

UNIVERSIDADE FEDERAL DO PARANÁ

PAULO HIROSHI KATO FILHO

PREVISÃO DA RESISTÊNCIA À COMPRESSÃO AOS 28 DIAS EM CONCRETOS
CONVENCIONAIS

CURITIBA, PR
2023

PAULO HIROSHI KATO FILHO

PREVISÃO DA RESISTÊNCIA À COMPRESSÃO AOS 28 DIAS EM CONCRETOS
CONVENCIONAIS

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Especialista em Inteligência Artificial Aplicada no Programa de Pós-Graduação em Inteligência Artificial Aplicada, Setor de Educação Profissional e Tecnológica, da Universidade Federal do Paraná.

Orientador: Prof. Dr. Razer Anthom Nizer Rojas Montaña.

CURITIBA, PR
2023

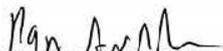


MINISTÉRIO DA EDUCAÇÃO
SETOR DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CURSO DE PÓS-GRADUAÇÃO INTELIGÊNCIA ARTIFICIAL
APLICADA - 40001016348E1

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação INTELIGÊNCIA ARTIFICIAL APLICADA da Universidade Federal do Paraná foram convocados para realizar a arguição da Monografia de Especialização de **PAULO HIROSHI KATO FILHO** intitulada: **Previsão da Resistência à Compressão aos 28 Dias em Concretos Convencionais**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa. A outorga do título de especialista está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 07 de Novembro de 2023.


RAZER ANTHOM NIZER ROJAS MONTAÑO
Presidente da Banca Examinadora


JAIME WOJCIECHOWSKI
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Previsão da Resistência à Compressão aos 28 dias em Concretos Convencionais

Paulo Hiroshi Kato Filho
Setor de Educação Profissional e Tecnológica
Universidade Federal do Paraná
Curitiba, Brasil
paulo.hiroshi.k@hotmail.com

Prof. Dr. Razer Anthom Nizer Rojas Montaña
Setor de Educação Profissional e Tecnológica
Universidade Federal do Paraná
Curitiba, Brasil
razer@ufpr.br

Resumo—Este artigo científico aborda a importância da predição da resistência à compressão do concreto na construção civil e a influência de fatores como a quantidade de água, curvas granulométricas dos agregados e outros componentes na resistência. O estudo utiliza modelos de aprendizado de máquina, incluindo Random Forest, XGBoost, Redes Neurais Artificiais e o Explainable Boosting Machine, para prever a resistência do concreto. Os resultados mostram que os modelos têm um desempenho sólido, com coeficientes de determinação próximos a 0,8, indicando previsões precisas. O Erro Percentual Absoluto Médio (MAPE) variou de 10,07% a 11,79%, sugerindo previsões confiáveis. Além disso, o EBM demonstrou capacidade de interpretabilidade, identificando as principais variáveis que influenciam a resistência do concreto, como a resistência desejada (fck), finura do cimento, umidade da areia e granulometria dos agregados. O estudo destaca a importância desses modelos na indústria da construção, possibilitando previsões acertivas e compreensão das relações entre variáveis. Também sugere possíveis melhorias futuras, como a incorporação da curva granulométrica dos materiais finos e consideração da composição mineralógica das britas e areias. Em resumo, este artigo contribui para a otimização do design do concreto e tem o potencial de beneficiar a construção civil, melhorando a qualidade e eficiência das estruturas de concreto.

Palavras-chave—Previsão, Resistência à Compressão, Concretos Convencionais, Inteligência Artificial, Otimização de Hiperparâmetros, Random Forest, XGBoost, Redes Neurais Artificiais, Explainable Boosting Machines

Resumo—This scientific article addresses the importance of predicting the compressive strength of concrete in the construction industry and the influence of factors such as the water content, particle size distribution of aggregates, and other components on its strength. The study employs machine learning models, including Random Forest, XGBoost, Artificial Neural Networks, and the Explainable Boosting Machine, to forecast concrete strength. The results demonstrate that the models exhibit robust performance, with coefficients of determination close to 0.8, indicating accurate predictions. The Mean Absolute Percentage Error (MAPE) ranged from 10.07% to 11.79%, suggesting reliable forecasts. Furthermore, the Explainable Boosting Machine (EBM) displayed interpretability by identifying the key variables influencing concrete strength, such as the desired strength (fck), cement fineness, sand moisture, and aggregate gradation. The study underscores the significance of these models in the construction industry, enabling accurate predictions and understanding of the relationships between variables. It also suggests potential future improvements, such as incorporating the particle size distribution of fine materials and considering the mineralogical composition of aggregates and sands. In summary, this article contributes to the

optimization of concrete design and has the potential to benefit the construction sector by enhancing the quality and efficiency of concrete structures

