivamente pequenas não linearidades, mas apresenta limitações em dados de alta dimensionalidade quando comparada a modelos ensemble globais. (Altman, 1992)

#### 3.1.4 Gradient Boosting e XGBoost

O Gradient Boosting (GB) e o Extreme Gradient Boosting (XGBoost) constroem sequencialmente árvores de decisão, cada uma corrigindo os erros da anterior, para minimizar uma função de perda especificada. O GB foi implementado com 400 árvores, taxa de aprendizado de 0,05 e profundidade máxima 4, enquanto o XGBoost utilizou 600 árvores, taxa de aprendizado de 0,03, profundidade máxima 5 e subamostragem de 0,9. Ajuste extensivo de hiperparâmetros e validação cruzada em 5 partes foram aplicados para prevenir superajuste e melhorar a generalização. Ambos os modelos demonstraram forte capacidade de modelagem não linear, alcançando valores de  $R^2$  de 0,904 (GB) e 0,942 (XGBoost). (Chen & Guestrin, 2016; Friedman, 2001)

#### 3.1.5 Modelos de regressão linear

A regressão linear (LR) assume uma relação linear entre a variável-alvo, resistência à compressão, e as variáveis de entrada. O método dos mínimos quadrados ordinários (OLS) foi utilizado para minimizar a diferença entre valores observados e previstos, fornecendo uma linha de base simples para comparação. Regressão Ridge, Lasso e Elastic Net são exemplos de modelos lineares regularizados utilizados para reduzir o superajuste e aprimorar a generalização. O Lasso utiliza regularização L1 para seleção de variáveis, a Ridge utiliza regularização L2 para penalizar coeficientes elevados, e o Elastic Net combina as duas penalizações. Esses modelos alcançaram valores de  $R^2$  variando de 0,842 a 0,893, indicando desempenho razoável, porém capacidade limitada de capturar interações não lineares inerentes aos conjuntos de dados de CAR. (Bhanja & Sengupta, 2005) (Hastie et al., 2009)

#### 3.1.6 Elastic Net

A regressão Elastic Net (EN) incorpora termos de regularização L1 (Lasso) e L2 (Ridge),

permitindo selecionar variáveis mantendo estabilidade quando há multicolinearidade entre as variáveis de entrada. Ao ajustar o parâmetro de mistura, o Elastic Net pode deslocar o equilíbrio entre a esparsidade L1 e a contração L2, sendo particularmente útil quando há preditores correlacionados, como é comum em conjuntos de dados de dosagem de concreto, nos quais múltiplas propriedades dos materiais interagem. Para maximizar a generalização, o Elastic Net foi utilizado nesta investigação com razão L1 moderada e escalonamento padrão das variáveis de entrada. O modelo produziu  $R^2$  de 0,846, ligeiramente inferior ao Ridge ou ao Lasso, indicando que, embora tenha capturado parcialmente tendências lineares dos dados, apresentou dificuldade em modelar plenamente os efeitos não lineares das propriedades dos agregados reciclados, da absorção de água e da resistência do concreto de origem. (Zou & Hastie, 2005) (Hastie et al., 2009; Zou & Hastie, 2005)

### **3.1.7 Regressão Ridge**

A Regressão Ridge (RR) é um método de regressão linear regularizada que reduz os coeficientes de regressão para evitar superajuste e melhorar a generalização, adicionando um termo de penalização L2 à função de custo padrão dos mínimos quadrados. Essa abordagem funciona bem quando os preditores apresentam forte correlação, pois ajuda a controlar a variância mantendo todas as variáveis no modelo. No presente estudo, a regressão Ridge foi utilizada para estimar a resistência à compressão aos 28 dias do concreto com agregados reciclados, e todas as variáveis de entrada foram padronizadas para manter influência uniforme entre elas. O modelo alcançou  $R^2$  de 0,842, indicando desempenho preditivo moderado. Embora a Ridge tenha lidado efetivamente com a multicolinearidade entre parâmetros de dosagem, como relação água/cimento, teor de agregados reciclados e propriedades dos agregados, foi limitada na captura de interações não lineares inerentes aos conjuntos de dados de CAR, quando comparada a modelos ensemble ou baseados em núcleo. (Hoerl & Kennard, 1970) (Hastie et al., 2009; Hoerl & Kennard, 1970)

### **3.1.8 Modelo ensemble por empilhamento**

Para aproveitar as capacidades complementares dos modelos individuais, foi implementado um ensemble por empilhamento, combinando os regressores de melhor desempenho. No empilhamento, aprendizes de base geram previsões que servem como entradas para um meta-aprendiz, otimizando a acurácia final. O ensemble por empilhamento alcançou precisão preditiva quase perfeita ( $R^2 = 0,999$ ), superando significativamente os modelos individuais em todas as métricas. Isso sugere que interações complexas entre fatores de dosagem e resistência à compressão podem ser capturadas de forma eficiente pela integração de modelos heterogêneos. (Wolpert, 1992; J. Zhang et al., 2022)

### **3.1.9 Ajuste de hiperparâmetros e validação cruzada**

A busca em grade foi utilizada para otimização de hiperparâmetros em todos os modelos de ML, e a validação cruzada foi empregada para assegurar a robustez dos modelos. Parâmetros como taxa de aprendizado, número de estimadores, profundidade máxima, coeficientes de regularização e número de vizinhos foram ajustados sistematicamente para minimizar erros de validação. A validação cruzada permitiu identificar comportamentos de subajuste ou superajuste, assegurando previsões generalizáveis. Para equilibrar adequadamente tendência e variância, critérios de parada antecipada foram usados nos modelos de boosting para interromper o treinamento quando nenhuma melhoria fosse observada. (Chen & Guestrin, 2016; Hastie et al., 2009)

Embora redes neurais artificiais (ANN) e outras arquiteturas de aprendizado profundo, como redes de função de base radial, tenham demonstrado forte desempenho na previsão de propriedades do concreto, elas não foram priorizadas no presente estudo devido ao tamanho relativamente limitado e à natureza estruturada do conjunto de dados experimental.

Modelos de aprendizado profundo geralmente requerem conjuntos de dados grandes e diversos para alcançar generalização confiável e evitar superajuste. Em contraste, o presente estudo concentra-se em um conjunto experimental controlado, com parâmetros de entrada bem definidos, no qual modelos clássicos de aprendizado de máquina, como Regressão por Vetores de Suporte e métodos ensemble (Random Forest, Gradient Boosting), são reconhecidamente eficazes.

Além disso, os modelos selecionados oferecem melhor interpretabilidade e eficiência computacional, permitindo uma compreensão mais clara da influência dos parâmetros de dosagem na resistência à compressão. Isso está alinhado ao objetivo do estudo, que não é apenas alcançar previsão precisa, mas também compreender o comportamento material subjacente.

Ainda assim, reconhece-se o potencial das ANN e das abordagens de aprendizado profundo, e trabalhos futuros poderão explorar sua aplicação com conjuntos de dados maiores e mais diversos.

#### 4. DESCRIÇÃO E ANÁLISE DO CONJUNTO DE DADOS

Para o presente estudo, foi utilizado um conjunto de dados abrangente composto por 1.125 amostras, combinando 25 misturas experimentais de concreto replicadas 45 vezes com variação aleatória de  $\pm 10\%$  para capturar a variabilidade dos parâmetros de dosagem e das condições de medição. Esse método assegura um conjunto de dados robusto e diverso, adequado a aplicações de aprendizado de máquina. O conjunto inclui 13 variáveis de entrada: cimento, areia natural, agregado miúdo (FA), agregado miúdo reciclado (RFA), agregado graúdo (CA), agregado graúdo reciclado (RCA), água, superplastificante, relação água/cimento (a/c), percentual de substituição por RCA, resistência do concreto de origem, absorção de água do RCA e valores de abrasão Los Angeles (LA). A variável-alvo é a resistência à compressão aos 28 dias (CS) do concreto com agregados reciclados. (Goodfellow et al., 2016; Naderpour et al., 2018)

Para descrever o conjunto de dados, foram calculadas estatísticas descritivas para cada parâmetro, incluindo mínimo, máximo, média, desvio padrão, assimetria e curtose. Cimento, agregados miúdos e graúdos e água apresentaram variação moderada entre as misturas, enquanto o teor de RCA, a absorção de água do RCA e a abrasão Los Angeles demonstraram maior variabilidade devido às diferenças nas propriedades dos materiais reciclados. A assimetria de cada variável indicou a assimetria da distribuição dos dados: assimetria positiva foi detectada para absorção de água do RCA e teor de RFA, sugerindo maior frequência de valores baixos, enquanto assimetria negativa apareceu nos teores de agregado graúdo natural e cimento, refletindo agrupamento em valores mais altos. A análise de curtose revelou valores de pico relativamente elevados para superplastificante e RCA, destacando a distribuição concentrada de aditivos específicos em misturas selecionadas. Esses resultados estatísticos confirmam que o conjunto de dados captura adequadamente variações em materiais naturais e reciclados, permitindo modelagem confiável por aprendizado de máquina. (Field, 2013) (Jahangir & Eidgahee, 2020)

