

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

N. Kumar Gautam^{1*}, A. Kumar² 

* Autor de Contato: navinphd2026@gmail.com

DOI: <https://doi.org/10.21041/ra.v16i3.1025>

Recebido: 20/02/2026 | Correções recebidas: 22/08/2026 | Aceito: 31/08/2026 | Publicado: 01/09/2026

RESUMO

Este estudo tem como objetivo desenvolver um método para prever a resistência à compressão de 28 dias do concreto misturado com agregado reciclado de concreto (RAC) para aplicações em pavimentos rígidos. Um conjunto de dados híbrido de 385 observações, combinando resultados laboratoriais e dados selecionados da literatura, foi utilizado para desenvolver e comparar modelos de aprendizado de máquina. Os modelos foram avaliados usando validação cruzada de cinco vezes, medidas de erro, análise de viés, avaliação multi-colinear e interpretação SHAP. A Regressão de Laço forneceu o melhor desempenho, com $R^2 = 0,7713$, MAE = 3,51 MPa e RMSE = 4,47 MPa. O estudo é limitado a validação cruzada de cinco vezes sem validação externa independente. Sua originalidade está na avaliação de um conjunto de dados híbrido RAC orientado para pavimento, utilizando análises preditivas e interpretativas. Os resultados mostram que modelos regularizados podem suportar a avaliação preliminar da mistura RAC e avaliação de materiais.

Palavras-chave: concreto com agregado reciclado; pavimento rígido; previsão de resistência à compressão; aprendizado de máquina; regressão de laço; materiais sustentáveis para pavimento.

Citar como: Kumar Gautam, N., Kumar, A. (2026), “Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida..”, Revista ALCONPAT, 16 (3), pp. 493 – 520, DOI: <https://doi.org/10.21041/ra.v16i3.1025>.

¹ Research Scholar, Department of Civil Engineering, Sandip University, Sijoul, Madhubani-847235, Bihar, India.

² Assistant Professor, Department of Civil Engineering, Sandip University, Sijoul, Madhubani-847235, Bihar, India.

Contribuição de cada autor

Neste trabalho, Navin Kumar Gautam contribuiu com conceitualização, investigação experimental, desenvolvimento de conjuntos de dados, modelagem de aprendizado de máquina, análise formal, visualização, preparação e revisão de manuscritos (contribuição de 75%). O Dr. Amrendra Kumar contribuiu para supervisão, revisão metodológica, validação, interpretação de resultados, revisão crítica e edição de manuscritos (contribuição de 25%). Todos os autores leram e aprovaram a versão final do manuscrito e concordam em ser responsáveis por todos os aspectos do trabalho.

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 discussão, incluindo a resposta dos autores, será publicada no segundo número do ano 2027, desde que a informação seja recebida antes do fechamento do primeiro número do ano de 2027.

Machine learning approaches for estimating the strength performance of recycled aggregate concrete in rigid pavement systems.

ABSTRACT

This study aims to develop a method for predicting the 28-day compressive strength of recycled aggregate concrete (RAC) for rigid pavement applications. A hybrid dataset of 385 observations, combining laboratory results and selected literature data, was used to develop and compare machine learning models. The models were assessed using five-fold cross-validation, error measures, bias analysis, multicollinearity assessment, and SHAP interpretation. Lasso Regression provided the best performance, with $R^2 = 0.7713$, MAE = 3.51 MPa, and RMSE = 4.47 MPa. The study is limited to five-fold cross-validation without independent external validation. Its originality lies in evaluating a pavement-oriented hybrid RAC dataset using predictive and interpretive analyses. The results show that regularized models can support preliminary RAC mix evaluation and material assessment.

Keywords: recycled aggregate concrete; rigid pavement; compressive strength prediction; machine learning; lasso regression; sustainable pavement materials.

Enfoques de aprendizaje automático para estimar el rendimiento de resistencia del hormigón agregado reciclado en sistemas de pavimento rígido.

RESUMEN

Este estudio tiene como objetivo desarrollar un método para predecir la resistencia a la compresión de 28 días del hormigón agregado reciclado (RAC) para aplicaciones de pavimento rígido. Se utilizó un conjunto de datos híbrido de 385 observaciones, combinando resultados de laboratorio y datos de literatura seleccionada, para desarrollar y comparar modelos de aprendizaje automático. Los modelos se evaluaron mediante validación cruzada de cinco vías, medidas de error, análisis de sesgos, evaluación multicolineal e interpretación SHAP. La regresión de lazo proporcionó el mejor rendimiento, con $R^2 = 0,7713$, MAE = 3,51 MPa y RMSE = 4,47 MPa. El estudio está limitado a una validación cruzada de cinco vías sin validación externa independiente. Su originalidad radica en evaluar un conjunto de datos híbrido de RAC orientado al pavimento mediante análisis predictivos e interpretativos. Los resultados muestran que los modelos regularizados pueden soportar la evaluación preliminar de la mezcla RAC y la evaluación de materiales.

Palabras clave: hormigón agregado reciclado; pavimento rígido; predicción de resistencia a la compresión; aprendizaje automático; regresión de lazo; materiales sostenibles para pavimentos.

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, Website: 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.

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

1. INTRODUÇÃO

Os pavimentos rígidos são amplamente utilizados em infraestruturas rodoviárias e aeroportuárias devido à sua elevada capacidade de suporte de cargas, rigidez estrutural e longa vida útil sob a ação de carregamentos repetidos do tráfego. O desempenho estrutural e a durabilidade dos pavimentos rígidos são amplamente determinados pelas propriedades mecânicas das placas de concreto, entre as quais a resistência à compressão constitui um parâmetro fundamental utilizado no dimensionamento da espessura do pavimento, na avaliação da fadiga e no controle da qualidade da construção (American Association of State Highway & Officials, 1993; Brandes et al., 2018; Huang, 2004). Portanto, a estimativa confiável da resistência à compressão é essencial para garantir a segurança, a capacidade de serviço e a relação custo-benefício dos sistemas de pavimentos rígidos.

Nos últimos anos, a crescente ênfase no desenvolvimento de infraestruturas sustentáveis e o esgotamento dos recursos de agregados naturais têm incentivado o uso de concreto com agregados reciclados de concreto (RAC) na construção de pavimentos. Os agregados reciclados obtidos a partir de resíduos de construção e demolição oferecem benefícios ambientais significativos ao reduzir a disposição de resíduos em aterros e preservar os recursos naturais (Behera et al., 2014; Silva et al., 2014; Tam et al., 2018). Diversos estudos têm relatado que o RAC pode ser utilizado de forma eficaz em aplicações de pavimentos rígidos, como camadas de base, acostamentos e até mesmo placas estruturais de concreto, desde que sejam adotados procedimentos adequados de dosagem e medidas de controle de qualidade (Ismail et al., 2022; Xiao et al., 2018).

Apesar dessas vantagens, o desempenho mecânico do RAC é geralmente mais variável do que o do concreto convencional. Os agregados reciclados frequentemente apresentam argamassa antiga aderida, microfissuras internas e maior porosidade, características que aumentam a heterogeneidade do material e resultam em maior dispersão dos resultados de resistência à compressão (Etxeberria et al., 2007; Limbachiya et al., 2000; Thomas et al., 2013). A resistência à compressão do RAC é influenciada por uma interação complexa de fatores, incluindo a taxa de substituição dos agregados, a relação água/cimento, a qualidade dos agregados e as condições de cura (Butler et al., 2016; Pedro et al., 2017). Esses efeitos não lineares e interdependentes limitam a aplicabilidade dos modelos tradicionais de previsão empíricos ou baseados em regressão, especialmente quando os dados são provenientes de múltiplas fontes (Asteris et al., 2020).

Os ensaios laboratoriais convencionais continuam sendo a abordagem mais confiável para a determinação da resistência à compressão; entretanto, programas experimentais extensos demandam tempo, mão de obra e custos elevados. Esse desafio é particularmente evidente em projetos de pavimentos rígidos, nos quais diversas dosagens de concreto podem precisar ser avaliadas em prazos limitados durante as etapas de seleção dos materiais e de projeto preliminar (Chou et al., 2014; Neville, 2011). Consequentemente, há um interesse crescente em métodos preditivos complementares capazes de reduzir o esforço experimental, mantendo níveis aceitáveis de precisão.

As técnicas de aprendizado de máquina (*Machine Learning* – ML) surgiram como ferramentas eficazes para a modelagem do comportamento complexo dos materiais, devido à sua capacidade de representar relações não lineares e interações entre múltiplas variáveis de entrada sem a necessidade de formas funcionais previamente definidas. Na engenharia do concreto, métodos de ML têm sido aplicados com sucesso na previsão da resistência à compressão, do módulo de elasticidade e de propriedades relacionadas à durabilidade, utilizando algoritmos como redes neurais artificiais, máquinas de vetores de suporte e técnicas de aprendizado por conjuntos (*ensemble learning*) (Asteris et al., 2019; Chou & Pham, 2013; Duan et al., 2021; Yeh, 1998). Estudos recentes indicam que os modelos de ML podem apresentar desempenho superior às abordagens estatísticas convencionais quando aplicados a materiais heterogêneos, como o RAC (Nguyen et al., 2021; Zhang et al., 2020).

Embora o aprendizado de máquina tenha sido cada vez mais aplicado à previsão das propriedades do RAC, sua eficácia depende fortemente da qualidade, diversidade e consistência dos dados utilizados no desenvolvimento dos modelos. Muitas pesquisas existentes baseiam-se em conjuntos de dados obtidos a partir de um único programa experimental ou de fontes bibliográficas com escopo restrito. Esses conjuntos de dados são úteis para estabelecer relações entre os parâmetros das misturas e a resistência do concreto, mas podem não representar adequadamente a variabilidade associada às diferentes fontes de agregados reciclados, às características do concreto de origem, às proporções das misturas e às condições de cura encontradas em aplicações práticas. Essa questão é particularmente relevante para o concreto destinado a pavimentos rígidos, nos quais as variações das propriedades dos materiais podem influenciar o dimensionamento baseado na resistência e a avaliação da qualidade.

O presente estudo aborda essa limitação por meio do desenvolvimento de um conjunto de dados híbrido, que combina observações experimentais controladas com dados provenientes da literatura, sistematicamente selecionados, relativos ao concreto com agregados reciclados. O objetivo dessa integração não é simplesmente aumentar o número de observações, mas ampliar a variedade de condições dos materiais e das misturas representadas no conjunto de dados utilizado para a modelagem, mantendo, simultaneamente, informações fundamentadas experimentalmente. O conjunto de dados resultante incorpora variações no teor de cimento, relação água/cimento, composição dos agregados, características dos agregados reciclados, resistência do concreto de origem, dosagem de aditivos, trabalhabilidade e condições de cura. Isso proporciona uma base mais abrangente para avaliar a previsão da resistência à compressão do concreto com agregados reciclados utilizado em aplicações de pavimentos rígidos.

A principal contribuição deste estudo reside no desenvolvimento e na avaliação sistemática de um conjunto de dados híbrido experimental–bibliográfico, direcionado a aplicações em pavimentos, para a previsão da resistência do RAC, e não na utilização de um algoritmo específico de aprendizado de máquina. Métodos consolidados de regressão, métodos baseados em *kernel* e métodos de aprendizado por conjuntos são comparados sob uma estrutura comum de validação, sendo seu desempenho posteriormente examinado por meio de métricas de erro, análise de viés, avaliação de multicolinearidade e interpretação da importância das variáveis. O objetivo é determinar qual abordagem de modelagem fornece previsões estáveis e de utilidade prática para o conjunto de dados heterogêneo de RAC considerado neste estudo. Os resultados visam subsidiar a avaliação preliminar dos materiais, a análise das dosagens e as decisões de controle de qualidade em aplicações sustentáveis de pavimentos rígidos, reconhecendo-se, entretanto, que a verificação laboratorial continua sendo necessária para as decisões finais de engenharia.

2 OBJETIVOS DA PESQUISA

O principal objetivo deste estudo é desenvolver uma metodologia confiável e prática para a previsão da resistência à compressão do concreto com agregados reciclados (RAC) destinado a aplicações em pavimentos rígidos, por meio da integração entre investigação experimental e técnicas de aprendizado de máquina.