Index Terms—Prediction, Compressive Strength, Conventional Concrete, Artificial Intelligence, Hyperparameter Optimization, Random Forest, XGBoost, Artificial Neural Networks, Explainable Boosting Machines

I. DESENVOLVIMENTO

O concreto desempenha um papel fundamental na construção civil, sendo amplamente empregado em estruturas para sustentar cargas e resistir às forças de compressão. A avaliação da resistência à compressão é um indicador primordial da qualidade do produto e um parâmetro crítico no desenho de estruturas de concreto.

A resistência à compressão do concreto é geralmente medida aos 28 dias, período este aceito internacionalmente [1]–[5] como padrão para que o concreto alcance sua resistência característica. Essa afirmação é baseada no fato de que o cimento - componente do concreto - passa por um processo químico conhecido como hidratação. Nessa reação, os silicatos de cálcio presentes no cimento combinam-se com a água para formar o silicato de cálcio hidratado (CSH) [6].

Durante a hidratação, o cimento - através da formação do silicato de cálcio hidratado - adquire propriedades que aumentam sua resistência mecânica, em especial à compressão. Este processo acontece rapidamente nos primeiros dias, então diminui gradualmente. Geralmente, cerca de 70% da resistência à compressão total é esperada dentro de uma semana [6].

A resistência à compressão do concreto é altamente influenciada pela quantidade de água utilizada em sua composição. Uma referência é a Curva de Abrams, proposta pelo engenheiro Duff Abrams em 1918, que postula que a resistência do concreto é inversamente proporcional à relação água/cimento, desde que todas as demais condições sejam mantidas constantes [7]. Isso se deve à química da hidratação do cimento: quando a quantidade de água na mistura é aumentada, a estrutura resultante do concreto se torna mais porosa e, consequentemente, menos resistente, enquanto a redução de água leva a uma estrutura mais densa, potencializando a resistência à compressão do material [7]. Contudo, é importante salientar a necessidade de

uma quantidade mínima de água para garantir a trabalhabilidade da mistura e a completa hidratação do cimento.

Outros fatores, como a quantidade de cimento e materiais cimentícios suplementares (SCMs), o tamanho das partículas dos agregados miúdos e graúdos e o tipo e a quantidade de aditivos químicos, também são fundamentais na determinação da resistência à compressão do concreto [8]. No entanto, os efeitos desses diversos componentes não são totalmente independentes; eles interagem entre si.

O uso de modelos de aprendizado de máquina (ML) para prever a resistência à compressão do concreto tem se tornado cada vez mais popular devido à complexidade dos fatores que regem esse fenômeno. Diversas técnicas de ML, como *Random Forest* (RF), *XGBoost* (XGB) e *Redes Neurais Artificiais* (RNA) têm sido empregadas para prever propriedades do concreto, incluindo a resistência à compressão [9]–[16]. Dentro da área de inteligência artificial, além do desenvolvimento de modelos preditivos mais tradicionais, há um grande interesse em estudar modelos de ML que não sejam somente preditivos, mas também interpretáveis e capazes de explicar suas previsões [17]–[20]. Novas abordagens, como a *Explainable Boosting Machine* (EBM) [21], têm sido oferecidas para proporcionar maior interpretabilidade, permitindo que o processo de tomada de decisão e as previsões sejam compreendidos tanto em aspectos globais quanto locais.

O desenvolvimento dessas técnicas interpretáveis é impulsionado pela necessidade de compreender os fatores que influenciam a resistência do concreto de maneira mais precisa. Além disso, a importância de ter dados confiáveis na base de treinamento para esses modelos é ressaltada, especialmente no que diz respeito à quantidade de água utilizada na mistura, uma vez que a relação água/cimento é fundamental para a resistência final do concreto.