O conjunto de dados apresenta variabilidade suficiente, tamanho amostral adequado e relação equilibrada entre variáveis de entrada e observações, tornando-o apropriado para previsão da resistência à compressão do CAR com base em aprendizado de máquina. Para fornecer rigor experimental e relevância prática ao projeto sustentável de concretos, a combinação de estatísticas descritivas, visualizações e análise de correlação oferece uma base sólida para os procedimentos posteriores de modelagem e seleção de variáveis. (Bilim, Ozbakkaloglu, et al., 2009; Naderpour et al., 2018)

##### 4.1 Avaliação de desempenho dos modelos

Utilizando o conjunto experimental de misturas de concreto e suas réplicas ampliadas, o presente trabalho aplicou modelos baseados em aprendizado de máquina e regressão múltipla para prever a resistência à compressão aos 28 dias do concreto com agregados reciclados (CAR). Os modelos

avaliados incluem LR, Ridge, Lasso, EN, SVR, KNN, RF, GB e XGBoost. Diversos indicadores foram utilizados para avaliar o desempenho dos modelos, incluindo coeficiente de determinação ( $R^2$ ), erro absoluto médio (MAE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro percentual absoluto médio (MAPE), erro médio de tendência (MBE) e estatística t, proporcionando uma compreensão abrangente da precisão preditiva e do tendência. (Farhangi et al., 2021; Jahangir & Eidgahee, 2020)

A Regressão Linear (LR) assume que as variáveis de entrada apresentam relação retilínea com a resistência à compressão. Embora seja fácil de compreender e aplicar, a LR é insuficiente para representar o comportamento não linear observado no concreto com agregados reciclados, no qual fatores como teor de substituição, absorção de água e resistência do concreto de origem interagem de forma mais complexa. Neste estudo, a LR alcançou  $R^2$  de 0,893 com MAE de 0,346, indicando desempenho preditivo moderado, mas com limitações para lidar com padrões não lineares complexos. (Bhanja & Sengupta, 2005)

A Figura 7 apresenta a capacidade do modelo de regressão linear na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. O modelo atinge  $R^2$  de 0,893, juntamente com baixos valores de erro absoluto médio e erro médio de tendência, demonstrando boa correspondência entre os valores medidos e previstos de resistência. O painel (a) mostra a comparação entre valores medidos e previstos, com a maioria dos pontos dentro dos limites de desvio de  $\pm 20\%$ . O painel (b) apresenta a superfície tridimensional do erro de previsão, oferecendo uma visão geral da distribuição dos resíduos no conjunto de dados e auxiliando na identificação de possíveis padrões ou desvios das premissas do modelo.

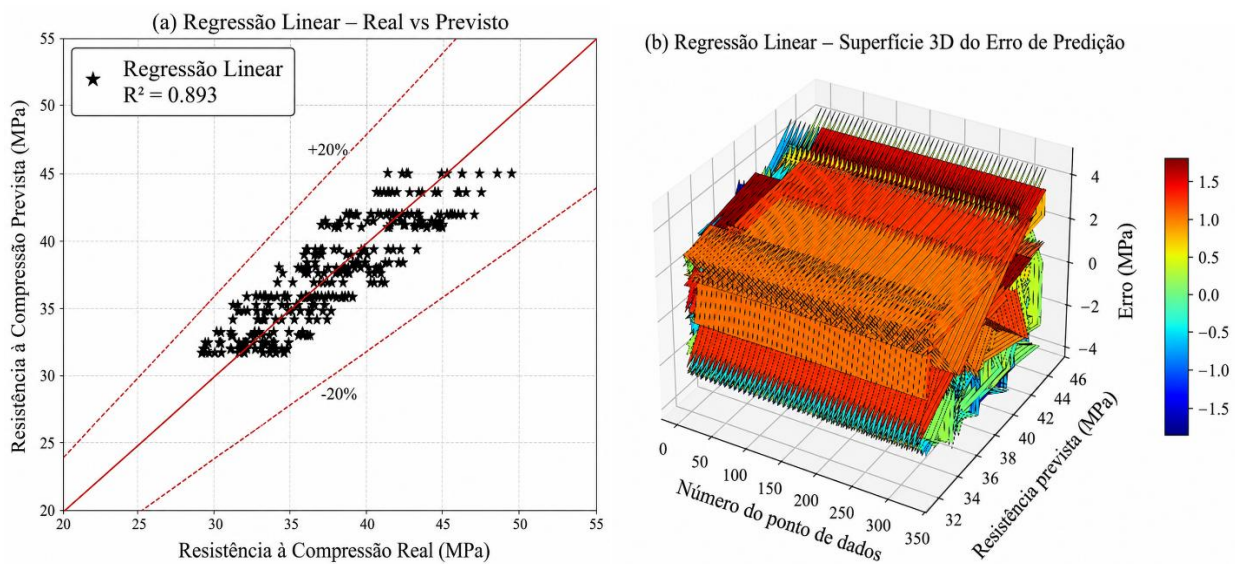


Figura 7. Desempenho do modelo de Regressão Linear para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

A Regressão Ridge amplia a LR pela incorporação de regularização L2, que penaliza coeficientes elevados para reduzir o superajuste e melhorar a generalização. A Ridge alcançou  $R^2$  de 0,842 e RMSE de 0,575. Embora lide ligeiramente melhor com multicolinearidade do que a LR, a Ridge ainda apresentou dificuldade para modelar dependências não lineares entre as propriedades dos agregados reciclados e a resistência à compressão. (Hoerl & Kennard, 1970)

A Figura 8 mostra o desempenho do modelo de regressão Ridge na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. O modelo atinge coeficiente de determinação de 0,842, indicando nível confiável de precisão preditiva. O painel (a) compara

resistências previstas e medidas, com a maioria dos pontos posicionada dentro da faixa de desvio de  $\pm 20\%$ . O painel (b) ilustra a superfície tridimensional de erro, fornecendo uma visão clara da distribuição dos resíduos no conjunto de dados e demonstrando o comportamento consistente do modelo sob condições variáveis de entrada.

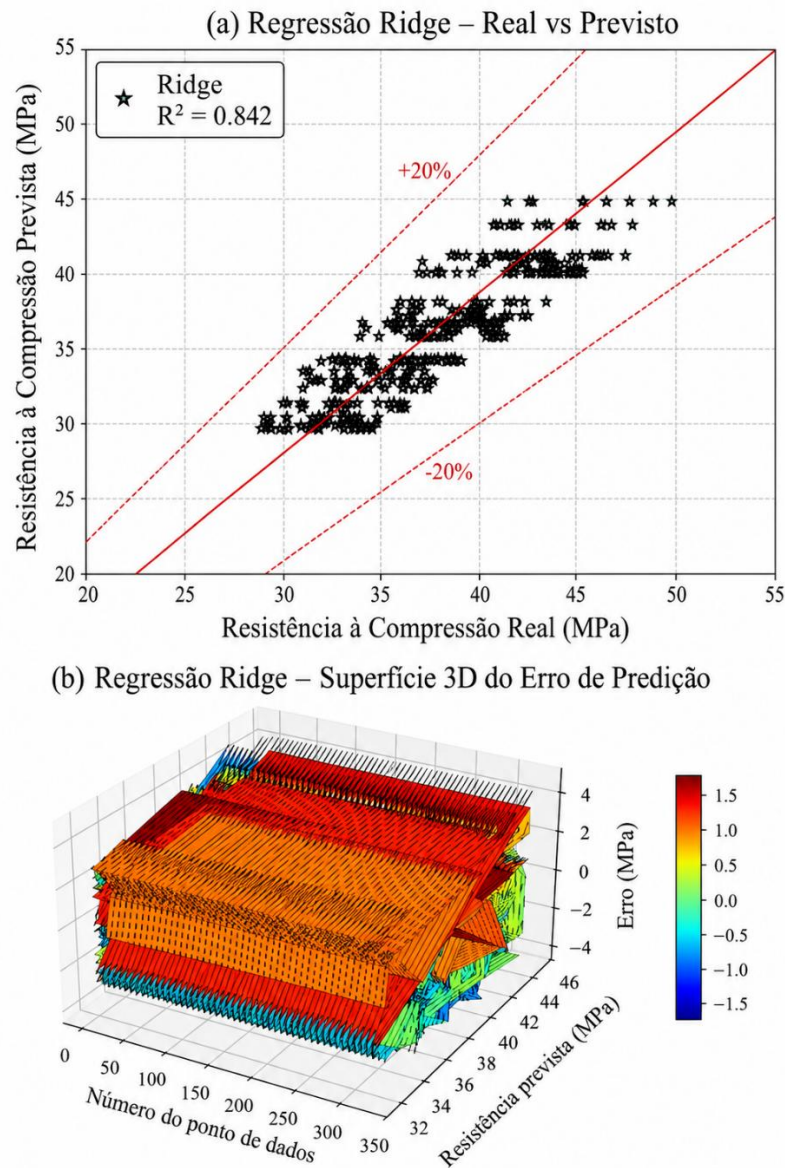


Figura 8. Desempenho do modelo de Regressão Ridge para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