Para alcançar esse objetivo geral, os objetivos específicos do estudo são os seguintes:

1. Avaliar experimentalmente a resistência à compressão aos 28 dias do concreto com agregados reciclados, produzido com proporções de mistura relevantes para a execução de pavimentos rígidos.
2. Desenvolver um conjunto de dados híbrido, combinando dados gerados experimentalmente com dados de resistência à compressão cuidadosamente selecionados a partir da literatura revisada, assegurando uma representação mais ampla da variabilidade dos materiais.
3. Aplicar e comparar diferentes modelos de aprendizado de máquina, incluindo modelos lineares regularizados, métodos de aprendizado por conjuntos (*ensemble learning*) e abordagens baseadas em *kernel*, para a previsão da resistência à compressão do RAC.

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

- 4 Avaliar o desempenho preditivo dos modelos desenvolvidos utilizando múltiplos indicadores estatísticos, incluindo métricas baseadas em erro, análise de viés e testes de hipóteses, a fim de assegurar a robustez e a confiabilidade dos resultados.
- 5 Identificar abordagens adequadas de aprendizado de máquina que possam auxiliar no projeto em nível de materiais, na avaliação da qualidade e na tomada de decisões para o uso sustentável do concreto com agregados reciclados na engenharia de pavimentos rígidos.

3. PROGRAMA EXPERIMENTAL

3.1 Materiais

O programa experimental foi desenvolvido para investigar o comportamento da resistência à compressão do concreto com agregados reciclados (RAC) destinado a aplicações em pavimentos rígidos. Foi utilizado cimento Portland comum, em conformidade com os requisitos normativos, como aglomerante principal. Agregados naturais e agregados de concreto reciclado (RCA) foram empregados como constituintes do agregado graúdo, enquanto areia natural de rio foi utilizada como agregado miúdo. A utilização de RCA representa cenários práticos de construção de pavimentos nos quais materiais reciclados são incorporados com o objetivo de aumentar a sustentabilidade (Silva et al., 2014; Tam et al., 2018).

Os agregados de concreto reciclado foram obtidos a partir da britagem de concretos de origem com diferentes níveis de resistência, representando condições práticas de resíduos provenientes de demolição. A resistência do concreto de origem foi considerada um parâmetro importante devido à sua influência sobre a qualidade e o desempenho mecânico do RCA (Katz, 2003; Pedro et al., 2017; Xiao et al., 2018). A dimensão nominal máxima do RCA variou entre 10 mm e 20 mm, o que é compatível com as granulometrias dos agregados comumente adotadas em concretos para pavimentos rígidos (Huang, 2004). A capacidade de absorção de água do RCA, variando aproximadamente entre 3,5% e 8,5%, foi registrada para considerar a maior porosidade e a maior demanda de água associadas aos agregados reciclados (Butler et al., 2016; Etxeberria et al., 2007). Foi utilizado um superplastificante à base de policarboxilato para proporcionar a trabalhabilidade desejada nas diferentes composições das misturas. Em algumas misturas, foi incorporada uma pequena proporção de fibras ou adições minerais, com o objetivo de representar variações comumente relatadas em estudos de concretos destinados a pavimentos (Li et al., 2022).

A Tabela 1 apresenta o conjunto completo de dados experimentais desenvolvido neste estudo para o concreto com agregados reciclados. A tabela sintetiza as proporções das misturas, as propriedades dos agregados de concreto reciclado, as condições de cura e os respectivos resultados de resistência à compressão aos 28 dias. O teor de cimento e a relação água/cimento foram variados em uma ampla faixa, a fim de abranger diferenças no consumo de aglomerante e na trabalhabilidade das misturas. A substituição dos agregados graúdos naturais por agregados de concreto reciclado foi considerada sistematicamente, variando de 0 a 100%, permitindo avaliar a influência da incorporação de agregados reciclados sobre o desempenho em termos de resistência.

Tabela 1. Resumo do conjunto de dados experimentais, incluindo a composição das misturas, as propriedades dos agregados de concreto reciclado, o regime de cura e os resultados de resistência à compressão aos 28 dias.

Parâmetro	Faixa / Níveis
Consumo de cimento (kg/m ³)	350 - 420
Relação água/cimento (a/c)	0.40, 0.45, 0.50, 0.55
Substituição do agregado natural (NA) (%)	100, 75, 50, 25, 0
Teor de agregado graúdo reciclado (RCA) (%)	0, 25, 50, 75, 100
Agregado miúdo (kg/m ³)	650 - 780
Resistência do concreto de origem (MPa)	25 - 45

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

Absorção de água do RCA (%)	3.5 - 8.5
Dimensão máxima do RCA (mm)	10, 12.5, 20
Dosagem de superplastificante (%)	0.40 - 1.20
Abatimento (mm)	60 - 140
Método de cura	Água, Úmida, Ambiente
Temperatura de cura (°C)	26 - 34
Adição de fibras/mineral (%)	0 - 1.50
Resistência à compressão aos 28 dias (MPa)	11.29 - 35.26

Tabela 2. Classificação das misturas experimentais de concreto de acordo com o nível de substituição por agregado de concreto reciclado (RCA).

Grupo	Faixa de identificação das misturas	Agregado natural (%)	Nível de substituição por RCA (%)
Grupo I	M1–M16	100	0
Grupo II	M17–M32	75	25
Grupo III	M33–M48	50	50
Grupo IV	M49–M64	25	75
Grupo V	M65–M80	0	100

Nota: RCA = agregado de concreto reciclado; NA = agregado graúdo natural. Cada grupo inclui múltiplas misturas preparadas com diferentes relações água/cimento, teores de cimento, regimes de cura e dosagens de aditivos, a fim de representar um amplo domínio experimental.

A Tabela 2 apresenta a classificação das misturas experimentais de concreto com base no percentual de substituição do agregado graúdo natural por agregado de concreto reciclado (RCA). As misturas foram organizadas em cinco grupos, abrangendo desde o concreto convencional, sem agregado reciclado, até o concreto com substituição total por agregado reciclado. Essa forma de agrupamento permite uma comparação sistemática da influência do teor de RCA sobre as propriedades do concreto nos estados fresco e endurecido, mantendo a consistência dos demais parâmetros de dosagem.




Figura 1. Resistência à compressão aos 28 dias: valores reais versus valores calculados, obtidos utilizando os parâmetros de entrada combinados do conjunto de dados experimental de concreto com agregados reciclados.




Figura 2. Mapa de calor de correlação mostrando as relações lineares entre os parâmetros de entrada selecionados e a resistência à compressão aos 28 dias do concreto com agregados reciclados.




Figura 3. Gráfico de coordenadas paralelas mostrando a distribuição normalizada dos parâmetros experimentais de entrada das misturas de concreto com agregados reciclados para diferentes níveis de substituição por agregado graúdo reciclado (RCA).

As Figuras 1–3 apresentam perspectivas complementares do conjunto de dados experimentais e de suas principais relações com a resistência à compressão aos 28 dias. A Figura 1 mostra a concordância entre os valores de resistência medidos e estimados, com os dados distribuídos próximos à linha de referência e dentro dos limites de desvio de $\pm 10\%$, indicando uma forte relação global ($R^2 = 0,95$). A Figura 2 apresenta a correlação entre as variáveis de entrada selecionadas e a resistência à compressão, enquanto a Figura 3 ilustra a distribuição multidimensional das misturas experimentais para diferentes níveis de substituição por RCA. Em conjunto, essas figuras demonstram a variabilidade do conjunto de dados experimentais e a influência combinada da composição das misturas e das características dos agregados reciclados sobre o desenvolvimento da resistência.

O valor de $R^2 = 0,95$, apresentado na Figura 1, deve ser interpretado como uma relação descritiva dentro do conjunto de dados experimentais, e não como uma medida da precisão preditiva de um modelo individual de aprendizado de máquina. Os modelos de aprendizado de máquina foram avaliados separadamente por meio de validação cruzada em cinco partições (*five-fold cross-validation*), e os respectivos resultados de validação são apresentados na Seção 5. Portanto, as métricas de desempenho obtidas por validação cruzada, apresentadas posteriormente no manuscrito, constituem a base apropriada para a comparação da capacidade preditiva dos modelos desenvolvidos.

3.2 Proporções das misturas e variáveis experimentais

Foi preparada uma ampla variedade de misturas de concreto, variando-se sistematicamente os principais parâmetros de dosagem relevantes para o desempenho de pavimentos rígidos. O teor de cimento variou aproximadamente entre 350 e 420 kg/m³, enquanto a relação água/cimento variou entre 0,40 e 0,55. Essas faixas são típicas de concretos para pavimentação projetados para proporcionar um equilíbrio entre resistência, durabilidade e trabalhabilidade (American Association of State Highway & Officials, 1993; Neville, 2011).

A taxa de substituição do agregado graúdo natural por agregado de concreto reciclado variou de 0% a 100%, correspondendo a teores de agregado natural de 100%, 75%, 50%, 25% e 0%. Essa ampla faixa permitiu avaliar toda a transição entre o concreto convencional e o concreto produzido integralmente com agregado graúdo reciclado, aspecto fundamental para avaliar a viabilidade do RAC em aplicações de pavimentos rígidos (Fanijo, 2023; Xiao et al., 2018).

O teor de agregado miúdo foi ajustado para manter uma granulometria adequada e uma trabalhabilidade satisfatória em todas as misturas. Os valores de abatimento (*slump*) variaram, de modo geral, entre aproximadamente 60 mm e 140 mm, garantindo misturas com trabalhabilidade adequada às operações de lançamento e adensamento do concreto para pavimentação (Huang, 2004). A dosagem de superplastificante foi ajustada de acordo com cada composição, a fim de compensar o aumento da demanda de água associado aos maiores teores de RCA.

3.3 Preparação dos corpos de prova e condições de cura

A mistura do concreto foi realizada seguindo procedimentos laboratoriais padronizados, a fim de garantir uniformidade e repetibilidade. Atenção especial foi dada ao condicionamento da umidade do RCA antes da mistura, com o objetivo de minimizar a absorção não controlada de água durante a dosagem, conforme recomendado em estudos anteriores sobre concreto com agregados reciclados (Etxeberria et al., 2007; Pedro et al., 2017).

O concreto fresco foi moldado em formas cúbicas ou cilíndricas padronizadas para a realização dos ensaios de resistência à compressão. Após a moldagem, os corpos de prova foram adequadamente adensados para eliminar o ar aprisionado e assegurar a correta compactação do concreto. Foram adotados diferentes regimes de cura, incluindo cura em água, cura úmida e cura em condições ambientes, a fim de representar a variedade de condições de cura comumente encontradas na prática de execução de pavimentos (Neville, 2011; Tam et al., 2005). As temperaturas de cura variaram aproximadamente entre 26 °C e 34 °C, em conformidade com condições de campo típicas de projetos de pavimentação.

3.4 Ensaio de resistência à compressão

Os ensaios de resistência à compressão foram realizados aos 28 dias, idade de referência padrão utilizada no dimensionamento e no controle de qualidade de concretos destinados a pavimentos. Os ensaios foram realizados de acordo com as normas estabelecidas, sendo registrada a resistência média à compressão para cada mistura (American Association of State Highway & Officials, 1993; Neville, 2011).

Os valores de resistência à compressão aos 28 dias, determinados experimentalmente, apresentaram uma ampla variação em razão das diferenças no teor de cimento, na relação

água/cimento, no nível de substituição por RCA, na resistência do concreto de origem e nas condições de cura. Essa variabilidade reflete o comportamento realista do concreto com agregados reciclados (RAC) utilizado em aplicações de pavimentos rígidos e fornece uma base robusta para a posterior modelagem orientada por dados (Li et al., 2022; Pedro et al., 2017).