O objetivo deste trabalho é realizar uma avaliação comparativa entre modelos preditivos tradicionais, como *Random Forest*, *XGBoost* e *Redes Neurais Artificiais*, e o modelo *Explainable Boosting Machine*, em termos de sua capacidade de prever a resistência à compressão do concreto.

Essa avaliação busca fornecer percepções sobre a eficácia e interpretabilidade dos diferentes modelos na previsão da resistência à compressão do concreto. Ao comparar os resultados dos modelos RF, XGB, RNA e EBM, será possível determinar se a abordagem explicável do EBM oferece vantagens adicionais em termos de interpretabilidade e desempenho preditivo.

A. Descrição dos dados

A base de dados utilizada para esta análise provém de várias concreteiras situadas em todo o Brasil, perfazendo um total de 46.071 registros desde o ano de 2021. Essa base é privada e contém informações detalhadas sobre as composições dos concretos. Esses dados são tanto valores teóricos, ou seja, valores utilizados na receita do concreto, quanto reais, isto é, medidos diretamente no sistema de automação da balança na planta de concreto.

Os dados abrangem uma variedade de atributos. Estes incluem, mas não estão limitados a:

- Informações sobre a remessa e o volume de concreto produzido;
- A resistência à compressão teórica do concreto (f_{ck}) e as resistências à compressão medidas aos 7 e 28 dias;
- Detalhes de eventuais anomalias detectadas durante o processo de produção;
- Informações do número da nota fiscal (para relacionar com as matérias-primas) e as características dos materiais compostos de concreto (MCCs), incluindo o tipo de MCC, a quantidade teórica e real, e a unidade de medida;
- Informações sobre as quantidades de águas teóricas e reais da mistura;
- Ensaio físicos e químicos realizados nos MCCs, que fornecem uma série de características, como a curva granulométrica, a absorção de água, a massa específica, entre outros.

Para determinar quais as variáveis relevantes, primeiro realizam-se consultas detalhadas com especialistas no negócio de concreto. Em seguida, buscam-se referências na literatura acadêmica e técnica pertinentes ao campo, a fim de estabelecer uma base sólida para a seleção das variáveis de interesse.

Nesse contexto, as granulometrias das areias e britas, juntamente com a finura do cimento, emergem como escolhas criteriosas. A decisão de considerar o tamanho dos agregados e a finura do cimento como variáveis relevantes baseia-se em suas notáveis influências na resistência à compressão do concreto. O tamanho das partículas de cimento afeta diretamente a área de contato, com partículas mais finas aumentando a velocidade de hidratação do cimento. Por outro lado, no caso dos agregados, tamanhos menores resultam em uma maior área de contato, o que, por sua vez, implica uma maior demanda de água de mistura, afetando negativamente a resistência do concreto [22]. Portanto, a seleção destes parâmetros é respaldada pela sua importância prática e impacto nas propriedades do concreto.

Além das granulometrias das areias e britas e da finura do cimento, as quantidades reais e teóricas de cada material desempenham um papel fundamental na determinação das variáveis do estudo. A quantidade de agregados, cimento e aditivo é especialmente importante, pois influencia diretamente a resistência à compressão, trabalhabilidade, tempo de pega e outros aspectos do concreto [11]. É importante ressaltar que a resistência intrínseca do próprio cimento também é um fator significativo que influencia a resistência do concreto.

A água é um componente fundamental no comportamento do concreto, conforme destacado na seção de desenvolvimento. Tanto a quantidade de água adicionada na mistura quanto a umidade dos materiais desempenham papéis importantes a serem considerados durante o processo de dosagem do concreto. A quantidade de água influencia diretamente a relação água-cimento, que, por sua vez, afeta a resistência e durabilidade do concreto. Adicionalmente, o tipo de aditivo utilizado pode ter um impacto significativo na trabalhabilidade da mistura e na demanda por água. Portanto, a seleção criteriosa da quantidade de água, umidade dos materiais e tipo de aditivo desempenha

papeis vitais na obtenção das propriedades desejadas para o concreto.

As variáveis utilizadas são apresentadas na Tabela VIII localizada no Apêndice A.