A Regressão Lasso utiliza regularização L1 para impor esparsidade, realizando efetivamente seleção de variáveis. O Lasso produziu  $R^2$  de 0,879 e menor MAE de 0,364, destacando sua capacidade de enfatizar as variáveis mais influentes, como relação água/cimento, teor de RCA e abrasão Los Angeles. Entretanto, a estrutura linear limita sua capacidade de capturar integralmente interações complexas entre os parâmetros de dosagem. (Hastie et al., 2009)

A Figura 9 apresenta os resultados de previsão do modelo de regressão Lasso para avaliar a resistência à compressão aos 28 dias do concreto com agregados reciclados. O painel (a) mostra a

comparação entre valores medidos e previstos, com a maioria dos pontos situada dentro de  $\pm 20\%$  das resistências reais, indicando forte concordância. O painel (b) apresenta a superfície tridimensional de erro, destacando a distribuição dos resíduos e confirmando tendência sistemático mínimo nas previsões do modelo. O modelo alcança coeficiente de determinação de 0,879, juntamente com baixas métricas de erro (MAE = 0,364 MPa, MSE = 0,218 MPa<sup>2</sup>, RMSE = 0,467 MPa, MAPE = 0,987%, MBE = 0,018), demonstrando sua confiabilidade para estimativa precisa da resistência à compressão.

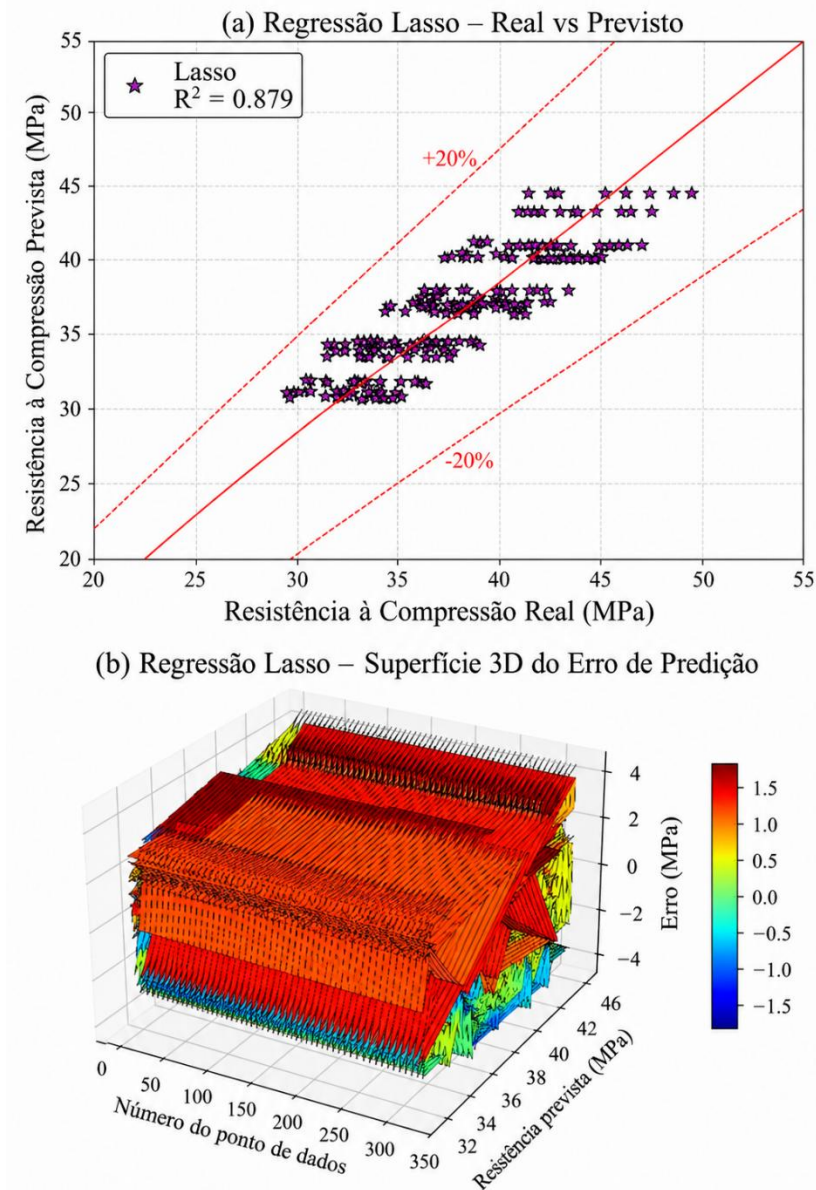


Figura 9. Desempenho do modelo de Regressão Lasso para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

O Elastic Net (EN) combina penalizações L1 e L2, equilibrando seleção de variáveis e contração de coeficientes. O EN alcançou R<sup>2</sup> de 0,846, oferecendo generalização ligeiramente melhor em comparação à Ridge, mas desempenho inferior às abordagens ensemble e não lineares. Seu desempenho sugere que, embora a regularização linear possa melhorar a estabilidade, as interações não lineares ainda exigem modelagem mais sofisticada. (Zou & Hastie, 2005)

A Figura 10 ilustra o desempenho do modelo de regressão Elastic Net na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. O painel (a) mostra a relação entre resistências medidas e previstas, com a maioria dos pontos dentro da faixa de desvio de  $\pm 20\%$ , indicando forte concordância. O painel (b) mostra a superfície tridimensional de erro, proporcionando uma visão detalhada da distribuição dos resíduos nas amostras de teste. O modelo apresenta coeficiente de determinação de 0,846 e baixo erro médio de tendência, demonstrando precisão preditiva substancial e desvio sistemático mínimo. Esses resultados apoiam a adequação da abordagem Elastic Net para conjuntos de dados com múltiplas variáveis de entrada correlacionadas.

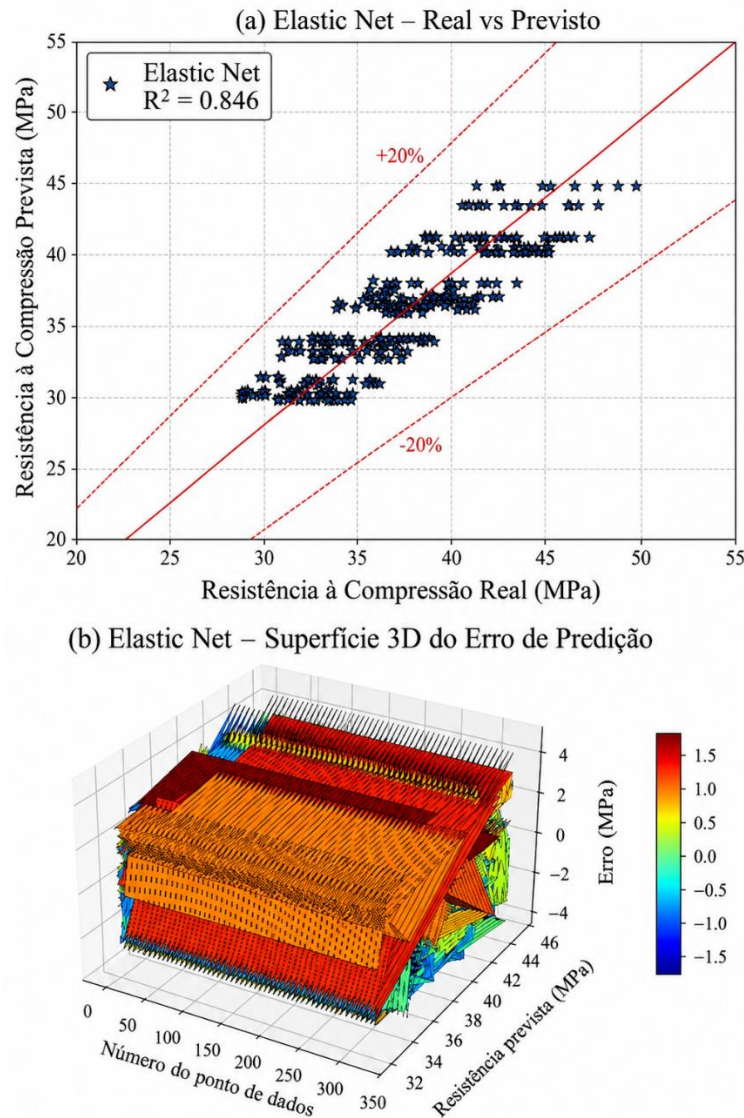


Figura 10. Desempenho do modelo Elastic Net para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

A Regressão por Vetores de Suporte (SVR) emprega uma abordagem baseada em núcleo para capturar relações não lineares entre variáveis de entrada e resistência à compressão do concreto. Com  $R^2$  de 0,998, MAE de 0,008 e RMSE de 0,011, o SVR superou todos os modelos lineares, refletindo com precisão os efeitos da substituição por RCA, da absorção de água e da resistência

do concreto de origem. O ajuste de hiperparâmetros do tipo de núcleo, do parâmetro de penalização (C) e da margem  $\epsilon$  foi crítico para otimizar o desempenho do SVR. (Smola & Scholkopf, 2004) A Figura 11 mostra o desempenho do modelo de regressão por vetores de suporte na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. O painel (a) mostra correspondência próxima entre valores medidos e previstos, com pontos concentrados dentro dos limites de desvio de  $\pm 20\%$ , indicando elevado nível de precisão preditiva. O painel (b) apresenta a superfície tridimensional de erro, que ilustra resíduos uniformes e mínimos no conjunto de dados. O modelo atinge coeficiente de determinação de 0,998 e apresenta erro médio de tendência desprezível, juntamente com erros absoluto médio e raiz do erro quadrático médio muito baixos, confirmando sua capacidade de capturar com confiabilidade a variação da resistência à compressão.