4. PREPARAÇÃO DO CONJUNTO DE DADOS E METODOLOGIA DE APRENDIZADO DE MÁQUINA

4.1 Formação do conjunto de dados híbrido para modelagem orientada a pavimentos

O conjunto de dados utilizado no aprendizado de máquina foi desenvolvido por meio de uma abordagem híbrida, que integra dados gerados experimentalmente com dados coletados da literatura científica revisada por pares. Os resultados experimentais obtidos no presente estudo constituem o núcleo do conjunto de dados e fornecem uma base de referência confiável, uma vez que foram produzidos sob condições laboratoriais controladas, com proporções de mistura relevantes para concretos destinados a pavimentos rígidos. Para ampliar a representatividade do conjunto de dados e contemplar a variabilidade encontrada na execução prática de pavimentos, os dados experimentais foram complementados com dados da literatura cuidadosamente selecionados.

Foram considerados apenas estudos que apresentavam informações completas sobre a composição das misturas, características dos agregados reciclados, trabalhabilidade, condições de cura e resistência à compressão aos 28 dias. Foram priorizadas investigações experimentais realizadas em contextos indianos e internacionais, uma vez que refletem fontes de materiais, ambientes de cura e práticas construtivas semelhantes às encontradas em projetos de pavimentos rígidos (Ojha et al., 2024; Patil, 2025; Tank et al., 2014). Estudos fundamentais que abordam a influência da resistência do concreto de origem, da qualidade do agregado reciclado e da taxa de substituição foram incluídos para garantir uma cobertura adequada dos diferentes níveis de desempenho (Limbachiya et al., 2000; Padmini et al., 2009).

Dados adicionais foram obtidos a partir de estudos que examinaram métodos de tratamento de agregados reciclados, características de absorção de água e comportamento da zona de transição interfacial, fatores reconhecidamente capazes de afetar de forma significativa o desenvolvimento da resistência do concreto com agregados reciclados (Chauhan & Singh, 2023; Ismail et al., 2022; Tam et al., 2005). Estudos experimentais e de revisão recentes também foram considerados para fundamentar a inclusão de adições minerais e do teor de fibras como variáveis secundárias que influenciam o desempenho do concreto para pavimentação (Jagadesh et al., 2024).

O conjunto de dados híbrido final foi composto por 385 amostras e representa uma ampla variedade de composições de mistura, níveis de substituição de agregados reciclados (0–100%), regimes de cura e resultados de resistência. Essa estrutura do conjunto de dados é particularmente adequada à modelagem de materiais destinados a pavimentos rígidos, nos quais a variabilidade das propriedades dos materiais deve ser explicitamente considerada durante o projeto e a avaliação da qualidade.

4.2 Seleção das variáveis de entrada e relevância para pavimentos

As variáveis de entrada selecionadas para a modelagem por aprendizado de máquina foram definidas com base em sua relação direta com o desenvolvimento da resistência à compressão e com o desempenho de pavimentos rígidos. Essas variáveis incluem teor de cimento, relação água/cimento, teor de agregado natural, taxa de substituição por agregado reciclado, teor de agregado miúdo, resistência do concreto de origem, absorção de água do agregado reciclado, dimensão máxima do agregado, dosagem de superplastificante, abatimento, método de cura, temperatura de cura e presença de fibras ou adições minerais.

Diversas dessas variáveis são particularmente importantes em aplicações de pavimentação. A resistência do concreto de origem e a absorção de água do agregado reciclado exercem forte influência sobre a qualidade do agregado reciclado e sobre a variabilidade da resistência, afetando diretamente a rigidez da placa e sua capacidade de suporte de cargas (Ismail et al., 2022; Padmini et al., 2009). Parâmetros relacionados à trabalhabilidade, como o abatimento e a dosagem de aditivos, afetam indiretamente a qualidade da compactação e a estrutura dos vazios de ar, aspectos fundamentais para a durabilidade e o desempenho de longo prazo dos pavimentos (Brandes et al., 2018). O método e a temperatura de cura foram incluídos para representar as condições de cura em campo comumente observadas na execução de pavimentos, especialmente em climas quentes (Chakradhara Rao et al., 2007; Patil, 2025).

A variável-alvo adotada para todos os modelos foi a resistência à compressão aos 28 dias, que permanece como o principal parâmetro mecânico utilizado no dimensionamento da espessura de pavimentos rígidos, na avaliação da fadiga e no controle de qualidade.

Tabela 3. Faixa estatística das variáveis de entrada utilizadas para o desenvolvimento do modelo.

Parâmetro de entrada	Min	Max	Média	Desvio-padrão	Variância
Cimento (kg/m ³)	300.2	469.1	386.28	44.31	1963.56
Relação água/cimento (a/c)	0.35	0.65	0.49	0.08	0.0063
Teor de agregado natural (%)	0	100	52.12	28.45	809.61
Agregado de concreto reciclado (RCA) (%)	0	100	47.88	28.37	804.95
Agregado miúdo (kg/m ³)	550	819.6	696.9	66.59	4434.75
Resistência do concreto de origem (MPa)	18.3	54.7	36.15	9.37	87.72
Absorção de água do RCA (%)	1.24	11.99	6.64	2.79	7.76
Dimensão máxima do RCA (mm)	10	20	15.29	4.02	16.13
Superplastificante (%)	0	1.79	0.9	0.47	0.22
Abatimento (mm)	35	169	98.91	34.44	1186.36
Temperatura de cura (°C)	20	39.9	29.91	5.13	26.31
Fibra / adição mineral (%)	0	2	0.49	0.55	0.31
Indicador da fonte dos dados	0	1	0.21	0.41	0.17

Nota: a/c = relação água/cimento; NA = agregado grão natural; RCA = agregado de concreto reciclado. Os valores de mínimo, máximo, média, desvio-padrão e variância apresentados foram calculados a partir do conjunto de dados híbrido combinado, composto tanto por dados gerados experimentalmente quanto por valores coletados da literatura publicada. O indicador da fonte dos dados distingue os registros experimentais daqueles provenientes da literatura. Todos os parâmetros apresentados na tabela foram considerados como variáveis de entrada durante o desenvolvimento do modelo.

As características estatísticas das variáveis de entrada utilizadas para o desenvolvimento do modelo estão resumidas na Tabela 3. A tabela apresenta a faixa de variação e a distribuição dos principais parâmetros de dosagem das misturas, das propriedades dos agregados reciclados e das variáveis relacionadas à cura, extraídos do conjunto de dados combinado, composto por dados experimentais e dados provenientes da literatura. A ampla variação observada no teor de cimento, na relação água/cimento, na composição dos agregados e nas características dos agregados reciclados assegura uma cobertura adequada das dosagens de concreto utilizadas na prática. Esses descritores estatísticos fornecem informações sobre a diversidade do conjunto de dados e contribuem para a robustez das etapas subsequentes de modelagem e análise.

4.3 Engenharia de atributos para o comportamento específico de pavimentos

Para melhorar a interpretabilidade física e a capacidade preditiva dos modelos, foram introduzidos atributos derivados adicionais para representar o comportamento dos materiais relevante para pavimentos. Uma relação água/cimento efetiva foi calculada incorporando a influência da absorção de água do agregado reciclado, refletindo a demanda adicional de água associada aos

agregados reciclados porosos. Esse ajuste é particularmente importante para concretos destinados a pavimentos, nos quais a variabilidade da umidade pode influenciar significativamente o desenvolvimento da resistência nas primeiras idades (Ismail et al., 2022; Tam et al., 2005). Foi introduzido um parâmetro de intensidade de aglomerante para representar o efeito combinado do teor de cimento e da relação água/cimento sobre o desenvolvimento da resistência, em consonância com os conceitos de dosagem de concretos para pavimentos baseada na resistência. Além disso, foi formulado um índice de severidade do agregado reciclado, combinando a taxa de substituição por agregado reciclado e sua absorção de água, com o objetivo de representar o efeito conjunto da quantidade e da qualidade dos agregados reciclados sobre a resistência à compressão. Indicadores combinados semelhantes têm sido recomendados em estudos anteriores sobre concretos com agregados reciclados, a fim de representar de maneira mais adequada a heterogeneidade do material (Ojha et al., 2024; Padmini et al., 2009).

4.4 Pré-processamento dos dados

Antes do desenvolvimento dos modelos, o conjunto de dados híbrido foi submetido a um pré-processamento para garantir consistência e estabilidade numérica. Os valores ausentes foram tratados por meio de imputação pela mediana, com o objetivo de preservar a integridade do conjunto de dados e, ao mesmo tempo, minimizar as distorções causadas por valores discrepantes (*outliers*). As variáveis contínuas foram padronizadas para eliminar os efeitos decorrentes das diferenças de escala, procedimento essencial para modelos lineares regularizados e algoritmos baseados em *kernel*.

As variáveis categóricas, como o método de cura, foram codificadas numericamente para permitir sua inclusão nos modelos de aprendizado de máquina. A estratégia de pré-processamento foi desenvolvida de modo a equilibrar a normalização dos dados com a preservação de seu significado físico, aspecto particularmente importante em aplicações de engenharia, nas quais a interpretabilidade dos resultados é fundamental (Jagadesh et al., 2024).

4.5 Modelos de aprendizado de máquina e estratégia de validação

A previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados foi formulada como um problema de regressão supervisionada, cujo objetivo é estabelecer uma relação funcional entre múltiplos parâmetros de dosagem da mistura e uma variável de saída contínua. Considerando a natureza heterogênea do concreto com agregados reciclados e sua relevância para o dimensionamento de pavimentos rígidos, foi empregado um conjunto diversificado de modelos de aprendizado de máquina, representando diferentes abordagens de modelagem.

A Figura 4 ilustra o fluxo de trabalho de aprendizado de máquina adotado neste estudo para prever a resistência à compressão aos 28 dias do concreto com agregados reciclados utilizado em aplicações de pavimentos rígidos. Dados experimentais e dados provenientes da literatura foram combinados para formar um conjunto de dados híbrido, que foi submetido ao pré-processamento e à engenharia de atributos relevantes para pavimentos antes do desenvolvimento dos modelos. Diferentes modelos de regressão, *ensemble* e baseados em *kernel* foram treinados e avaliados por meio de validação cruzada de cinco dobras, seguida da avaliação estatística de desempenho, viés e multicolinearidade. O fluxo de trabalho é concluído com a interpretação dos modelos e a seleção do modelo de previsão mais confiável para aplicação em engenharia.

Os algoritmos de aprendizado de máquina considerados neste estudo foram selecionados com base em sua aplicabilidade consolidada na modelagem de materiais de engenharia civil e em sua capacidade de fornecer previsões confiáveis utilizando conjuntos de dados de tamanho moderado.




Figura 4: Fluxo de trabalho de aprendizado de máquina adotado para a previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados para aplicações em pavimentos rígidos.

Os modelos selecionados representam três categorias principais de técnicas de aprendizado supervisionado: modelos de regressão regularizada, métodos de aprendizado baseados em kernel e abordagens de aprendizado por ensemble. Modelos de redes neurais artificiais não foram incluídos na presente investigação, uma vez que o objetivo principal foi comparar técnicas interpretáveis de aprendizado de máquina capazes de fornecer tanto precisão preditiva quanto informações relevantes para a interpretação do comportamento dos materiais sob a perspectiva da engenharia. Essa abordagem também favorece a transparência dos modelos e sua implementação prática em aplicações envolvendo concreto com agregados reciclados, nas quais a compreensão da influência das variáveis individuais é frequentemente tão importante quanto o próprio desempenho preditivo. Foi adotada a validação cruzada de cinco dobras (*five-fold cross-validation*) com o objetivo de proporcionar uma avaliação robusta do desempenho dos modelos e, simultaneamente, maximizar o aproveitamento do conjunto de dados híbrido disponível. Essa estratégia de validação reduz a influência de uma única divisão entre dados de treinamento e teste e permite avaliar o desempenho em múltiplos subconjuntos de dados. Embora uma validação externa utilizando um conjunto de dados independente pudesse fornecer evidências adicionais sobre a capacidade de generalização dos modelos, conjuntos de dados com variáveis consistentes e especificamente orientadas ao concreto com agregados reciclados para pavimentação não estavam prontamente disponíveis. Dessa forma, a validação cruzada foi considerada a estratégia de validação mais adequada para a presente investigação.