B. Métodos

1) *Coleta e estruturação dos dados*: As informações utilizadas na predição da resistência à compressão do concreto estão presentes em três conjuntos de dados principais relacionados à produção e desempenho do concreto: parâmetros de qualidade do concreto, dados da pesagem dos agregados e ensaios físicos e químicos dos agregados e do cimento. Esses conjuntos de dados contêm variadas informações como datas de remessa, volumes, resistência do concreto, categorias de materiais, quantidades teóricas e reais, e uma ampla gama de parâmetros de ensaios físicos e químicos.

Uma parte significativa deste estudo envolveu a preparação e o processamento destes dados para que pudessem ser utilizados em um modelo preditivo de resistência do concreto. O objetivo principal da preparação dos dados foi combinar todas as informações relevantes em um formato adequado para análise e modelagem.

Já em relação aos agregados, eles representam boa parte da composição do concreto, e as suas propriedades, tais como o tamanho e a distribuição granulométrica, podem ter um impacto significativo na resistência do concreto. Neste estudo, utiliza-se a curva granulométrica, que representa a distribuição do tamanho das partículas retidas em diferentes peneiras, de forma a criar uma "impressão digital" dos agregados em cada lote de concreto. Duas curvas granulométricas foram consideradas, sendo uma para as areias (natural e artificial somadas) e uma para as britas (brita 0 e brita 1 somadas).

Ao somar as curvas granulométricas retidas dos diferentes agregados de um lote, é possível criar um perfil granulométrico composto. Este perfil granulométrico composto captura as características dos agregados de forma integrada e proporciona uma representação abrangente da composição granulométrica do concreto.

A inclusão deste perfil granulométrico composto no modelo preditivo permite incorporar as características dos agregados na previsão da resistência do concreto e não só as quantidades reais e teóricas. Esta é uma etapa primordial, dado que diferentes fornecedores de agregados podem fornecer materiais com características granulométricas variadas, o que pode impactar a resistência do concreto.

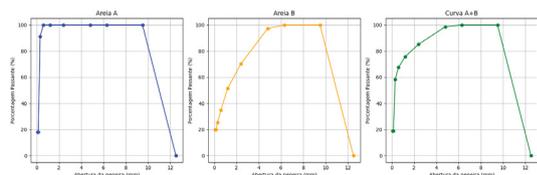


Figura 1. Curvas granulométricas individuais de dois tipos diferentes de areias e a curva composta

Fonte: O autor (2023)

2) *Processamento dos dados*: Para o processamento dos dados, foram aplicadas as seguintes técnicas:

- **Anonimização de dados empresariais**: No contexto deste estudo, os dados usados foram fornecidos por uma empresa e continham informações sensíveis que necessitavam de anonimização para garantir a confidencialidade dos detalhes de negócios e a conformidade com as regulamentações de proteção de dados. A anonimização é uma técnica de tratamento de dados que remove ou modifica informações que podem ser usadas para identificar fontes específicas ou elementos sensíveis dentro de um conjunto de dados, tornando impossível a ligação de informações específicas à sua origem. Isso inclui a remoção ou modificação de detalhes como identificadores de lote de produção, nomes de fornecedores, códigos de produtos e outras informações que poderiam ser usadas para rastrear os dados até sua fonte original.
- **Exclusão de valores nulos**: Uma etapa crítica na preparação dos dados é o tratamento de valores ausentes ou nulos. Valores nulos em um conjunto de dados podem ocorrer por várias razões, tais como erros na coleta de dados, falhas durante a transferência de dados ou simplesmente porque a informação não estava disponível ou não se aplica em alguns casos. Quando os dados nulos não são devidamente tratados, podem resultar em viés ou imprecisão na análise e nas conclusões extraídas dos dados. Portanto, a exclusão de valores nulos é uma abordagem comum para lidar com esses dados.
- **Exclusão de outliers**: Essa etapa foi realizada para garantir que os dados utilizados no treinamento do modelo sejam confiáveis e não estejam distorcidos por valores discrepantes. A técnica utilizada para a exclusão de outliers é a técnica dos quartis. Os outliers foram identificados e removidos da seguinte maneira:
 - Os valores abaixo do primeiro quartil menos 1,5 vezes o intervalo interquartil ($Q1 - 1,5 * IQR$) foram considerados outliers e excluídos do conjunto de dados.
 - Os valores acima do terceiro quartil mais 1,5 vezes o intervalo interquartil ($Q3 + 1,5 * IQR$) também foram considerados outliers e removidos.
- **Engenharia de recursos (Feature Engineering)**: Durante a preparação dos dados, várias técnicas de engenharia de recursos foram aplicadas para melhorar a qualidade dos dados e torná-los adequados para o treinamento do modelo. Algumas das transformações de recursos realizadas incluem:
 - **Cálculo do teor de argamassa**: O teor de argamassa foi calculado para cada amostra como a proporção da quantidade de finos (que inclui areia, cimento e finos) em relação ao volume total (que inclui britas, areia, cimento e finos).