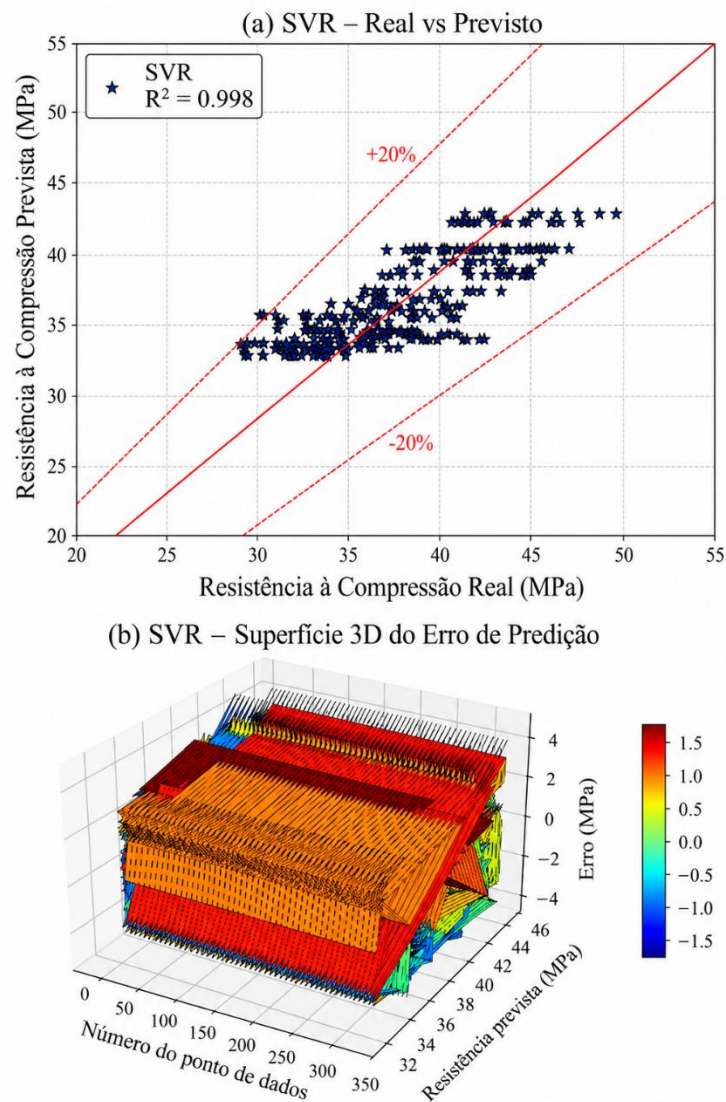


Figura 11. Desempenho do modelo de Regressão por Vetores de Suporte para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

K-Nearest Neighbors (KNN) é uma abordagem não paramétrica que prevê valores-alvo com base na similaridade com observações próximas. O KNN alcançou  $R^2$  de 0,947, demonstrando forte

desempenho, embora ligeiramente inferior ao SVR. O modelo capturou efetivamente padrões locais no conjunto de dados, particularmente variações nos percentuais de RCA e nas relações água/cimento, embora seja sensível a valores atípicos e a espaços de alta dimensionalidade.(Altman, 1992)

A Figura 12 mostra o desempenho do modelo K-Nearest Neighbors na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. O painel (a) mostra a relação entre valores medidos e previstos, com a maioria dos pontos situada dentro dos limites de desvio de  $\pm 20\%$ , indicando concordância confiável. O painel (b) apresenta a superfície tridimensional de erro, fornecendo uma visão geral da distribuição dos resíduos no conjunto de dados e demonstrando o comportamento preditivo robusto do modelo, com desvio mínimo.

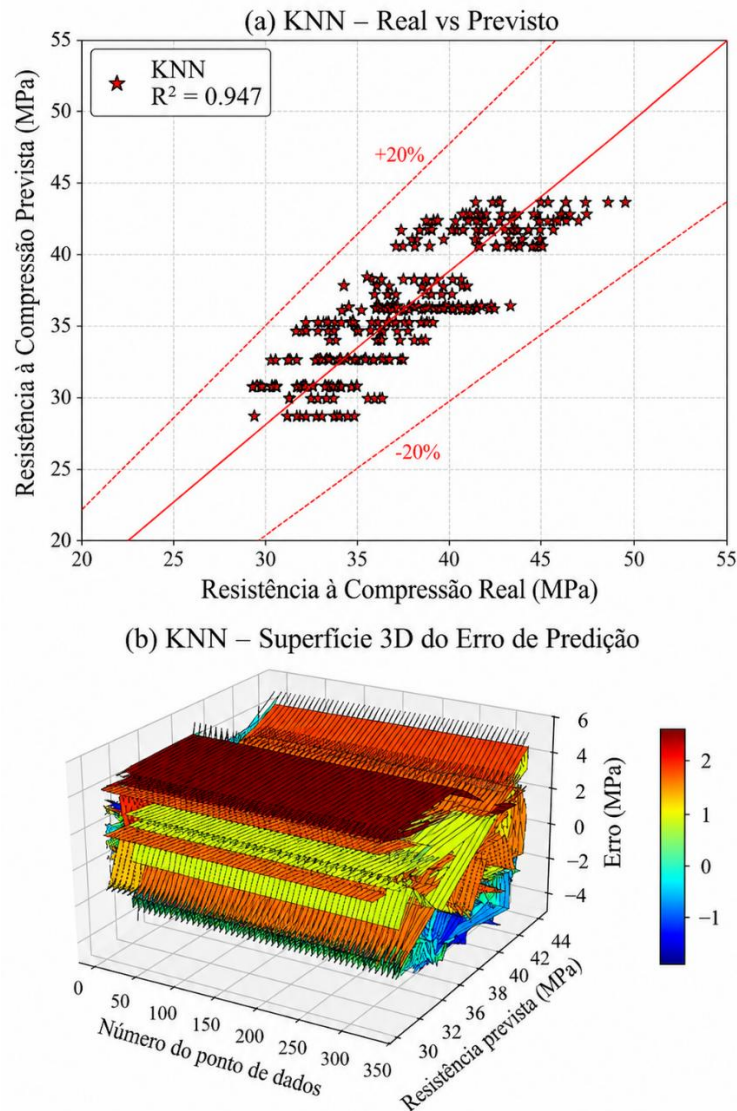


Figura 12. Desempenho do modelo K-Nearest Neighbors para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

Random Forest (RF) é um método ensemble baseado em árvores que calcula a média de várias árvores de decisão para reduzir a variância e melhorar a generalização. O RF alcançou  $R^2$  de 0,996 com baixos MAE e MSE, demonstrando robustez para lidar com multicolinearidade e interações não lineares entre parâmetros de dosagem.(Breiman, 2001)