4.5.1 Treinamento dos modelos e otimização de hiperparâmetros

Antes do desenvolvimento dos modelos, o conjunto de dados híbrido foi submetido a etapas de pré-processamento e verificação da qualidade, a fim de assegurar a consistência entre os registros experimentais e aqueles provenientes da literatura. Posteriormente, os modelos de aprendizado de máquina foram treinados e avaliados utilizando um procedimento de validação cruzada de cinco dobras (*five-fold cross-validation*), no qual o conjunto de dados foi dividido em cinco

subconjuntos, sendo cada subconjunto utilizado uma vez como conjunto de validação, enquanto os demais foram empregados no treinamento do modelo. As métricas finais de desempenho apresentadas neste estudo correspondem ao desempenho médio obtido em todas as dobras de validação.

Para aumentar a confiabilidade e o desempenho preditivo dos modelos, foi realizada a otimização dos hiperparâmetros de todos os algoritmos de aprendizado de máquina antes da avaliação final. Para as regressões Ridge e Lasso, a intensidade da regularização foi ajustada de modo a obter um equilíbrio adequado entre a complexidade do modelo e a precisão das previsões. Para a Regressão por Vetores de Suporte (SVR), foram otimizados os parâmetros relacionados ao *kernel* de função de base radial (RBF), com o objetivo de melhorar a capacidade de previsão de relações não lineares. Os modelos de aprendizado por *ensemble*, incluindo Random Forest, Gradient Boosting e XGBoost, foram ajustados por meio da otimização da complexidade dos modelos e dos parâmetros associados ao aprendizado das árvores, visando melhorar sua capacidade de generalização.

A configuração final de cada modelo foi selecionada com base no desempenho obtido durante a validação cruzada, garantindo uma comparação equitativa entre os diferentes algoritmos. Esse procedimento reduziu a probabilidade de sobreajuste (*overfitting*) e possibilitou uma avaliação mais robusta da adequação das diferentes abordagens de aprendizado de máquina para a previsão da resistência à compressão do concreto com agregados reciclados destinado a aplicações em pavimentos rígidos

4.5.2 Modelos de regressão linear e regularizada

A Regressão Linear foi adotada como modelo de referência (*baseline*) para avaliar a relação linear entre as variáveis de entrada e a resistência à compressão. A forma geral do modelo de regressão linear é expressa como:

$$y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ij} + \varepsilon_i \quad (1)$$

em que y_i representa a resistência à compressão prevista, x_{ij} corresponde às variáveis de entrada, β_i representa os coeficientes de regressão e ε representa o erro aleatório. Embora a regressão linear ofereça transparência e interpretabilidade, seu desempenho pode ser reduzido na presença de multicolinearidade e de interações não lineares, características comuns em conjuntos de dados de concreto com agregados reciclados.

Para contornar essas limitações, foram empregadas a Regressão Ridge e a Regressão Lasso. A Regressão Ridge introduz um termo de regularização L2, que penaliza coeficientes de elevada magnitude e reduz a sensibilidade do modelo à multicolinearidade:

$$\min(\sum (y_i - y_i^0)^2 + \lambda \sum \beta_j^2) \quad (2)$$

A Regressão Lasso aplica a regularização L1, que pode reduzir alguns coeficientes a zero, realizando, assim, de forma efetiva, a seleção de variáveis:

$$\min(\sum (y_i - y_i^0)^2 + \lambda \sum |\beta_j|) \quad (3)$$

Os modelos de regressão regularizada são particularmente adequados para conjuntos de dados híbridos que combinam dados experimentais e dados provenientes da literatura, uma vez que proporcionam maior estabilidade e capacidade de generalização na presença de variáveis de entrada correlacionadas e de variabilidade nas medições (Asteris et al., 2021; Kumar et al., 2024). Em aplicações de pavimentos rígidos, nas quais são desejáveis previsões conservadoras e confiáveis das propriedades dos materiais, essa estabilidade é essencial.

4.5.3 Regressão por Vetores de Suporte

A Regressão por Vetores de Suporte (SVR) foi empregada para representar as relações não lineares entre os parâmetros de dosagem da mistura e a resistência à compressão. A SVR constrói uma função de regressão minimizando o erro de previsão dentro de uma faixa de tolerância ε -insensível, ao mesmo tempo em que controla a complexidade do modelo:

$$\min \left(\frac{1}{2} \|w\|^2 + C \sum (\xi_i + \xi_i^*) \right) \quad (4)$$

A Regressão por Vetores de Suporte (SVR) é eficaz na modelagem do comportamento não linear dos materiais e tem sido amplamente utilizada em estudos de previsão da resistência do concreto. No entanto, seu desempenho é sensível à seleção do *kernel* e à escolha dos parâmetros, podendo apresentar limitações quando a variabilidade do conjunto de dados é elevada, como ocorre frequentemente em conjuntos de dados híbridos de concretos destinados à pavimentação (Jagadesh et al., 2024; Nguyen et al., 2021). Foi adotado um kernel de função de base radial (RBF) devido à sua ampla utilização na previsão da resistência do concreto.

4.5.4 Modelos de aprendizado por *ensemble*

Os modelos de aprendizado por *ensemble* foram empregados para representar interações não lineares complexas entre os parâmetros de dosagem das misturas. O Random Forest é um método *ensemble* baseado em *bagging*, que constrói múltiplas árvores de decisão utilizando amostras *bootstrap* e calcula a média de suas previsões:

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T f_t(x) \quad (5)$$

em que $f_t(x)$ representa a previsão da t -ésima árvore de decisão. Os modelos Random Forest são robustos a ruídos e capazes de lidar com dados de alta dimensionalidade, tornando-os adequados para a previsão da resistência do concreto.

O Gradient Boosting e o Extreme Gradient Boosting (XGBoost) são métodos de aprendizado por *ensemble* baseados em *boosting*, que constroem modelos sequencialmente com o objetivo de minimizar o erro de previsão. Esses métodos são particularmente eficazes na representação de dependências não lineares e dos efeitos de interação entre as variáveis:

$$y_i^0 = \sum_{k=1}^K f_k(x_i) \quad (6)$$

Os métodos de aprendizado por *ensemble* têm demonstrado elevado desempenho preditivo em estudos de engenharia do concreto; entretanto, também estão sujeitos ao sobreajuste (*overfitting*) quando o tamanho do conjunto de dados é limitado ou quando sua variabilidade é elevada (Ojha et al., 2024; Zhang et al., 2020). A inclusão desses métodos neste estudo permite uma comparação abrangente entre abordagens de modelagem simples e complexas para a previsão das propriedades dos materiais empregados em pavimentos rígidos

4.5.5 Estratégia de validação

Para assegurar uma avaliação robusta da capacidade de generalização dos modelos, foi adotada uma estratégia de validação cruzada de cinco dobras (*five-fold cross-validation*). O conjunto de dados foi dividido aleatoriamente em cinco subconjuntos de igual tamanho; em cada iteração, quatro subconjuntos foram utilizados para o treinamento e um subconjunto para a validação. Esse processo foi repetido até que cada subconjunto fosse utilizado uma vez como conjunto de validação, sendo os resultados das previsões posteriormente agregados.

A validação cruzada é particularmente importante para conjuntos de dados híbridos, nos quais os dados são provenientes de diferentes fontes experimentais e estudos da literatura. Essa abordagem minimiza o viés associado a uma única divisão entre os conjuntos de treinamento e teste (*train-test split*) e fornece uma estimativa confiável do desempenho dos modelos diante de dados não

utilizados durante o treinamento, aspecto fundamental para previsões das propriedades dos materiais empregadas no dimensionamento de pavimentos rígidos (Kumar et al., 2024; Patil, 2025).

4.6 Critérios de avaliação de desempenho

O desempenho preditivo dos modelos de aprendizado de máquina foi avaliado utilizando múltiplos indicadores estatísticos, com o objetivo de analisar tanto a precisão quanto a confiabilidade das previsões. Esses indicadores fornecem perspectivas complementares sobre o comportamento dos modelos e são particularmente relevantes para a tomada de decisões de engenharia no dimensionamento de pavimentos rígidos.

O coeficiente de determinação (R^2) foi utilizado para avaliar a qualidade do ajuste entre os valores previstos e observados da resistência à compressão:

$$R^2 = 1 - \frac{\sum(y_i - y_i^0)^2}{\sum(y_i - \bar{y})^2} \quad (7)$$

O Erro Quadrático Médio (MSE) e a Raiz do Erro Quadrático Médio (RMSE) quantificam a dispersão dos erros de previsão e penalizam desvios de maior magnitude:

$$MSE = \frac{1}{N} \sum (y_i - y_i^0)^2 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum (y_i - y_i^0)^2} \quad (9)$$

O Erro Absoluto Médio (MAE) mede a magnitude média dos erros de previsão, sem atribuir maior peso aos valores extremos:

$$MAE = \frac{1}{N} \sum |y_i - y_i^0| \quad (10)$$

O Erro Percentual Absoluto Médio (MAPE) fornece uma medida relativa da precisão das previsões, expressa em porcentagem, facilitando a comparação entre diferentes faixas de resistência:

$$MAPE = \frac{1}{N} \sum \left| \frac{y_i - y_i^0}{y_i} \right| \times 100 \quad (11)$$

Para avaliar o viés sistemático das previsões, foi calculado o Erro Médio de Viés (MBE):

$$MBE = \frac{1}{N} \sum (y_i - y_i^0) \quad (12)$$

Um valor positivo de MBE indica superestimação, enquanto um valor negativo indica subestimação. A avaliação do viés é particularmente importante em aplicações de pavimentos rígidos, nas quais a superestimação ou subestimação sistemática da resistência à compressão pode afetar diretamente o dimensionamento da espessura das placas e as margens de segurança (Brandes et al., 2018; Patil, 2025).

Por fim, foram calculadas estatísticas t para amostras pareadas a fim de avaliar a significância estatística das diferenças entre os valores previstos e observados:

$$t = \frac{\sqrt{(N-1) \cdot MBE^2}}{\sqrt{RMSE^2 - MBE^2}} \quad (13)$$

Os valores de p correspondentes foram utilizados para avaliar se os erros de previsão eram estatisticamente significativos. A inclusão de métricas de teste de hipóteses assegura que os modelos selecionados sejam não apenas precisos, mas também estatisticamente consistentes e adequados para aplicações de engenharia envolvendo pavimentos rígidos.

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

5 RESULTADOS E DISCUSSÃO

5.1 Comparação geral do desempenho dos modelos

O desempenho preditivo dos modelos de aprendizado de máquina desenvolvidos foi avaliado por meio de múltiplos indicadores estatísticos, incluindo métricas relacionadas à precisão e ao viés, com o objetivo de assegurar sua adequação à avaliação de materiais destinados a pavimentos rígidos. A Tabela 4 resume o desempenho de todos os modelos considerados neste estudo.

A Figura 5 resume o desempenho preditivo de seis modelos de aprendizado de máquina desenvolvidos para estimar a resistência à compressão aos 28 dias do concreto com agregados reciclados. Os gráficos de valores reais versus previstos mostram o nível de concordância entre os valores experimentais e aqueles estimados pelos modelos, enquanto as distribuições dos resíduos fornecem informações sobre a dispersão e a consistência dos erros de previsão. O desempenho preditivo apresentado nesta seção não deve ser comparado diretamente com a análise de correlação apresentada na Figura 1. Enquanto a Figura 1 ilustra a associação geral entre a resistência à compressão e o conjunto de parâmetros de entrada no conjunto de dados experimentais, os resultados dos modelos de aprendizado de máquina são derivados de validação cruzada e, portanto, representam o desempenho dos modelos sob condições de validação independente. A diferença entre esses valores reflete a distinção entre correlação descritiva e capacidade de generalização preditiva, aspecto comumente observado em aplicações de aprendizado de máquina envolvendo conjuntos de dados heterogêneos de engenharia. Os indicadores de desempenho apresentados correspondem às versões otimizadas de cada modelo de aprendizado de máquina, obtidas por meio do procedimento de ajuste de hiperparâmetros e validação cruzada descrito na Seção 4.5.1, proporcionando, assim, uma base consistente para a avaliação comparativa dos modelos.