$$K\% = \frac{\text{Quantidade de finos} + \text{Quantidade de areias}}{\text{Quantidade total de todos os materiais}}$$

- **Cálculo do crescimento da resistência do cimento:** O crescimento da resistência do cimento representa a evolução da resistência do cimento ao longo do tempo, especialmente nas idades de 7 e 28 dias, que são marcos importantes na avaliação da qualidade do concreto. Essas medidas de crescimento da resistência aos 7 e 28 dias são essenciais para avaliar a qualidade e o desempenho do concreto em diferentes estágios de cura e maturação.

$$\text{Crescimento (\%)} = \frac{R28 - R7}{R28}$$

Onde R28 representa a resistência à compressão aos 28 dias e R7 representa a resistência à compressão aos 7 dias.

- **Cálculo da relação a/c:** A relação água/cimento (a/c) foi calculada para cada amostra. Essa relação é importante na determinação da resistência do concreto. Ela foi calculada usando a fórmula:

$$\text{Relação a/c} = \frac{\text{Quantidade de água}}{\text{Quantidade de cimento}}$$

Essa etapa de pré-processamento foi essencial para garantir a qualidade dos dados antes do treinamento do modelo.

- **Normalização:** Os dados podem ser normalizados para garantir que todas as variáveis tenham a mesma escala. A normalização foi feita utilizando a fórmula:

$$x^* = \frac{(x - \min)}{(\max - \min)}$$

Onde x^* é o valor normalizado, x é o valor da variável, \min é o valor mínimo e \max é o valor máximo.

3) **Seleção de Variáveis:** A escolha cuidadosa das variáveis para análise foi orientada por duas fontes fundamentais: a revisão da literatura especializada e o aconselhamento de especialistas na área de concreto e cimento. A revisão da literatura forneceu uma base sólida ao identificar características frequentemente destacadas como cruciais em estudos anteriores. Complementarmente, a experiência valiosa e o conhecimento dos especialistas contribuíram para uma abordagem mais holística, considerando nuances específicas do setor. Essa combinação estratégica de informações possibilitou a seleção criteriosa de características reconhecidas como relevantes, promovendo, assim, uma abordagem robusta na análise de variáveis.

As granulometrias das areias e britas, juntamente com a finura do cimento, emergem como escolhas criteriosas, respaldadas por suas notáveis influências na resistência à compressão do concreto. O tamanho das partículas de cimento afeta diretamente a velocidade da cinética de hidratação, enquanto tamanhos menores de agregados resultam em uma maior demanda de água, impactando a resistência do concreto. Além desses fatores, as quantidades reais e teóricas de cada material também desempenham papéis fundamentais. A quantidade de agregados, cimento e aditivo influencia diretamente propriedades como resistência à compressão, trabalhabilidade

e tempo de pega [11]. A resistência intrínseca do cimento também é crucial nesse contexto.

4) **Técnicas de Machine Learning:** As técnicas de ML utilizadas para o treinamento do modelo de previsão da resistência à compressão do concreto são descritas abaixo. Todas as informações dos hiperparâmetros e funcionamento dos modelos foram tiradas na documentação das bibliotecas *Scikit-learn* *scikit-learn*, *XGBoost* [23] e *InterpretML* [24].

a) **Random Forest (RF):** O algoritmo *Random Forest* é uma técnica baseada em um conjunto de árvores de decisão. Cada árvore é treinada em uma amostra aleatória dos dados de treinamento e gera uma previsão individual. A previsão final é obtida através da combinação das previsões de todas as árvores, seja pela média ou pela escolha da maioria, resultando em um modelo robusto e menos propenso a *overfitting*. Os hiperparâmetros que foram ajustados e otimizados para o *Random Forest* podem ser encontrados na Tabela I.