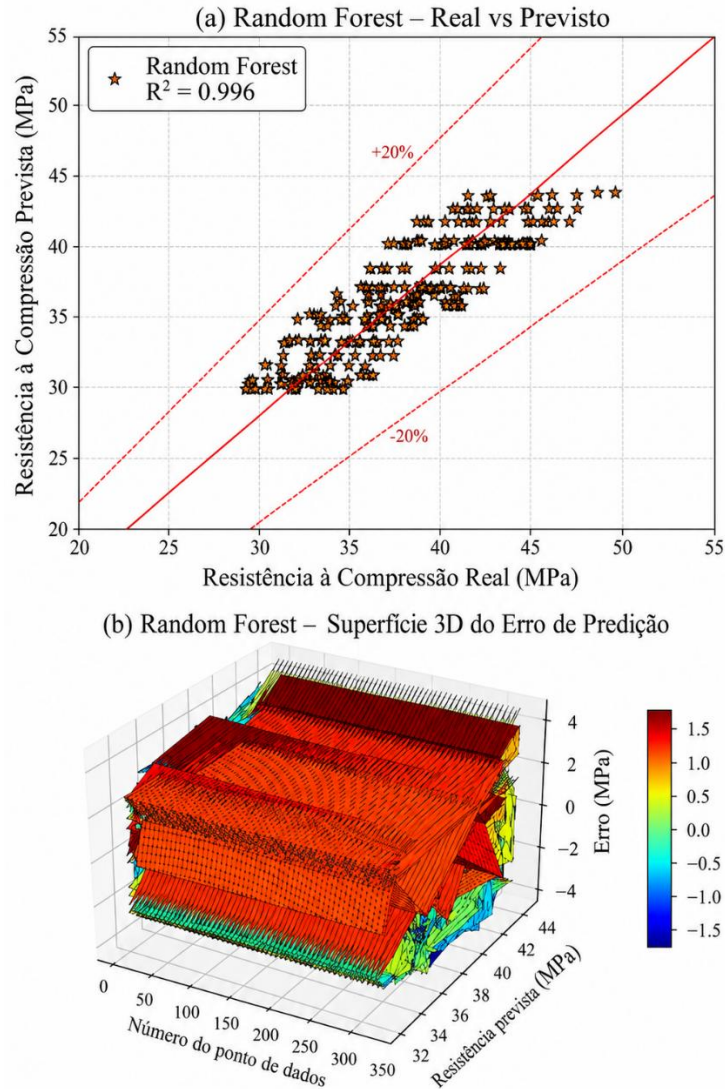


Figura 13. Desempenho do modelo Random Forest para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

A capacidade preditiva do modelo Random Forest para estimar a resistência à compressão aos 28 dias do concreto com agregados reciclados é ilustrada na Figura 13. O painel (a) mostra a comparação entre valores medidos e previstos, com a maioria dos pontos dentro da faixa de desvio de  $\pm 20\%$ , indicando forte precisão preditiva. O painel (b) apresenta a superfície tridimensional de erro, destacando resíduos consistentemente baixos no conjunto de dados. O modelo alcança coeficiente de determinação de 0,996 e baixas métricas de erro, confirmando sua confiabilidade e adequação para previsão robusta da resistência à compressão do concreto.

O Gradient Boosting (GB) constrói sequencialmente árvores sobre os erros residuais das árvores anteriores para minimizar iterativamente o viés. O GB produziu R<sup>2</sup> de 0,904, mostrando boa capacidade preditiva, mas desempenho ligeiramente inferior ao RF devido à sensibilidade aos hiperparâmetros, como taxa de aprendizado, profundidade das árvores e número de estimadores. (Friedman, 2001)

A Figura 14 mostra o bom desempenho do modelo Gradient Boosting na previsão da resistência à

compressão aos 28 dias do concreto com agregados reciclados. O painel (a) apresenta a comparação entre valores medidos e previstos, com a maioria dos pontos posicionada dentro da faixa de desvio de  $\pm 20\%$ , indicando forte concordância. O painel (b) mostra a superfície tridimensional de erro, destacando a magnitude e a distribuição dos resíduos, predominantemente baixos e uniformemente distribuídos no conjunto de teste. Essas observações confirmam a confiabilidade e a acurácia do modelo na previsão da resistência à compressão do concreto.

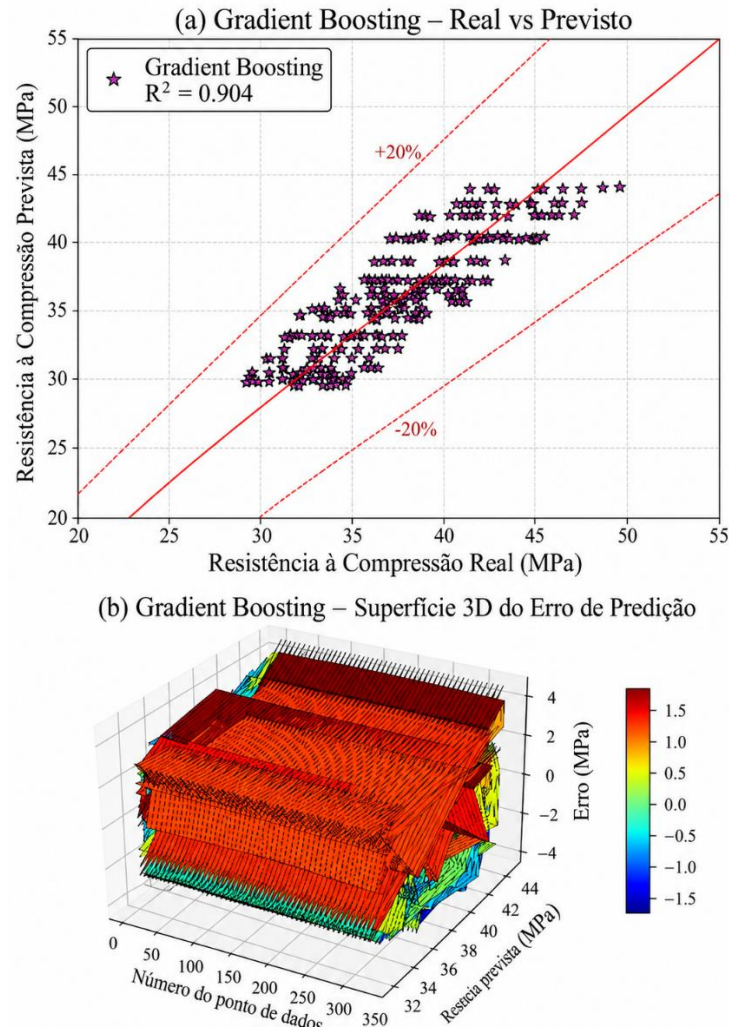


Figura 14. Desempenho do modelo Gradient Boosting para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

O XGBoost, uma implementação altamente eficiente de gradient boosting, obteve  $R^2$  de 0,942, MAE de 0,186 e RMSE de 0,248. O XGBoost lidou de forma eficaz com dependências não lineares e variáveis de entrada de alta dimensionalidade, como absorção de água do RCA, abrasão Los Angeles e teor de cimento, mantendo eficiência computacional. (Chen & Guestrin, 2016)

A Figura 15 mostra o desempenho do modelo XGBoost na estimativa da resistência à compressão aos 28 dias do concreto com agregados reciclados. No painel (a), os valores previstos acompanham de perto as resistências medidas, com a maioria dos pontos dentro de  $\pm 20\%$  da linha ideal, indicando alta precisão preditiva. O painel (b) apresenta a superfície tridimensional de erro, mostrando a distribuição dos resíduos no conjunto de dados e destacando desvios geralmente pequenos. O modelo alcança elevado coeficiente de determinação ( $R^2 = 0,942$ ) e baixas métricas

de erro (MAE = 0,186 MPa, RMSE = 0,248 MPa), confirmando sua confiabilidade e efetividade para previsão da resistência.

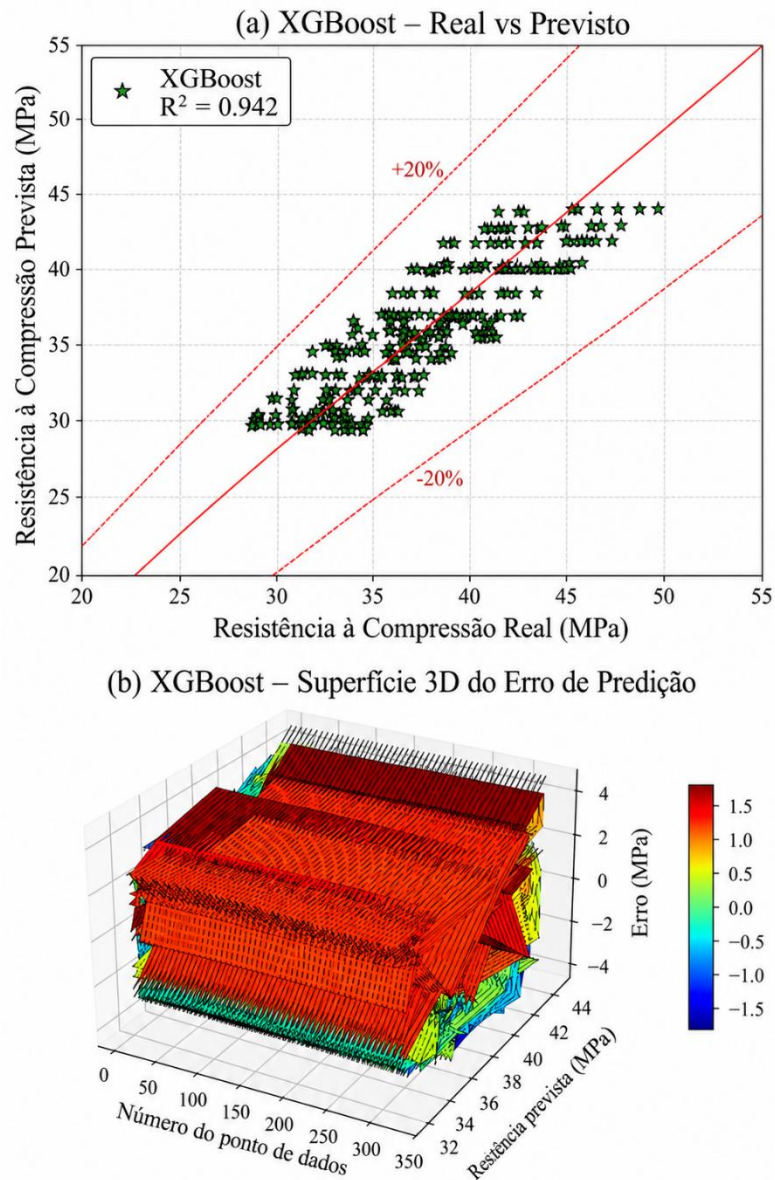


Figura 15. Desempenho do modelo XGBoost para prever a resistência à compressão aos 28 dias do concreto. (a) Diagrama de dispersão entre resistência medida e prevista, (b) superfície 3D mostrando a distribuição dos erros de previsão em todas as observações.