Entre os modelos avaliados, a Regressão Lasso apresentou a maior precisão preditiva, alcançando um valor de R^2 de 0,7713, juntamente com os menores valores de MAE (3,51 MPa), RMSE (4,47 MPa) e MAPE (16,44%). A Regressão Ridge apresentou desempenho muito próximo, com valor de R^2 de 0,7695 e níveis de erro semelhantes. Em contraste, modelos de aprendizado por *ensemble*, como Gradient Boosting, XGBoost e Random Forest, apresentaram valores de R^2 comparativamente menores e erros de previsão mais elevados, enquanto a Regressão por Vetores de Suporte (SVR) apresentou o desempenho mais fraco entre todos os modelos avaliados. Esses resultados indicam que modelos de regressão regularizada mais simples apresentam desempenho superior ao de modelos não lineares mais complexos quando aplicados ao conjunto de dados híbrido utilizado no presente estudo (Zhuang et al., 2021). Esse resultado é consistente com achados recentes que indicam que conjuntos de dados híbridos, combinando dados experimentais e provenientes da literatura, frequentemente apresentam elevada variabilidade e multicolinearidade, condições nas quais modelos lineares regularizados tendem a fornecer previsões mais estáveis e confiáveis (Asteris et al., 2021; Kumar et al., 2024).

O desempenho superior da Regressão Lasso pode ser atribuído às características do conjunto de dados híbrido utilizado neste estudo. O conjunto de dados combina observações experimentais e dados provenientes da literatura e, portanto, apresenta variabilidade considerável, variáveis preditoras correlacionadas e possíveis inconsistências de medição. Nessas condições, a Regressão Lasso se beneficia da regularização L1, que reduz a influência de variáveis redundantes e diminui a complexidade do modelo, melhorando, consequentemente, sua capacidade de generalização. A Regressão Ridge também apresentou bom desempenho, pois seu mecanismo de regularização estabiliza a estimativa dos coeficientes na presença de multicolinearidade. Entretanto, diferentemente da Regressão Lasso, ela não elimina as variáveis preditoras menos informativas, o que pode explicar seu desempenho ligeiramente inferior.




Figura 5. Comparação do desempenho de seis modelos de aprendizado de máquina na previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados. Para cada modelo, são apresentados os valores reais versus previstos da resistência à compressão e a correspondente distribuição dos resíduos.

Em contraste, os modelos de aprendizado por *ensemble*, como Random Forest, Gradient Boosting e XGBoost, são desenvolvidos para representar interações não lineares complexas. Embora esses métodos frequentemente apresentem desempenho excepcional em conjuntos de dados extensos e altamente estruturados, sua vantagem pode diminuir quando os dados disponíveis apresentam variabilidade substancial e tamanho amostral moderado. Nessas condições, os modelos podem aprender parcialmente padrões específicos do conjunto de dados que não se generalizam de maneira consistente entre as diferentes dobras de validação. De forma semelhante, a Regressão por Vetores de Suporte (SVR) apresentou menor capacidade preditiva, o que pode ser atribuído à dificuldade de representar o comportamento heterogêneo do concreto com agregados reciclados por meio de uma única função de decisão baseada em *kernel*. Essas observações indicam que as relações predominantes que governam a resistência à compressão no conjunto de dados analisado são suficientemente representadas por abordagens de modelagem linear regularizada.

Tabela 4. Comparação do desempenho dos modelos de aprendizado de máquina e de regressão na previsão da resistência à compressão aos 28 dias.

Modelo	R^2	MAE	MSE	RMSE	MAPE	MBE	Estatística t	Valor de p
Regressão Lasso	0.7713	3.51	20.01	4.47	16.44	-0.03	0.139	0.89

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

Regressão Ridge	0.7695	3.52	20.16	4.49	16.47	-0.04	0.163	0.871
Gradient Boosting	0.7175	3.93	24.71	4.97	18.31	0.2	-0.774	0.439
XGBoost	0.7169	3.97	24.77	4.98	18.56	0.27	-1.048	0.295
Aleatória (Random Forest)	0.6899	4.16	27.13	5.21	19.78	0.2	-0.751	0.453
Regressão por Vetores de Suporte (SVR)	0.6395	4.37	31.54	5.62	20.91	0.06	-0.200	0.842

Nota: R^2 = coeficiente de determinação; MAE = erro absoluto médio (MPa); MSE = erro quadrático médio (MPa²); RMSE = raiz do erro quadrático médio (MPa); MAPE = erro percentual absoluto médio (%); MBE = erro médio de viés (MPa). A estatística t e o valor de p correspondente foram utilizados para avaliar a significância estatística do viés de previsão dos modelos. Todos os indicadores de desempenho foram avaliados utilizando uma estratégia idêntica de particionamento dos dados e validação, a fim de assegurar uma comparação equitativa entre os modelos.

5.2 Interpretação sob a perspectiva de pavimentos rígidos

No dimensionamento de pavimentos rígidos, a resistência à compressão é um parâmetro de entrada crítico, que influencia a espessura das placas, a eficiência da transferência de cargas e o desempenho à fadiga. Sob a perspectiva da engenharia, a confiabilidade das previsões e o controle do viés são tão importantes quanto a obtenção de elevada precisão numérica. O desempenho superior dos modelos de Regressão Lasso e Ridge sugere que a relação entre a resistência à compressão e os parâmetros de dosagem do concreto com agregados reciclados destinado a pavimentos é predominantemente governada por tendências lineares, apesar da presença de algumas interações não lineares.

O concreto com agregados reciclados utilizado em pavimentos apresenta, em geral, maior heterogeneidade do material, em razão das variações na resistência do concreto de origem, na absorção de água dos agregados reciclados e nas condições de cura. Nesses casos, modelos *ensemble* mais complexos podem apresentar sobreajuste (*overfitting*) a padrões localizados presentes nos dados de treinamento, particularmente quando o conjunto de dados incorpora informações provenientes de múltiplas fontes experimentais (Ojha et al., 2024; Patil, 2025). Os modelos de regressão regularizada atenuam esse problema ao restringir a magnitude dos coeficientes, melhorando, assim, sua capacidade de generalização sob condições variáveis.

O desempenho relativamente inferior do Random Forest e dos modelos baseados em *boosting*, observado neste estudo, está de acordo com resultados semelhantes relatados para concretos com agregados reciclados, nos quais os modelos *ensemble* não apresentaram desempenho consistentemente superior ao de abordagens mais simples quando a variabilidade dos dados era elevada e o tamanho da amostra moderado (Jagadesh et al., 2024; Zhang et al., 2020).

5.3 Métricas de erro e significado para a engenharia

Sob a perspectiva da engenharia de pavimentos, medidas de erro absoluto, como o MAE e o RMSE, são particularmente importantes, pois refletem o desvio esperado entre os valores previstos e reais da resistência à compressão. Os valores de MAE obtidos para os modelos de Regressão Lasso e Ridge (aproximadamente 3,5 MPa) encontram-se dentro de uma faixa aceitável para aplicações preliminares de dimensionamento de materiais para pavimentação e controle de qualidade.

Os valores de MAPE dos modelos com melhor desempenho permaneceram abaixo de 17%, indicando uma consistência razoável das previsões em uma ampla faixa de resistência. Esse nível de precisão é comparável ou superior ao relatado em estudos anteriores que utilizaram aprendizado de máquina para a previsão da resistência do concreto com agregados reciclados (Jagadesh et al., 2024; Nguyen et al., 2021). A Regressão por Vetores de Suporte (SVR) apresentou os maiores valores de MAE, RMSE e MAPE, sugerindo robustez limitada para conjuntos de dados híbridos de concretos destinados à pavimentação.

Os valores mais elevados de RMSE observados nos modelos *ensemble* e naqueles baseados em *kernel* indicam maior sensibilidade a erros extremos de previsão. No dimensionamento de pavimentos rígidos, essa variabilidade pode resultar em estimativas inseguras ou excessivamente conservadoras da espessura das placas, particularmente quando as previsões de resistência à compressão são utilizadas diretamente em métodos de dimensionamento mecânico-empíricos (Brandes et al., 2018).

5.4 Análise de viés e consistência estatística

A avaliação do viés desempenha um papel fundamental na análise da adequação de modelos preditivos para aplicações de engenharia. Os valores do Erro Médio de Viés (MBE) para os modelos de Regressão Lasso e Ridge foram próximos de zero ($-0,0317$ MPa e $-0,0373$ MPa, respectivamente), indicando uma superestimação ou subestimação sistemática desprezível. Além disso, as estatísticas *t* associadas apresentaram valores baixos, e os valores de *p* foram significativamente superiores a 0,05, indicando que as diferenças entre os valores previstos e observados não são estatisticamente significativas.

Em contraste, modelos *ensemble*, como Gradient Boosting, XGBoost e Random Forest, apresentaram valores positivos de MBE mais elevados, indicando uma tendência à superestimação da resistência à compressão. Embora esses vieses não tenham sido estatisticamente significativos para um nível de confiança de 95%, sua magnitude é indesejável sob a perspectiva do dimensionamento de pavimentos, uma vez que a superestimação sistemática pode resultar em dimensionamentos estruturais inseguros e redução da vida útil (Patil, 2025).

A Regressão por Vetores de Suporte (SVR) apresentou viés relativamente pequeno; entretanto, sua maior dispersão dos erros, indicada pelos valores de RMSE e MAPE, reduz sua aplicabilidade prática na previsão das propriedades dos materiais destinados a pavimentos rígidos. Esses resultados reforçam a importância de combinar métricas relacionadas ao viés com medidas convencionais de precisão na avaliação de modelos de aprendizado de máquina para aplicações em engenharia de pavimentos (Brandes et al., 2018).

5.5 Comparação com estudos anteriores

Os resultados obtidos neste estudo são consistentes com a literatura recente, que indica que modelos de regressão regularizada frequentemente apresentam desempenho competitivo ou superior ao de algoritmos complexos de aprendizado de máquina na previsão da resistência do concreto utilizando conjuntos de dados heterogêneos (Asteris et al., 2021; Kumar et al., 2024). Estudos voltados ao concreto com agregados reciclados também têm destacado os desafios associados à modelagem da variabilidade da resistência decorrente da qualidade dos agregados reciclados e das características do concreto de origem (Ojha et al., 2024; Padmini et al., 2009).

Embora os modelos *ensemble* tenham demonstrado elevado desempenho em algumas aplicações envolvendo concreto, sua eficácia parece depender do contexto e ser influenciada pelo tamanho do conjunto de dados, sua variabilidade e a consistência das fontes de dados (Zhang et al., 2020). Para aplicações em pavimentos rígidos, nas quais a estabilidade das previsões e o controle do viés são aspectos críticos, os resultados do presente estudo sugerem que modelos mais simples e adequadamente regularizados podem representar uma alternativa mais confiável. O desempenho preditivo alcançado no presente estudo deve ser interpretado no contexto de uma avaliação baseada em validação cruzada. Embora a validação cruzada seja amplamente aceita para a avaliação de modelos de aprendizado de máquina em aplicações de engenharia, a validação externa utilizando conjuntos de dados completamente independentes continua sendo uma etapa importante para confirmar a capacidade de transferência dos modelos diante de diferentes fontes de materiais, práticas construtivas e condições ambientais. Consequentemente, as métricas de desempenho apresentadas devem ser consideradas indicadores da capacidade de generalização interna dos modelos, e não de sua capacidade preditiva universal.

Diferenças semelhantes entre análises baseadas em correlação e o desempenho preditivo obtido por validação cruzada têm sido relatadas em estudos anteriores de aprendizado de máquina envolvendo concreto com agregados reciclados e outros materiais de construção. As análises de correlação são úteis para identificar tendências predominantes e relações entre as variáveis, enquanto a validação cruzada fornece uma estimativa mais conservadora e realista do desempenho dos modelos quando aplicados a novos conjuntos de dados. Portanto, os resultados preditivos apresentados neste estudo devem ser interpretados prioritariamente com base nas métricas de validação cruzada, e não apenas em medidas simples de correlação.