Tabela I
PARÂMETROS IMPORTANTES DO RANDOM FOREST

Parâmetro	Descrição
n_estimators	Número de árvores no conjunto
max_features	Número máximo de características consideradas em cada divisão
max_depth	Profundidade máxima de cada árvore
min_samples_split	Número mínimo de amostras necessárias para realizar uma divisão em um nó
min_samples_leaf	Número mínimo de amostras em cada folha da árvore

Fonte: O autor (2023)

b) **XGBoost (XGB):** O algoritmo *XGBoost* é uma implementação otimizada do algoritmo de aumento de gradiente que tem como objetivo ser altamente eficiente, flexível e portátil. Ele consegue realizar a otimização tanto para problemas de regressão quanto para classificação. Os hiperparâmetros a serem otimizados podem ser encontrados na Tabela II.

c) **Redes Neurais Artificiais (RNA):** As redes neurais artificiais são modelos matemáticos inspirados no funcionamento do cérebro humano. Elas são compostas por um conjunto de neurônios interconectados, onde cada neurônio recebe valores de entrada, processa as informações ponderando as entradas por meio de pesos associados e, em seguida, aplica uma função de ativação para produzir uma saída. Os pesos desempenham um papel crucial nesse processo, pois determinam a influência relativa de cada variável de entrada na saída do neurônio. Uma função de ativação comum, usada para introduzir não-linearidade nas redes neurais, é a função ReLU (*Rectified Linear Unit*), que ativa o neurônio se a soma ponderada das entradas for maior que zero; caso contrário, produz uma saída igual a zero. Esse processo de ajuste de pesos é repetido em várias camadas da rede, permitindo que as redes neurais aprendam representações complexas de dados para modelos de regressão.

Tabela II
PARÂMETROS IMPORTANTES DO XGBOOST

Parâmetro	Descrição
max_depth	A profundidade máxima permitida para uma árvore de decisão.
eta	A taxa de aprendizado controla o tamanho dos passos de atualização dos pesos durante cada iteração do treinamento.
gamma	O parâmetro de penalização é usado para controlar a complexidade das árvores adicionando uma penalização ao adicionar uma nova folha à árvore.
subsample	A fração de amostras usadas para treinar cada árvore do XGBoost. Isso introduz aleatoriedade e ajuda a evitar overfitting.
colsample_bytree	A fração de características usadas para treinar cada árvore. Isso também ajuda a reduzir a correlação entre as árvores e melhora o desempenho.
lambda	A regularização L2 é um termo de penalização aplicado aos pesos das folhas das árvores, ajudando a evitar o overfitting.
booster	O tipo de impulsador a ser usado, que é 'gbtree' para indicar que árvores gradient boosting serão usadas no XGBoost.

Fonte: O autor (2023)

Os hiperparâmetros utilizados na otimização estão apresentados na Tabela III.

Tabela III
HIPERPARÂMETROS DAS REDES NEURAIS ARTIFICIAIS

Hiperparâmetro	Descrição
num_units	Número de neurônios em cada camada escondida
learning_rate	Taxa de aprendizado para ajustar os pesos
dropout_rate	Fração de unidades ocultas a serem deixadas de fora durante o treinamento
num_layers	Número de camadas ocultas na rede neural

Fonte: O autor (2023)

d) *Explainable Boosting Machine (EBM)*: O *Explainable Boosting Machine* é um modelo de aprendizado de máquina que combina interpretabilidade com desempenho preditivo. Para configurar um EBM eficaz na tarefa de previsão da resistência à compressão do concreto, é fundamental ajustar

seus hiperparâmetros. Na Tabela IV são apresentados os hiperparâmetros essenciais utilizados na otimização.