Os resultados mostram que algoritmos não lineares e métodos ensemble fornecem previsões mais precisas da resistência à compressão do CAR em comparação com técnicas lineares. Os elevados valores de R<sup>2</sup> alcançados pelo SVR e pelo Random Forest demonstram sua confiabilidade para uso em aplicações reais, enquanto os modelos lineares permanecem úteis como referências de base ou em situações nas quais a interpretabilidade seja prioritária.




Figura 16. Análise dos limites de erro mostrando a distribuição dos resíduos absolutos para todos os modelos de regressão.

A Figura 16 mostra a avaliação dos limites de erro de cada modelo de regressão com base na dispersão dos valores absolutos dos resíduos. O modelo SVR apresenta a menor dispersão residual, em concordância com seu baixo MAE de 0,008, confirmando sua forte consistência na previsão da resistência à compressão. Random Forest (MAE 0,128), KNN (MAE 0,164) e XGBoost (MAE 0,186) também apresentam distribuições compactas de erro, indicando desempenho estável dentro de limites restritos. Em contraste, Gradient Boosting (MAE 0,189), Regressão Linear (MAE 0,346), Lasso (MAE 0,364), Elastic Net (MAE 0,425) e Ridge (MAE 0,450) mostram faixas de erro mais amplas, sugerindo controle comparativamente mais fraco sobre os desvios de previsão. Modelos com menor MAE exibem faixas de erro mais compactas, enquanto métodos lineares e regularizados geralmente apresentam maior dispersão dos resíduos.

#### 4.2 Diagnóstico de regressão e avaliação dos modelos

Foi realizado um procedimento abrangente de otimização de hiperparâmetros para cada modelo, visando melhorar o desempenho preditivo global. O ajuste de hiperparâmetros envolveu a variação sistemática de parâmetros-chave dos modelos, como tipo de núcleo,  $C$  e  $\epsilon$  para a Regressão por Vetores de Suporte (SVR); número de estimadores, profundidade máxima e número mínimo de amostras por divisão para Random Forest (RF); número de vizinhos para K-Nearest Neighbors (KNN); taxa de aprendizado e profundidade máxima para XGBoost e Gradient Boosting; e parâmetros de regularização para Lasso, Ridge e Elastic Net. Métodos de busca em grade e busca aleatória foram empregados em conjunto com validação cruzada  $k$ -fold ( $k=10$ ) para assegurar seleção robusta de parâmetros e prevenir superajuste. A validação cruzada permitiu que os modelos fossem treinados e validados em múltiplos subconjuntos do conjunto de dados, fornecendo uma estimativa não enviesada do desempenho de generalização. (Farhangi et al., 2021; Naderpour et al., 2018)(Deng et al., 2018; Jahangir & Eidgahee, 2020)(Ghanizadeh et al., 2019)

A acurácia dos modelos foi avaliada por múltiplos indicadores, como coeficiente de determinação ( $R^2$ ), erro absoluto médio (MAE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro percentual absoluto médio (MAPE), erro médio de tendência (MBE) e estatística  $t$ . Entre os modelos individuais, o SVR alcançou a maior precisão preditiva, com  $R^2 = 0,998$ , MAE

mínimo (0,008) e RMSE de 0,011, seguido de perto pelo Random Forest ( $R^2 = 0,996$ ). Modelos não lineares como KNN, XGBoost e Gradient Boosting superaram os modelos lineares (Regressão Linear, Lasso, Ridge, Elastic Net), indicando fortes relações não lineares entre os parâmetros de dosagem e a resistência à compressão. KNN e XGBoost registraram valores de  $R^2$  de 0,947 e 0,942, respectivamente, enquanto o Gradient Boosting atingiu 0,904. A Regressão Linear e os modelos lineares regularizados apresentaram valores de  $R^2$  comparativamente menores, variando de 0,842 a 0,893, destacando suas limitações para capturar interações complexas. (Bilim, Koksall, et al., 2009; Farhangi et al., 2021)(Deng et al., 2018; Naderpour et al., 2018)(Bilim, Ozbakkaloglu, et al., 2009; Jahangir & Eidgahee, 2020)

Para aumentar a acurácia das previsões, foi criado um modelo ensemble por empilhamento, integrando as capacidades dos algoritmos de melhor desempenho. O método ensemble combina diversos modelos de base com um modelo de nível superior, que aprende a partir de suas saídas para melhorar a acurácia preditiva global. O modelo Stacking demonstrou desempenho superior, com valores de  $R^2$  de 0,999 para o conjunto de treinamento e 0,998 para o conjunto de teste, acompanhado por erros desprezíveis ( $MAE \approx 0,0099$ ;  $RMSE \approx 0,0137$ ), conforme Tabela 6. Esses resultados confirmam que o aprendizado ensemble pode explorar de forma efetiva capacidades complementares dos modelos individuais, alcançando previsão quase perfeita da resistência à compressão aos 28 dias no conjunto experimental diverso. Esse método evidencia como modelos modernos de aprendizado de máquina podem fornecer previsões precisas e baseadas em dados do desempenho do concreto com agregados reciclados, ajudando a minimizar a necessidade de grandes volumes de ensaios laboratoriais, sem comprometer a confiabilidade dos resultados. (J. Zhang et al., 2022)(Farhangi et al., 2021; Jahangir & Eidgahee, 2020)(Ghanizadeh et al., 2019; Naderpour et al., 2018)

Tabela 6. Desempenho comparativo dos modelos de regressão para previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados.

Modelo	Valor $R^2$	MAE	MSE	RMSE	MAPE (%)	MBE	T-stat
Regressão por Vetores de Suporte	0.998	0.008	0	0.011	0.022	0	-0.309
Random Forest	0.996	0.128	0.032	0.179	0.346	0.017	1.373
K-Nearest Neighbors	0.947	0.164	0.052	0.227	0.441	0.029	1.913
XGBoost	0.942	0.186	0.061	0.248	0.494	-0.01	-0.282
Gradient Boosting	0.904	0.189	0.063	0.251	0.505	0.006	0.353
Regressão Linear	0.893	0.346	0.209	0.457	0.94	0.009	0.284
Regressão Lasso	0.879	0.364	0.218	0.467	0.987	0.018	0.556
Elastic Net	0.846	0.425	0.291	0.539	1.148	0.024	0.646
Regressão Ridge	0.842	0.45	0.331	0.575	1.209	0.026	0.672

*Nota: os valores representam a média da validação cruzada em cinco partes, calculada sobre três sementes aleatórias. Os hiperparâmetros foram otimizados com validação cruzada em 10 partes, usando busca em grade e busca aleatória para assegurar seleção robusta dos modelos. As métricas de desempenho incluem  $R^2$ , MAE, MSE, RMSE, MAPE, MBE e estatística t pareada, destacando a acurácia superior dos modelos não lineares e ensemble.*

Embora valores muito elevados de  $R^2$  tenham sido obtidos para alguns modelos, esses resultados devem ser interpretados no contexto do conjunto de dados controlado e da forte correlação entre parâmetros de dosagem e resistência à compressão. A validação cruzada e as métricas de erro foram utilizadas para avaliar o desempenho dos modelos; entretanto, o potencial de superajuste devido à expansão do conjunto de dados é reconhecido como uma limitação do estudo.

### 4.3 Interpretabilidade do modelo e importância das variáveis

Para compreender o efeito de cada parâmetro de mistura na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados pelo modelo de Regressão por Vetores de Suporte, foi realizada análise SHapley Additive exPlanations (SHAP). O SHAP fornece interpretação transparente dos resultados de aprendizado de máquina ao atribuir um valor de contribuição a cada variável, com base em sua influência na previsão final. Essa abordagem permite compreender detalhadamente efeitos não lineares e interativos que não são visíveis por meio de análises tradicionais de sensibilidade. (Lundberg & Lee, 2017; Molnar, 2020)

A Figura 17 mostra como cada variável de entrada contribui para a saída do modelo com base na análise SHAP. Os valores médios de SHAP para o modelo SVR são apresentados na Figura 17(a). Entre todas as variáveis, o percentual de RCA teve o maior impacto, com valor médio de SHAP de 0,638, demonstrando que a quantidade de agregado graúdo reciclado desempenhou o papel mais significativo na previsão da resistência à compressão. A absorção de água do RCA (0,584) e o valor de abrasão Los Angeles (0,459) também foram altamente influentes, refletindo o papel crítico da condição superficial dos agregados e da integridade mecânica na determinação do desempenho do concreto. A resistência do concreto de origem (0,351), o teor de aditivo plastificante (0,346) e a relação água/cimento (0,168) vieram em seguida, mostrando influência moderada, porém significativa, no desenvolvimento da resistência.