5.6 Implicações para o dimensionamento e a prática de pavimentos rígidos

Os resultados deste estudo apresentam implicações práticas para a utilização de concreto com agregados reciclados na execução de pavimentos rígidos. A confiabilidade demonstrada pelos modelos de Regressão Lasso e Ridge indica que o aprendizado de máquina pode ser utilizado de forma eficaz como ferramenta de apoio à avaliação preliminar dos materiais, otimização das misturas e controle de qualidade, especialmente quando os recursos disponíveis para ensaios experimentais são limitados.

É importante destacar que a capacidade dos modelos regularizados de fornecer previsões sem viés significativo e estatisticamente consistentes aumenta a confiabilidade de sua aplicação no dimensionamento da espessura dos pavimentos e na avaliação de seu desempenho. Ao integrar dados obtidos experimentalmente com informações provenientes da literatura, a estrutura de modelagem híbrida proposta proporciona uma representação realista das condições de campo, contribuindo para o uso sustentável do concreto com agregados reciclados em sistemas de pavimentos rígidos.

Para aplicação prática, a metodologia proposta pode ser utilizada durante as etapas de dosagem preliminar das misturas, seleção de materiais e avaliação da qualidade em projetos de pavimentos rígidos. Os engenheiros podem utilizar o modelo de aprendizado de máquina desenvolvido para obter estimativas rápidas da resistência à compressão com base em parâmetros de dosagem prontamente disponíveis, reduzindo, assim, a dependência de um grande número de misturas experimentais durante as fases iniciais de planejamento do projeto. A metodologia é particularmente útil na avaliação de diferentes fontes de agregados reciclados, distintos níveis de substituição ou diferentes composições de materiais cimentícios.

Os resultados indicam ainda que atenção especial deve ser dada à intensidade de aglomerante, ao teor de cimento, à resistência do concreto de origem e à dosagem de superplastificante, uma vez que essas variáveis exercem maior influência sobre o desenvolvimento da resistência à compressão. Consequentemente, a otimização desses parâmetros deve ser priorizada durante a dosagem do concreto destinado à pavimentação. Em contrapartida, a taxa de substituição por agregado reciclado, quando considerada isoladamente, não deve ser adotada como o principal indicador do desempenho esperado em termos de resistência, uma vez que a qualidade do agregado e as características de sua origem desempenham papel mais significativo.

Para aplicações de engenharia, os modelos desenvolvidos devem ser considerados ferramentas de apoio à tomada de decisão, e não substitutos dos ensaios laboratoriais normatizados. A aprovação final da mistura de concreto destinada ao pavimento deve continuar fundamentada em verificação experimental, de acordo com as especificações de projeto e os procedimentos de controle de qualidade aplicáveis. Ainda assim, a metodologia proposta pode reduzir substancialmente o número de misturas experimentais necessárias durante as etapas de seleção de materiais e dimensionamento preliminar de pavimentos.

5.7 Identificação do modelo mais adequado

A seleção do modelo preditivo mais adequado para aplicações em pavimentos rígidos deve se basear não apenas na precisão numérica, mas também na robustez diante da multicolinearidade, no comportamento do viés e na confiabilidade para aplicações de engenharia. Na prática do

dimensionamento de pavimentos rígidos, previsões conservadoras e estatisticamente consistentes da resistência à compressão são essenciais, uma vez que esse parâmetro influencia diretamente a determinação da espessura das placas, o desempenho à fadiga e a segurança estrutural em longo prazo. Dessa forma, a seleção do modelo neste estudo foi realizada por meio de uma estrutura de avaliação integrada, combinando métricas de precisão preditiva, análise de viés, avaliação da multicolinearidade por meio do Fator de Inflação da Variância (VIF) e análise da contribuição das variáveis utilizando SHapley Additive exPlanations (SHAP).

Com base na avaliação comparativa apresentada na Tabela 4, a Regressão Lasso destacou-se como o modelo mais adequado para a previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados destinado a aplicações em pavimentos rígidos. A Regressão Lasso apresentou o maior coeficiente de determinação ($R^2 = 0,7713$), indicando a maior concordância entre os valores previstos e medidos da resistência à compressão entre todos os modelos avaliados. Também apresentou os menores valores de MAE (3,51 MPa), RMSE (4,47 MPa) e MAPE (16,44%), demonstrando maior precisão e consistência em toda a faixa de resistência analisada. Sob a perspectiva da engenharia de pavimentos, o comportamento do viés é particularmente crítico. O Erro Médio de Viés (MBE) obtido para o modelo Lasso foi de $-0,0317$ MPa, valor efetivamente desprezível, indicando ausência de superestimação ou subestimação sistemática. A estatística t associada apresentou valor muito baixo, e o valor de p (0,8896) foi substancialmente superior ao nível de significância de 0,05, confirmando que as diferenças entre os valores previstos e observados não são estatisticamente significativas e reforçando a confiabilidade do modelo Lasso para a tomada de decisões em engenharia (Brandes et al., 2018; Hall & Hall, 2017; Patil, 2025). A robustez da Regressão Lasso é adicionalmente justificada pela análise do Fator de Inflação da Variância (VIF). Foram observados valores extremamente elevados de VIF para diversos parâmetros fisicamente inter-relacionados, incluindo a relação água/cimento ($VIF \approx 7836$), a relação água/cimento efetiva ($VIF \approx 7078$), o teor de cimento ($VIF \approx 924$) e a intensidade de aglomerante ($VIF \approx 847$), indicando multicolinearidade severa no conjunto de dados híbrido. Essa multicolinearidade é inerente às variáveis de dosagem do concreto e torna-se particularmente pronunciada em conjuntos de dados híbridos que combinam dados experimentais e provenientes da literatura. Nessas condições, modelos de regressão convencionais e modelos não lineares complexos estão sujeitos a instabilidades. A Regressão Lasso atenua efetivamente esse problema por meio da regularização L1, que penaliza variáveis preditoras redundantes e estabiliza a estimativa dos coeficientes, aumentando, assim, a capacidade de generalização em condições caracterizadas por variáveis de entrada altamente correlacionadas (Asteris et al., 2021; Kumar et al., 2024). A presença de multicolinearidade severa no conjunto de dados híbrido não é inesperada, uma vez que muitos parâmetros de dosagem do concreto são fisicamente inter-relacionados. Por exemplo, a intensidade de aglomerante, o teor de cimento, a relação água/cimento e a relação água/cimento efetiva são derivados de princípios de dosagem relacionados entre si e, em conjunto, influenciam o desenvolvimento da resistência. Embora essas variáveis apresentem forte correlação estatística, elas representam diferentes características de engenharia que governam o desempenho do concreto com agregados reciclados. Portanto, o objetivo deste estudo não foi eliminar variáveis correlacionadas exclusivamente com base em critérios estatísticos, mas preservar informações fisicamente significativas e relevantes para o comportamento do concreto destinado à pavimentação. A adoção de modelos de aprendizado de máquina regularizados possibilitou a manutenção dessas variáveis, ao mesmo tempo em que minimizou os efeitos adversos da multicolinearidade sobre a estabilidade das previsões.

Uma validação física adicional da adequação do modelo foi obtida por meio da análise SHAP, que revelou que a intensidade de aglomerante (média de $|SHAP| \approx 2,61$) e o teor de cimento ($\approx 2,34$) são os parâmetros de maior influência na previsão da resistência à compressão, seguidos pela resistência do concreto de origem ($\approx 2,05$) e pela dosagem de superplastificante ($\approx 1,95$). Esses resultados são plenamente consistentes com o comportamento do concreto destinado a pavimentos

rígidos, nos quais a qualidade da pasta, a origem dos agregados reciclados e a eficiência da compactação exercem influência predominante sobre a capacidade de suporte de cargas e a durabilidade. O índice de severidade do agregado reciclado também apresentou contribuição significativa ($\approx 1,25$), confirmando que o efeito combinado da quantidade e da qualidade dos agregados reciclados exerce maior influência do que a taxa de substituição por agregado reciclado considerada isoladamente, a qual apresentou contribuição SHAP comparativamente baixa ($\approx 0,13$). Variáveis com menor relevância, como método de cura, dimensão máxima do agregado e teor de fibras ou adições minerais, apresentaram influência secundária dentro da faixa estudada, indicando que seus efeitos são, em grande parte, indiretos ou estão incorporados aos parâmetros predominantes da mistura (Jagadesh et al., 2024; Ojha et al., 2024). A predominância da intensidade de aglomerante e do teor de cimento observada na análise SHAP é consistente com os mecanismos fundamentais que governam o desenvolvimento da resistência do concreto. A intensidade de aglomerante reflete a quantidade de material cimentício disponível para a formação dos produtos de hidratação e para o desenvolvimento de uma microestrutura densa, enquanto o teor de cimento influencia diretamente a formação do gel de silicato de cálcio hidratado (C-S-H), principal responsável pelo desenvolvimento da resistência. Valores mais elevados desses parâmetros geralmente contribuem para a melhoria da qualidade da pasta, redução da porosidade e aumento da capacidade de suporte de cargas. Portanto, sua elevada contribuição para as previsões do modelo reflete princípios amplamente estabelecidos da tecnologia do concreto e do dimensionamento de materiais para pavimentos rígidos.

A resistência do concreto de origem destacou-se como outra variável de elevada influência, uma vez que os agregados reciclados herdam características físicas do concreto original a partir do qual são produzidos. Agregados reciclados provenientes de concretos de origem com maior resistência geralmente apresentam menor nível de microfissuração, menor deterioração da argamassa aderida e maior integridade do agregado. Consequentemente, a qualidade do concreto de origem influencia significativamente o comportamento mecânico do concreto com agregados reciclados. A elevada contribuição SHAP associada a essa variável confirma que a qualidade do agregado reciclado não pode ser adequadamente representada apenas pela taxa de substituição, devendo também considerar as propriedades do material de origem. A importância da dosagem de superplastificante pode ser atribuída à sua influência sobre a trabalhabilidade, dispersão das partículas e eficiência da compactação. A dispersão adequada das partículas de cimento favorece uma hidratação mais uniforme e possibilita a redução da demanda efetiva de água sem comprometer a trabalhabilidade. Esse efeito é particularmente benéfico no concreto com agregados reciclados, no qual a maior capacidade de absorção de água dos agregados reciclados pode afetar negativamente as propriedades do concreto no estado fresco. Os resultados da análise SHAP indicam, portanto, que os aditivos químicos desempenham papel significativo no controle do desempenho do concreto tanto no estado fresco quanto no estado endurecido, dentro da faixa de proporções das misturas investigadas.

A Figura 6 ilustra a contribuição das variáveis de entrada individuais para a previsão da resistência à compressão aos 28 dias utilizando o modelo de Regressão Lasso, conforme interpretado por meio da análise SHAP. Os valores absolutos médios de SHAP apresentados na Figura 6(a) quantificam a importância global de cada parâmetro na influência sobre a saída do modelo, enquanto a Figura 6(b) fornece uma visualização comparativa dos efeitos das variáveis ao longo do conjunto de dados.

Embora a Regressão Ridge tenha apresentado desempenho próximo ao da Regressão Lasso, com valores semelhantes de R^2 e de erro, seus erros de previsão ligeiramente mais elevados e seu viés marginalmente maior indicam menor robustez diante de multicolinearidade severa, uma vez que a Regressão Ridge promove a redução da magnitude dos coeficientes sem eliminar variáveis redundantes. Os modelos de aprendizado por *ensemble*, incluindo Gradient Boosting, XGBoost e Random Forest, apresentaram menor precisão preditiva e tendência a viés positivo, indicando superestimação sistemática da resistência à compressão. Esse comportamento é indesejável em

aplicações de pavimentos rígidos, pois pode resultar em um dimensionamento não conservador da espessura das placas e na redução das margens de segurança, particularmente sob condições de tráfego pesado (Ojha et al., 2024; Patil, 2025). A Regressão por Vetores de Suporte (SVR) apresentou o desempenho global mais fraco, caracterizado por maior dispersão dos erros e capacidade limitada de generalização para o conjunto de dados híbrido utilizado no presente estudo.