Tabela IV
HIPERPARÂMETROS DO EXPLAINABLE BOOSTING MACHINE

Hiperparâmetro	Descrição
learning_rate	A taxa de aprendizado, controlando o tamanho dos passos de atualização dos pesos durante o treinamento do EBM.
max_bins	O número máximo de bins para discretizar características numéricas, afetando a complexidade do modelo.
max_interaction_bins	O número máximo de bins para discretização de características em interações, influenciando a granularidade das interações identificadas.
min_samples_leaf	O número mínimo de amostras necessário em uma folha da árvore de decisão utilizada no EBM.
outer_bags	O número de bags externos utilizados para treinamento do modelo EBM, afetando a estabilidade e confiabilidade das previsões.

Fonte: O autor (2023)

5) *Otimização de Hiperparâmetros*: Para otimizar os hiperparâmetros das técnicas de *Random Forest*, *Redes Neurais Artificiais*, *XGBoost* e *Explainable Boosting Machine*, foram empregados os algoritmos *Particle Swarm Optimization* (PSO) e o *framework* Optuna. O Optuna é uma ferramenta especializada em otimização de hiperparâmetros que incorpora técnicas avançadas, como busca sequencial e otimização bayesiana, para efetivamente descobrir a combinação ideal de hiperparâmetros.

Ao contrário das abordagens convencionais, como busca em grade (*GridSearch*) e busca aleatória em grade (*Randomized-GridSearch*), o Optuna, através das suas técnicas avançadas, explora o espaço de hiperparâmetros de uma forma mais rápida e eficaz, adaptando-se com base no desempenho observado de configurações anteriores.

O objetivo desses métodos de otimização é encontrar configurações que maximizem o desempenho dos modelos com base em uma métrica específica, como o RMSE (Raiz do Erro Médio Quadrático). A principal métrica considerada durante a otimização é o RMSE, que calcula a raiz quadrada do erro médio quadrático entre as previsões do modelo e os valores reais. Minimizando o RMSE, busca-se um modelo que forneça previsões mais precisas em relação aos resultados reais.

Os espaço de busca dos hiperparâmetros de cada modelo otimizado são apresentados na Tabela V. Para garantir que a otimização seja reproduzível, foi utilizado o parâmetro `random_state` igual a 86905.

6) *Medidas de avaliação*: Foram utilizadas as seguintes métricas para avaliar a qualidade dos modelos de predição:

Tabela V
LIMITES DOS HIPERPARÂMETROS

Modelo	Parâmetro	Limite Inferior	Limite Superior
RF	n_estimators	50	150
	max_depth	1	100
	min_samples_split	0,0001	0,1
	min_samples_leaf	0,00001	0,01
	max_features	0,1	0,9
XGB	max_depth	50	150
	eta	0,0001	0,5
	gamma	16	80
	subsample	0,5	0,9
	colsample_bytree	0,5	0,99
	lambda	1	10
RNA	num_units	16	256
	learning_rate	0.001	0.1
	dropout_rate	0,1	0,9
	num_layers	2	2
EBM	learning_rate	0,0001	2
	max_bins	11	12
	max_interaction_bins	200	300
	min_samples_leaf	8	10
	outer_bags	8	10

- MAPE (*Mean Absolute Percentage Error*): calculado como a média percentual dos erros absolutos em relação aos valores reais. A fórmula é dada por:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (1)$$

Onde n é o número de amostras, y_i é o valor real e \hat{y}_i é o valor predito.

- RMSE (*Root Mean Squared Error*): calculado como a raiz quadrada do erro quadrático médio e mede a dispersão dos erros. A fórmula é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

- R^2 (*Coefficient of Determination*): é uma medida de quão bem o modelo se ajusta aos dados e varia de 0 a 1. Um valor mais próximo de 1 indica um melhor ajuste. A fórmula é dada por:

$$R = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Onde \bar{y} é a média dos valores reais.

7) *Avaliação dos Resultados*: A avaliação dos resultados foi realizada utilizando técnicas de *holdout*, em que o conjunto de dados é dividido em um conjunto de treinamento e um conjunto de teste. Neste estudo, a divisão adotada foi de 70% para treinamento e 30% para teste, de forma a avaliar o desempenho dos modelos em dados não vistos durante o treinamento.