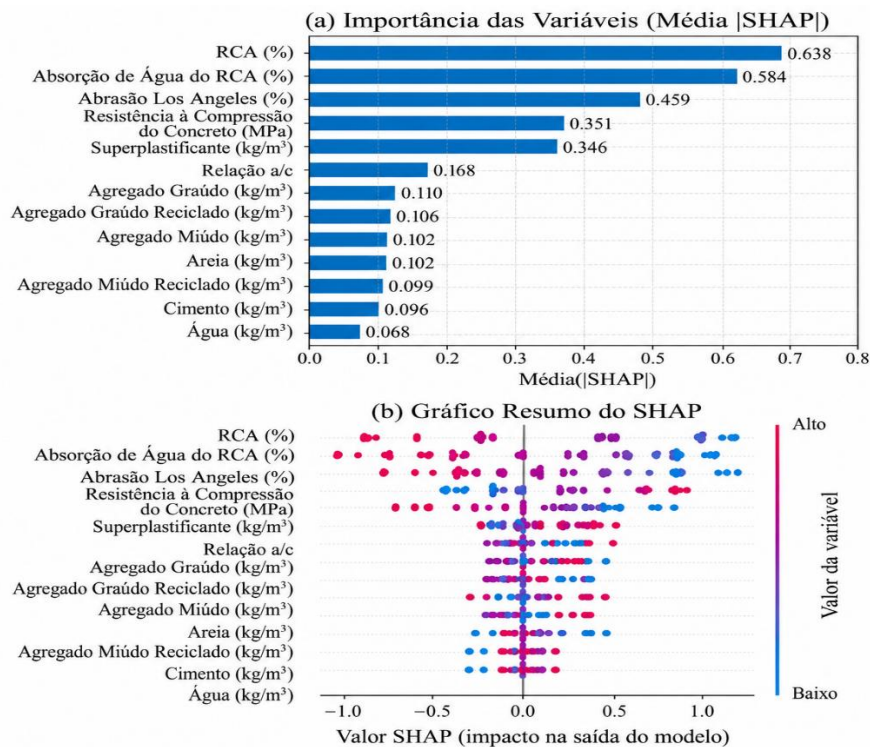


Figura 17. Análise SHAP: (a) valores SHAP absolutos médios indicando a influência relativa das variáveis de entrada nas previsões do modelo SVR para resistência à compressão aos 28 dias; (b) gráfico resumo SHAP mostrando a distribuição, direção e magnitude dos efeitos das variáveis em todas as amostras.

Outros constituintes, como agregado graúdo total (0,110), agregado graúdo reciclado (0,106), agregado miúdo (0,102), areia (0,102) e agregado miúdo reciclado (0,099), apresentaram contribuições menores, mas coerentes com seu papel no controle da trabalhabilidade, da empacotamento interno e da qualidade da zona de transição interfacial. Cimento (0,096) e teor de água (0,068) tiveram os menores valores SHAP, sugerindo variabilidade limitada em suas faixas no conjunto de dados, e não menor importância do ponto de vista de engenharia.

A Figura 17(b) mostra como os valores SHAP se distribuem para cada amostra. A maior dispersão horizontal observada para percentual de RCA, absorção e abrasão indica que essas entradas contribuem mais para a variabilidade da previsão no conjunto de dados. Em contraste, cimento e água exibem dispersões muito mais estreitas, indicando que o modelo é menos sensível a variações nessas variáveis. Gradientes de cor vermelho e azul mostram como valores altos ou baixos das variáveis deslocam as previsões positiva ou negativamente, auxiliando a visualizar a direção e a influência de cada entrada no desempenho do modelo.

Em conjunto, as Figuras 17(a) e 17(b) demonstram que as propriedades dos agregados reciclados governam a previsão da resistência no CAR de forma mais intensa do que as proporções da mistura isoladamente. Esses resultados fornecem orientação orientada por dados para a otimização do CAR, destacando que melhorar a qualidade dos agregados, controlar a absorção e selecionar concretos de origem duráveis pode melhorar significativamente os resultados de resistência previstos pelo modelo.

A elevada importância da absorção de água e dos parâmetros relacionados ao RCA observada na análise SHAP confirma ainda mais que a qualidade dos agregados e as características associadas à porosidade desempenham papel dominante na previsão da resistência.

Essas informações permitem uma abordagem de otimização de dosagem orientada por dados: aumentar a eficiência do ligante e controlar a qualidade do RCA pode maximizar a resistência, enquanto pequenos ajustes no teor de água, areia e aditivo plastificante podem melhorar a trabalhabilidade e a integridade estrutural sem comprometer a resistência à compressão. Assim, os valores SHAP fornecem interpretabilidade e orientação prática para a dosagem de misturas sustentáveis de CAR, reduzindo ensaios experimentais e mantendo alta confiança nas previsões do modelo. (Lundberg & Lee, 2017; Molnar, 2020)

## 5. CONCLUSÃO

Este trabalho investiga a resistência à compressão do concreto com agregados reciclados (CAR) utilizando ensaios laboratoriais e técnicas de aprendizado de máquina. Ao todo, foram preparadas 25 misturas de concreto com diferentes combinações de agregados naturais e reciclados, graúdos e miúdos, relações água/cimento variáveis e diferentes resistências do concreto de origem. Os resultados de resistência à compressão aos 28 dias variaram de 31,8 MPa para misturas contendo apenas agregados reciclados a 45,2 MPa para misturas produzidas integralmente com agregados naturais. Em seguida, modelos baseados em aprendizado de máquina foram desenvolvidos para prever a resistência à compressão a partir dos parâmetros de dosagem. A Regressão por Vetores de Suporte (SVR) apresentou os resultados mais precisos, alcançando  $R^2$  de 0,998 com erros de previsão muito pequenos (MAE = 0,008 MPa; RMSE = 0,011 MPa). Métodos ensemble como Random Forest e KNN também tiveram bom desempenho, enquanto abordagens tradicionais como Regressão Linear, Lasso e Ridge registraram menor acurácia em comparação.

As principais observações do estudo incluem:

- O aumento do teor de agregados reciclados geralmente reduz a resistência à compressão. Misturas com 75-100% de RCA apresentaram os menores valores de resistência, enquanto misturas sem RCA alcançaram os maiores.
- A relação água/cimento, a resistência do concreto de origem e a absorção de água do RCA

estiveram entre os fatores mais influentes na resistência à compressão. Relações a/c mais elevadas, combinadas com altos teores de RCA, causaram reduções significativas de resistência.

- Os modelos baseados em aprendizado de máquina demonstraram forte capacidade de prever a resistência à compressão a partir dos parâmetros de dosagem. Os modelos SVR e RF apresentaram precisão preditiva muito elevada dentro da faixa estudada, sendo altamente adequados para otimização de dosagens.
- Modelos ensemble e outros modelos não lineares apresentaram melhores resultados que a regressão linear tradicional, mostrando que considerar relações complexas entre as variáveis de entrada é importante para prever o comportamento do concreto com agregados reciclados.

Os resultados indicam que a substituição de agregados naturais por agregados reciclados na faixa de 25% a 75% é viável para a produção de concreto quando a mistura é bem dosada. Embora se observe alguma redução de resistência, ela permanece dentro de limites aceitáveis, e o concreto resultante mantém desempenho estrutural. Em contraste, a substituição completa (100%) conduz consistentemente aos menores valores de resistência, principalmente devido à maior absorção de água dos agregados reciclados e à menor qualidade do concreto de origem. A integração de ensaios laboratoriais com aprendizado de máquina aumenta a precisão na previsão do desempenho do concreto e minimiza a necessidade de ensaios físicos repetidos, facilitando a determinação do teor mais adequado de agregados reciclados para aplicações sustentáveis em concreto.

Estudos futuros devem considerar a incorporação de variáveis adicionais de entrada, como variáveis químicas, indicadores de durabilidade, variáveis de cura e comportamento de longo prazo, para fortalecer a confiabilidade e a profundidade preditiva dos modelos. Esses modelos também podem ser expandidos para prever outros parâmetros mecânicos e de durabilidade, auxiliando no desenvolvimento de materiais cimentícios ambientalmente conscientes e de alto desempenho.