Figura 6. Interpretação baseada em SHAP do modelo de Regressão Lasso para a previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados: (a) valores absolutos médios de SHAP, indicando a contribuição relativa de cada parâmetro de entrada; e (b) gráfico de resumo SHAP, ilustrando a influência comparativa das variáveis sobre as previsões do modelo.

As evidências integradas provenientes das métricas de precisão preditiva, da análise de viés, da avaliação pelo VIF e da interpretação da importância das variáveis baseada em SHAP confirmam que a Regressão Lasso oferece a estrutura mais confiável, estável e fisicamente coerente para a previsão da resistência à compressão do concreto com agregados reciclados em aplicações de pavimentos rígidos. No âmbito deste estudo, a Regressão Lasso é, portanto, identificada como o modelo mais adequado para apoiar a avaliação dos materiais de pavimentação e o dimensionamento sustentável de pavimentos. De forma mais ampla, o estudo demonstra que o valor do aprendizado de máquina para a previsão da resistência do concreto com agregados reciclados (RAC) depende não apenas da seleção do algoritmo, mas também da qualidade e da diversidade do conjunto de dados utilizado. O conjunto de dados híbrido experimental–literatura desenvolvido neste estudo constitui a principal contribuição metodológica, ao combinar observações fundamentadas experimentalmente com uma gama mais ampla de condições de RAC relatadas na literatura, enquanto a análise comparativa dos modelos identifica a Regressão Lasso como a abordagem mais adequada dentro do escopo dos dados disponíveis.

6 CONCLUSÕES E IMPLICAÇÕES PRÁTICAS

Este estudo desenvolveu e avaliou sistematicamente um conjunto de dados híbrido experimental–literatura para a previsão da resistência à compressão aos 28 dias do concreto com agregados reciclados (RAC) destinado a aplicações em pavimentos rígidos. O conjunto de dados combina observações obtidas em laboratório com dados cuidadosamente selecionados da literatura, de modo a representar uma gama mais ampla de condições de dosagem do RAC, características dos agregados reciclados e condições de cura. A análise por aprendizado de máquina foi então utilizada para avaliar o desempenho de diferentes abordagens de modelagem dentro desse conjunto de dados heterogêneo. Os resultados demonstram que a principal contribuição do estudo consiste no estabelecimento de uma base de dados mais abrangente e direcionada às aplicações em pavimentos para a previsão da resistência do RAC, enquanto a análise dos modelos fornece evidências sobre a adequação relativa das diferentes abordagens de previsão.

A investigação experimental confirmou que a resistência à compressão do RAC utilizado em pavimentos rígidos é governada pela influência combinada das características do aglomerante, qualidade dos agregados reciclados, resistência do concreto de origem e condições de cura. Os valores de resistência medidos apresentaram variabilidade significativa, particularmente para níveis mais elevados de substituição por agregados reciclados, evidenciando as limitações das relações empíricas convencionais quando o RAC é empregado em concretos destinados à pavimentação. Essa constatação justificou o desenvolvimento de uma estrutura de previsão orientada por dados, adaptada às proporções de mistura relevantes para aplicações em pavimentos. O conjunto de dados híbrido integrou com sucesso os dados experimentais aos resultados reportados na literatura, permitindo que os modelos de aprendizado de máquina fossem desenvolvidos a partir de uma gama mais ampla de qualidades dos agregados reciclados e composições de mistura. Essa abordagem possibilitou uma melhor capacidade de generalização e contribuiu para superar a limitação decorrente da quantidade restrita de dados experimentais, situação comum em estudos de materiais destinados à pavimentação. A avaliação comparativa dos modelos de aprendizado de máquina demonstrou que as técnicas de regressão linear regularizada são mais eficazes do que os modelos *ensemble* e aqueles baseados em *kernel* quando aplicados a conjuntos de dados híbridos dessa natureza. Entre todos os modelos avaliados, a Regressão Lasso apresentou o melhor desempenho preditivo, com coeficiente de determinação de 0,7713, erro absoluto médio de 3,51 MPa e raiz do erro quadrático médio de 4,47 MPa. Esses valores indicam uma precisão confiável na previsão da resistência para a avaliação de materiais destinados a pavimentos rígidos. Em contraste, modelos de aprendizado por *ensemble*, como Gradient Boosting, XGBoost e Random Forest, apresentaram valores de R^2 inferiores, variando entre 0,69 e 0,72, e valores de RMSE mais elevados, entre 4,97 e 5,21 MPa, enquanto a Regressão por Vetores de Suporte (SVR) apresentou o desempenho mais fraco, com RMSE de 5,62 MPa e MAPE superior a 20%. A análise de viés reforçou ainda mais a adequação da Regressão Lasso, que apresentou um Erro Médio de Viés (MBE) desprezível, de $-0,0317$ MPa, e uma diferença estatisticamente não significativa entre as resistências previstas e observadas, conforme indicado pelo valor de p de 0,8896. Esse comportamento sem viés significativo e estatisticamente consistente é particularmente importante para o dimensionamento de pavimentos rígidos, no qual estimativas conservadoras da resistência à compressão são essenciais para assegurar a espessura adequada das placas e o desempenho à fadiga.

A robustez do modelo selecionado foi adicionalmente validada por meio da análise do Fator de Inflação da Variância (VIF), que revelou multicolinearidade severa entre diversas variáveis de dosagem fisicamente inter-relacionadas. Foram observados valores extremamente elevados de VIF para a relação água/cimento e a relação água/cimento efetiva (superiores a 7000), bem como para o teor de cimento e a intensidade de aglomerante (superiores a 800), refletindo a dependência física inerente entre essas variáveis. Apesar disso, a Regressão Lasso permaneceu estável devido à sua capacidade de regularização L1, confirmando sua adequação para conjuntos de dados de

Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

pavimentação nos quais a presença de variáveis correlacionadas é inevitável. A análise de SHapley Additive exPlanations (SHAP) forneceu informações adicionais, sob a perspectiva da engenharia, sobre os mecanismos que governam o desenvolvimento da resistência à compressão do concreto com agregados reciclados. A intensidade de aglomerante destacou-se como a variável de maior influência, evidenciando a importância da disponibilidade de material cimentício nos processos de hidratação e formação da microestrutura. O teor de cimento também apresentou elevada contribuição, confirmando seu papel direto na formação dos produtos de hidratação responsáveis pelo desenvolvimento da resistência. A resistência do concreto de origem foi identificada como outro parâmetro de grande influência, uma vez que a qualidade dos agregados reciclados depende fortemente das características do concreto do qual são provenientes. Agregados reciclados originados de concretos de maior resistência geralmente apresentam menores níveis de microfissuração e maior integridade, contribuindo positivamente para o desempenho mecânico. A dosagem de superplastificante também apresentou influência significativa, por melhorar a trabalhabilidade, a dispersão das partículas e a eficiência da compactação, particularmente em misturas contendo agregados reciclados com maior absorção de água. Em conjunto, esses resultados indicam que o desenvolvimento da resistência à compressão do concreto com agregados reciclados é governado não apenas pelos níveis de substituição dos agregados reciclados, mas também pela qualidade do aglomerante, pelas características do material de origem e pelas estratégias de otimização da mistura. O índice de severidade do agregado reciclado demonstrou ainda que a qualidade do agregado exerce maior influência sobre o desempenho da resistência do que a taxa de substituição considerada isoladamente. A multicolinearidade observada deve ser interpretada como uma característica inerente aos conjuntos de dados de dosagem de concreto, e não como uma deficiência da modelagem. Muitas variáveis utilizadas no projeto de misturas de concreto são matematicamente relacionadas e não podem ser tratadas como parâmetros completamente independentes. Consequentemente, a manutenção das variáveis correlacionadas foi considerada necessária para preservar a relevância do ponto de vista da engenharia e manter a coerência com os procedimentos práticos de dosagem do concreto. O desempenho satisfatório dos modelos regularizados demonstra que é possível obter previsões confiáveis da resistência, mesmo na presença de forte dependência entre as variáveis.

Sob a perspectiva da engenharia de pavimentos rígidos, esses resultados indicam que a previsão da resistência à compressão do concreto com agregados reciclados (RAC) é governada principalmente por relações lineares predominantes associadas aos parâmetros de qualidade do aglomerante e dos agregados. A maior precisão, o viés desprezível, a robustez diante de multicolinearidade extrema e o comportamento fisicamente interpretável da Regressão Lasso tornam esse modelo particularmente adequado para a tomada de decisões em nível de material no dimensionamento de placas de pavimentos, na estimativa da vida à fadiga e na seleção de materiais orientada por critérios de sustentabilidade. A tendência dos modelos *ensemble* de superestimar a resistência reforça ainda mais a importância da avaliação do viés quando abordagens de aprendizado de máquina são aplicadas a sistemas de pavimentação nos quais a segurança é um aspecto crítico.

Apesar dos resultados promissores, algumas limitações devem ser reconhecidas. O conjunto de dados híbrido contém variáveis que apresentam multicolinearidade significativa, decorrente das relações inerentes entre os parâmetros de dosagem do concreto. Embora as técnicas de regularização tenham controlado de forma eficaz sua influência no presente estudo, a capacidade de transferência dos modelos desenvolvidos deve ser investigada adicionalmente utilizando conjuntos de dados independentes provenientes de diferentes regiões geográficas e fontes de materiais. Estudos futuros também poderão explorar técnicas avançadas de seleção de variáveis e redução de dimensionalidade, a fim de avaliar se uma precisão preditiva comparável pode ser alcançada utilizando um conjunto reduzido de variáveis de engenharia.

A metodologia proposta permite uma estimativa confiável da resistência à compressão do concreto

com agregados reciclados, com um erro médio de previsão de aproximadamente 3,5 MPa, contribuindo para o dimensionamento preliminar de materiais destinados a pavimentos rígidos. A metodologia auxilia na otimização das misturas e na avaliação da qualidade, ao mesmo tempo em que reduz a dependência de uma extensa campanha de ensaios laboratoriais durante as etapas iniciais de projeto. Além disso, a interpretação transparente proporcionada pela análise SHAP permite que os engenheiros priorizem a qualidade do aglomerante e as características dos agregados reciclados durante a dosagem do concreto para pavimentação, contribuindo para uma construção sustentável sem comprometer a confiabilidade estrutural. Cabe destacar também que a validação dos modelos foi realizada por meio de uma estrutura de validação cruzada em cinco partes (*five-fold cross-validation*), e não utilizando um conjunto de dados externo totalmente independente. Embora essa abordagem proporcione uma avaliação rigorosa da capacidade preditiva interna, uma validação adicional utilizando conjuntos de dados provenientes de diferentes regiões geográficas, fontes de agregados e ambientes construtivos contribuiria para aumentar a confiabilidade quanto à aplicabilidade mais ampla da metodologia proposta. Dessa forma, os resultados do presente estudo devem ser interpretados como uma avaliação comparativa confiável dos algoritmos de aprendizado de máquina dentro do escopo do conjunto de dados híbrido disponível.

Do ponto de vista prático, a metodologia de aprendizado de máquina proposta pode auxiliar os engenheiros na avaliação rápida de misturas de concreto com agregados reciclados durante as etapas preliminares de dimensionamento de pavimentos e seleção de materiais. A capacidade de identificar as variáveis de maior influência sobre a resistência fornece suporte adicional para a otimização das proporções das misturas, mantendo, simultaneamente, os objetivos relacionados à sustentabilidade da construção.

Pesquisas futuras devem se concentrar na ampliação da metodologia proposta para a previsão da resistência à tração na flexão, módulo de elasticidade e desempenho à fadiga, propriedades diretamente utilizadas no dimensionamento mecânico-empírico de pavimentos rígidos. A incorporação de indicadores de durabilidade de longo prazo, como retração, resistência à abrasão e desempenho frente aos ciclos de congelamento e degelo, contribuiria ainda mais para aprimorar a avaliação dos pavimentos com base em seu ciclo de vida. Também são necessários estudos adicionais para desenvolver conjuntos de dados calibrados em condições de campo, que incorporem carregamentos decorrentes do tráfego, exposição ambiental e variabilidade construtiva, bem como para explorar modelos de aprendizado de máquina informados pela física (*physics-informed machine learning*), capazes de integrar a mecânica dos pavimentos às previsões orientadas por dados. Esses avanços contribuirão para ampliar ainda mais a aplicabilidade do aprendizado de máquina na engenharia sustentável de pavimentos rígidos.