## 6. REFERÊNCIAS

- Ajdukiewicz, A., & Kliszczewicz, A. (2002). Influence of recycled aggregates on mechanical properties of high-strength concrete. *Cement and Concrete Composites*, 24(2), 269–279. [https://doi.org/10.1016/S0958-9465\(01\)00012-9](https://doi.org/10.1016/S0958-9465(01)00012-9)
- Akbar, A., & Liew, J. Y. R. (2020a). Environmental impact of cement production and concrete sustainability. *Journal of Cleaner Production*, 258, 120543. <https://doi.org/10.1016/j.jclepro.2020.120543>
- Akbar, A., & Liew, K. M. (2020b). Assessing recycling potential of carbon fiber reinforced plastic waste in eco-efficient cement materials. *Journal of Cleaner Production*, 274, 123001. <https://doi.org/10.1016/j.jclepro.2020.123001>
- Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175–185. <https://doi.org/10.1080/00031305.1992.10475879>
- Bai, X., & others. (2023). Experimental study on mechanical properties and compressive constitutive model of recycled concrete under sulfate attack considering the effects of multiple factors. *Buildings*, 14(9), 2761. <https://doi.org/10.3390/buildings14092761>
- Bhanja, S., & Sengupta, B. (2005). Prediction of compressive strength of concrete using regression analysis. *Cement and Concrete Research*, 35(9), 1848–1855. <https://doi.org/10.1016/j.cemconres.2005.03.003>
- Bilim, C., Atis, C. D., Tanyildizi, H., & Karahan, O. (2009). Predicting compressive strength of GGBS concrete using ANN. *Advances in Engineering Software*, 40(5), 334–340. <https://doi.org/10.1016/j.advengsoft.2008.05.005>

- Bilim, C., Koksall, F., & Tosun, T. (2009). Prediction of concrete strength using ANN. *Expert Systems with Applications*, 36(2), 3736–3742. <https://doi.org/10.1016/j.eswa.2008.03.011>
- Bilim, C., Ozbakkaloglu, T., & Tanyu, B. F. (2009). Artificial neural networks for predicting compressive strength of concrete. *ACI Materials Journal*, 106(3), 203–211.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cakiroglu, M., Pal, S., & Sharma, R. (2023). Environmental challenges of construction waste: A review. *Journal of Environmental Management*, 335, 117142. <https://doi.org/10.1016/j.jenvman.2023.117142>
- Chakradhara Rao, M., Bhattacharyya, S. K., & Barai, S. V. (2011). Influence of field recycled coarse aggregate on properties of concrete. *Materials and Structures*, 44(1), 205–220. <https://doi.org/10.1617/s11527-010-9620-x>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *KDD Proceedings*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chicco, D., & Warrens, M. J. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Dantas, A. T., Leite, M., & Nagahama, K. (2013). ANN-based strength prediction of concrete with waste. *Construction and Building Materials*, 38, 717–722.
- Deng, A., Naderpour, H., & Ghanizadeh, A. (2018). Predicting strength of recycled concrete using ML. *Materials Today: Proceedings*, 5(11), 24091–24099. <https://doi.org/10.1016/j.matpr.2018.10.091>
- Emmert-Streib, F., & Dehmer, M. (2019). Evaluation of regression models: Model assessment, model selection and generalization error. *Machine Learning and Knowledge Extraction*, 1(1), 521–551. <https://doi.org/10.3390/make1010032>
- Farhangi, V., Jahangir, H., & Ghafari, E. (2021). ML-based prediction of recycled aggregate concrete. *Materials Today Communications*, 28, 102633. <https://doi.org/10.1016/j.mtcomm.2021.102633>
- Field, A. (2013). *Discovering statistics using IBM SPSS* (4th ed.). Sage.
- Friedman, J. (2001). Greedy function approximation: Gradient boosting. *Annals of Statistics*, 29(5), 1189–1232.
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63, 3–42.
- Ghanizadeh, A., Naderpour, H., & Deng, Q. (2019). AI-based strength prediction for recycled concrete. *Journal of Cleaner Production*, 215, 376–385.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Hansen, T. C., & Narud, H. (1983). Strength of recycled concrete with crushed aggregates. *Concrete International*, 5(1), 79–83.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *Elements of statistical learning*. Springer.
- Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55–67. <https://doi.org/10.1080/00401706.1970.10488634>
- Huang, B., & Yan, Q. (2025). Evaluating the mechanical properties of recycled aggregate concrete with variable coarse and fine aggregate replacements. *Discover Civil Engineering*. <https://doi.org/10.1007/s44290-025-00336-3>
- International, A. (2024). *ASTM C150/C150M-24: Standard specification for Portland cement*.
- Jahangir, H., & Eidgahee, D. (2020). Hybrid AI modeling for FRP–concrete bond strength. *Composite Structures*, 257, 113160.
- Jahangir, H., Farhangi, H., & Ghodrati, B. (2021). Ensemble prediction of RAC strength. *Construction and Building Materials*, 271, 121654.

- Katz, A. (2003). Concrete made from partially hydrated recycled aggregate. *Cement and Concrete Research*, 33(5), 703–711.
- Khalil, E., & AbouZeid, M. (2025). Framework for cement plants assessment through cement production improvement measures for reduction of CO<sub>2</sub> emissions towards net zero emissions. *Construction Materials*, 5(2), 20. <https://doi.org/10.3390/constrmater5020020>
- Khan, K., & others. (2022). Comparison of machine learning methods for recycled aggregate concrete strength prediction. *Materials*, 15(10), 3430. <https://doi.org/10.3390/ma15103430>
- Khatib, J. M. (2005). Concrete with fine recycled aggregates. *Cement and Concrete Research*, 35(4), 763–769.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Miller, C., & others. (2024). A review of model evaluation metrics for machine learning in regression, classification, and clustering. *PeerJ Computer Science*, 10, eXXXX.
- Molnar, C. (2020). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. Lulu.com.
- Naderpour, H., Ghanizadeh, M., & Behnood, A. (2018). RAC compressive strength prediction via ANN. *Journal of Cleaner Production*, 184, 640–650.
- Padmini, A. K., Ramamurthy, K., & Mathew, M. (2002). Influence of parent concrete on RAC properties. *Cement and Concrete Research*, 32(12), 1893–1901.
- Pal, R., & Singh, S. (2024). Role of impact and compression-based crushing on the physical, chemical, and morphological characteristics of recycled concrete aggregates. *Journal of Materials in Civil Engineering*. <https://doi.org/10.1061/JMCEE7.MTENG-17400>
- Plevis, V., Solórzano, G., Bakas, N. P., & Ben Seghier, M. E. (2022). Investigation of performance metrics in regression analysis and machine learning based prediction models. *Proceedings of the 8th European Congress on Computational Methods in Applied Sciences and Engineering (ECCOMAS 2022)*. <https://doi.org/10.23967/eccomas.2022.155>
- Ryu, G. S. (2002). Strength and durability of recycled aggregate concrete. *Construction and Building Materials*, 16(1), 95–101.
- Shin, Y. S., & Kim, G. H. (2013). Predicting Compressive Strength of Recycled Aggregate Concrete by Multiple Regression Analysis. *Applied Mechanics and Materials*, 253–255, 546–549. <https://doi.org/10.4028/www.scientific.net/AMM.253-255.546>
- Smola, A., & Scholkopf, B. (2004). Tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222.
- Steurer, M., Schulz, W., & Werwatz, A. (2021). Metrics for evaluating the performance of machine learning prediction models. *International Journal of Forecasting*, 36(6), 812–828. <https://doi.org/10.1080/09599916.2020.1858937>
- Tu, C., Belarbi, R., Pigeon, M., & Tam, V. (2006). Properties of concrete with recycled aggregate. *Cement and Concrete Research*, 36(1), 153–159.
- Wolpert, D. (1992). Stacked generalization. *Neural Networks*, 5(2), 241–259.
- Yeh, I.-C. (2007). ML prediction of concrete properties. *Cement and Concrete Research*, 37(5), 676–685.
- Zain, M. F. M., Safiuddin, M., & Mahmud, H. B. (2002). Development of high-performance concrete using silica fume and superplasticizer. *Cement and Concrete Research*, 32(1), 115–122. [https://doi.org/10.1016/S0008-8846\(01\)00643-1](https://doi.org/10.1016/S0008-8846(01)00643-1)
- Zhang, J., Li, X., & Chen, Y. (2022). Stacking ensemble for concrete strength prediction. *Engineering Applications of Artificial Intelligence*, 109, 104617.
- Zhang, P., Sun, X., Wang, F., & Wang, J. (2023). Mechanical properties and durability of geopolymer recycled aggregate concrete: A review. *Polymers*, 15(3), 615. <https://doi.org/10.3390/polym15030615>

- Zhang, X., Sun, X., Wang, F., & Wang, J. (2023). Predicting compressive strength of recycled aggregate concrete using machine learning and hyperparameter optimization techniques. *Frontiers in Earth Science, 11*, 1112105. <https://doi.org/10.3389/feart.2023.1112105>
- Zou, H., & Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B, 67*(2), 301–320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>