Embora a metodologia desenvolvida tenha apresentado desempenho preditivo satisfatório, sua validação ficou limitada à validação cruzada em cinco partes (*five-fold cross-validation*) do conjunto de dados híbrido disponível. Estudos futuros deverão incorporar conjuntos de dados externos independentes e populações amostrais maiores, a fim de avaliar de forma mais abrangente a capacidade de transferência e a robustez dos modelos.

2. REFERÊNCIA

- Alyami, M., Alyousef, R., Alabduljabbar, H., Alrshoudi, F. (2024). *Machine learning-based prediction of concrete compressive strength using hybrid datasets*. Construction and Building Materials, 390, 131768. <https://doi.org/10.1016/j.conbuildmat.2023.131768>
- American Association of State Highway, & Officials, T. (1993). *AASHTO Guide for Design of Pavement Structures*. AASHTO.
- Asteris, P. G., Apostolopoulou, M., Skentou, A. D., Moropoulou, A. (2021). *Application of machine learning techniques for concrete strength prediction*. Materials, 14(6), 1434. <https://doi.org/10.3390/ma14061434>
- Asteris, P. G., Kolovos, K. G., Douvika, M. G., Roussis, P. C. (2019). *Prediction of self-compacting*
- Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

- concrete strength using artificial neural networks. *European Journal of Environmental and Civil Engineering*, 23(3), 329–347. <https://doi.org/10.1080/19648189.2017.1320233>
- Asteris, P. G., Skentou, A. D., Bardhan, A., Samui, P., Pilakoutas, K. (2020). *Predicting concrete strength using machine learning*. *Construction and Building Materials*, 252, 119134. <https://doi.org/10.1016/j.conbuildmat.2020.119134>
- Behera, M., Bhattacharyya, S. K., Minocha, A. K., Deoliya, R., Maiti, S. (2014). *Recycled aggregate from C&D waste and its use in concrete*. *Resources, Conservation and Recycling*, 68, 30–43. <https://doi.org/10.1016/j.resconrec.2012.10.007>
- Brandes, M. R., Butterfield, J., Roesler, J. R. (2018). *Effect of recycled concrete aggregates on strength and stiffness gain of concrete*. *PCI Journal*, 63(3), 52–65. <https://doi.org/10.15554/pci.06012018.52.65>
- Butler, L., West, J. S., Tighe, S. L. (2016). *Effect of recycled concrete aggregate properties on the bond strength between concrete and steel reinforcement*. *Cement and Concrete Research*, 41(10), 1037–1049. <https://doi.org/10.1016/j.cemconres.2011.06.004>
- Chakradhara Rao, M., Bhattacharyya, S. K., Barai, S. V. (2007). *Assessment of durability of recycled aggregate concrete produced by two-stage mixing approach*. *Journal of Materials in Civil Engineering*, 19(5), 379–386. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2007\)19:5\(379\)](https://doi.org/10.1061/(ASCE)0899-1561(2007)19:5(379))
- Chauhan, B. L., Singh, G. J. (2023). *Sustainable development of recycled concrete aggregate through optimized acid–mechanical treatment: A simplified approach*. *Construction and Building Materials*, 399, 132559. <https://doi.org/10.1016/j.conbuildmat.2023.132559>
- Chou, J. S., Pham, A. D. (2013). *Hybrid computational model for predicting bridge construction cost*. *Automation in Construction*, 35, 331–340. <https://doi.org/10.1016/j.autcon.2013.05.016>
- Chou, J. S., Tsai, C. F., Pham, A. D., Lu, Y. H. (2014). *Machine learning in concrete strength simulations: Multi-nation data analytics*. *Construction and Building Materials*, 73, 771–780. <https://doi.org/10.1016/j.conbuildmat.2014.09.054>
- Duan, Z., Kou, S. C., Poon, C. S. (2021). *Using artificial neural networks to predict the compressive strength of recycled aggregate concrete*. *Construction and Building Materials*, 289, 123155. <https://doi.org/10.1016/j.conbuildmat.2021.123155>
- Etzeberria, M., Vázquez, E., Marí, A., Barra, M. (2007). *Influence of amount of recycled coarse aggregates and production process on properties of recycled aggregate concrete*. *Cement and Concrete Research*, 37(5), 735–742. <https://doi.org/10.1016/j.cemconres.2007.02.002>
- Fanijo, E. O. (2023). *A comprehensive review on the use of recycled concrete aggregates for pavement construction*. *Cleaner Materials*, 8, 100159. <https://doi.org/10.1016/j.clema.2023.100159>
- Gogoi, S., Singh, J. P., Verma, A. (2023). *Multicollinearity effects in machine learning models for concrete*. *Materials Today: Proceedings*, 72, 2580–2587. <https://doi.org/10.1016/j.matpr.2022.09.507>
- Hall, J. W., Hall, J. L. (2017). *Engineering Decision-Making under Uncertainty*. Springer. <https://doi.org/10.1007/978-3-319-69953-0>
- Huang, Y. H. (2004). *Pavement Analysis and Design* (2nd ed.). Pearson Prentice Hall.
- Ismail, S., Ramli, M., Karim, M. R. (2022). *Influence of recycled aggregate quality and proportioning criteria on recycled concrete properties: A review*. *Construction and Building Materials*, 340, 127746. <https://doi.org/10.1016/j.conbuildmat.2022.127746>
- Jagadesh, P., Karthik, K., Kalaivani, P. (2024). *Examining the influence of recycled aggregates on the fresh and mechanical characteristics of high-strength concrete: A comprehensive review*. *Sustainability*, 16(20), 9052. <https://doi.org/10.3390/su16209052>
- Katz, A. (2003). *Properties of concrete made with recycled aggregate from partially hydrated old concrete*. *Cement and Concrete Research*, 33(5), 703–711. [https://doi.org/10.1016/S0008-8846\(02\)01033-5](https://doi.org/10.1016/S0008-8846(02)01033-5)
- Khan, M. A., Khan, M. I., Aslam, F. (2022). *Machine learning-based prediction of recycled aggregate concrete strength*. *Journal of Building Engineering*, 45, 103115. <https://doi.org/10.1016/j.jobbe.2021.103115>
- Kumar, M., Samui, P., Kumar, D. R. (2024). *State-of-the-art machine learning models for predicting compressive strength of concrete: A comparative study*. *Construction and Building Materials*, 375, 130890. <https://doi.org/10.1016/j.conbuildmat.2023.130890>
- Li, L., Wang, Y., Zhang, J., Li, Z. (2022). *Effects of multicollinearity on machine learning prediction of concrete strength incorporating recycled aggregates*. *Engineering Structures*, 252, 113620. <https://doi.org/10.1016/j.engstruct.2021.113620>
- Limbachiya, M. C., Leelawat, T., Dhir, R. K. (2000). *Use of recycled concrete aggregate in high-strength*
- Abordagens de aprendizado de máquina para estimar a resistência do concreto de agregado reciclado de concreto em sistemas de pavimentação rígida.

- concrete. *Materials and Structures*, 33(9), 574–580. <https://doi.org/10.1007/BF02480538>
- Liu, H., Wu, J., Chen, B. (2021). *Prediction of compressive strength of recycled aggregate concrete using ensemble machine learning techniques*. *Materials*, 14(18), 5263. <https://doi.org/10.3390/ma14185263>
- Lundberg, S. M., Lee, S. I. (2017). *A unified approach to interpreting model predictions*. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Neville, A. M. (2011). *Properties of Concrete* (5th ed.). Pearson Education.
- Nguyen, T. T., Pham, T. M., Hao, H. (2021). *Prediction of concrete compressive strength using machine learning: A comparative study*. *Structures*, 33, 120–134. <https://doi.org/10.1016/j.istruc.2021.04.056>
- Ojha, P. N., Kaura, P., Singh, B. (2024). *Studies on mechanical performance of treated and non-treated coarse recycled concrete aggregate and its performance in concrete: An Indian case study*. *Research on Engineering Structures & Materials*, 10(1), 341–362. <https://doi.org/10.17515/resm2023.53me0728rs>
- Padmini, A. K., Ramamurthy, K., Mathews, M. S. (2009). *Influence of parent concrete on the properties of recycled aggregate concrete*. *Construction and Building Materials*, 23(2), 829–836. <https://doi.org/10.1016/j.conbuildmat.2008.03.006>
- Park, S., Kim, J., Lee, H. (2022). *Machine learning-based prediction of mechanical properties of recycled aggregate concrete under controlled experimental conditions*. *Sustainability*, 14(9), 5407. <https://doi.org/10.3390/su14095407>
- Patil, R. D. (2025). *The performance of concrete with various recycled aggregates: Indian case studies and comparative assessment*. *European Transport Research Review*, 17(1), 12. <https://doi.org/10.1186/s12544-025-00632-1>
- Pedro, D., de Brito, J., Evangelista, L. (2017). *Structural concrete with incorporation of coarse recycled concrete aggregates: Mechanical, durability and long-term properties*. *Construction and Building Materials*, 154, 294–309. <https://doi.org/10.1016/j.conbuildmat.2017.07.185>
- Shahmansouri, A. A., Bengar, H. A., Akbarzadeh Bengar, H. (2021). *Data-driven prediction of concrete properties*. *Engineering Structures*, 226, 111353. <https://doi.org/10.1016/j.engstruct.2020.111353>
- Silva, R. V., de Brito, J., Dhir, R. K. (2014). *Properties and composition of recycled aggregates from construction and demolition waste suitable for concrete production*. *Construction and Building Materials*, 65, 201–217. <https://doi.org/10.1016/j.conbuildmat.2014.04.117>
- Tam, V. W. Y., Soomro, M., Evangelista, A. C. J. (2018). *A review of recycled aggregate in concrete applications*. *Journal of Cleaner Production*, 172, 272–291. <https://doi.org/10.1016/j.jclepro.2017.10.236>
- Tam, V. W. Y., Tam, C. M., Ng, W. C. Y. (2005). *Microstructural analysis of recycled aggregate concrete produced from two-stage mixing approach*. *Cement and Concrete Research*, 35(6), 1195–1203. <https://doi.org/10.1016/j.cemconres.2004.10.025>
- Tamagusko, J., Ferreira, R. M., Jalali, S. (2024). *Practical limitations of laboratory-based datasets in machine learning applications for recycled aggregate concrete*. *Automation in Construction*, 156, 105116. <https://doi.org/10.1016/j.autcon.2023.105116>
- Tank, Y. R., Parmar, J. P., Gadhiya, D. H., Goyani, J. S. (2014). *Experimental study of compressive strength of recycled aggregate concrete*. *International Journal of Engineering Research & Technology*, 3(4), 1380–1384.
- Thomas, C., Setién, J., Polanco, J. A., Alaejos, P., de Juan, M. (2013). *Durability of recycled aggregate concrete*. *Construction and Building Materials*, 40, 1054–1065. <https://doi.org/10.1016/j.conbuildmat.2012.11.106>
- Xiao, J., Li, W., Fan, Y., Huang, X. (2018). *An overview of study on recycled aggregate concrete in China*. *Construction and Building Materials*, 31, 364–383. <https://doi.org/10.1016/j.conbuildmat.2011.12.074>
- Yeh, I. C. (1998). *Modeling of strength of high-performance concrete using artificial neural networks*. *Cement and Concrete Research*, 28(12), 1797–1808. [https://doi.org/10.1016/S0008-8846\(98\)00165-3](https://doi.org/10.1016/S0008-8846(98)00165-3)
- Zhang, J., Zhao, Y., Chen, Y. (2020). *Prediction of recycled aggregate concrete strength using support vector machine and ensemble learning*. *Materials & Design*, 190, 108572. <https://doi.org/10.1016/j.matdes.2020.108572>
- Zhuang, Y., Chen, Y., Li, Z. (2021). *Performance comparison of machine learning models for concrete strength prediction*. *Construction and Building Materials*, 276, 122132. <https://doi.org/10.1016/j.conbuildmat.2020.122132>