C. Tecnologias

O desenvolvimento do projeto foi realizado utilizando as seguintes tecnologias:

- scikit-learn (versão 1.3.1): O scikit-learn é uma biblioteca amplamente utilizada para tarefas de aprendizado de máquina em Python. Ela fornece uma ampla gama de algoritmos de classificação, regressão, agrupamento e pré-processamento de dados, bem como ferramentas para avaliação de modelos, seleção de hiperparâmetros e validação cruzada.
- xgboost (versão 2.0.0): O *xgboost* é uma biblioteca de aprendizado de máquina que se destaca em tarefas de classificação e regressão. É conhecida por sua eficiência e desempenho superior, tornando-a uma escolha popular em competições de ciência de dados. O XGBoost implementa uma versão otimizada do algoritmo de gradient boosting, o que o torna adequado para problemas complexos de aprendizado de máquina.
- interpret (versão 0.4.4): O *interpret* é uma biblioteca que oferece métodos para explicar modelos de aprendizado de máquina, tornando os resultados do modelo mais interpretáveis. Ele fornece recursos para interpretar as previsões de modelos e entender como os recursos afetam as saídas do modelo. Isso é crucial para entender o raciocínio por trás das decisões do modelo e comunicar essas explicações de forma eficaz.
- pyswarm (versão 0.6): A biblioteca contém um algoritmo chamado PSO, que é uma técnica de otimização inspirada no comportamento de enxames de pássaros e cardumes de peixes. O PSO é usado para encontrar soluções aproximadas para problemas de otimização em espaços de alta dimensionalidade. É especialmente útil em otimização global e problemas complexos
- optuna (versão 3.3.0): O *optuna* é uma biblioteca de otimização de hiperparâmetros para algoritmos de aprendizado de máquina. Ela permite a busca eficiente e automática da melhor configuração de hiperparâmetros para um modelo, economizando tempo e recursos computacionais caso isso fosse feito usando o GridSearch do scikit-learn.
- plotly (versão 5.17.0): O *plotly* é uma biblioteca Python que fornece uma maneira elegante de criar gráficos interativos e visualizações de dados. Ele é amplamente usado em ciência de dados, análise estatística e visualização de dados devido à sua facilidade de uso e capacidade de criar gráficos interativos de alta qualidade.
- numpy (versão 1.25.2): O *numpy* é uma biblioteca fundamental para computação científica em Python. Ela fornece suporte para arrays multidimensionais e uma ampla variedade de funções matemáticas para manipulação eficiente de dados numéricos.
- pandas (versão 2.1.1): O *pandas* é uma biblioteca de análise de dados que fornece estruturas de dados flexíveis e eficientes, como DataFrames, para manipulação e análise de dados tabulares. Ele oferece uma variedade de funcionalidades para importar, manipular, limpar e

explorar dados.

- matplotlib (versão 3.8.0): O matplotlib é uma biblioteca para criação de visualizações estáticas, animadas e interativas em Python. Ele fornece uma API simples e poderosa para a criação de gráficos como de dispersão, histogramas, entre outros tipos de visualizações.

II. RESULTADOS E DISCUSSÕES

Após a conclusão do processo de otimização, as configurações finais de cada modelo foram ajustadas de acordo com os limites definidos. A seguir, são apresentadas as configurações otimizadas para cada modelo, conforme especificado na Tabela VI.

Tabela VI
CONFIGURAÇÃO DOS MODELOS COM HIPERPARÂMETROS OTIMIZADOS

Modelo	Hiperparâmetro	Valor otimizado
RF	n_estimators	107
	max_depth	98
	min_samples_split	1e-04
	min_samples_leaf	1e-05
	max_features	0,8965
XGB	max_depth	92
	eta	0,0529
	gamma	59,5832
	subsample	0,7674
	colsample_bytree	0,8252
	lambda	4,0540
RNA	num_units	128
	learning_rate	0,0012
	dropout_rate	0,1279
	num_layers	2
EBM	learning_rate	1,5604
	max_bins	12
	max_interaction_bins	274
	min_samples_leaf	8
	outer_bags	8

Essas configurações otimizadas representam os valores ideais para os hiperparâmetros de cada modelo, obtidos após o processo de busca e ajuste. Elas estão prontas para serem utilizadas na construção dos modelos finais de previsão da resistência à compressão do concreto.

A. Medida de qualidade dos modelos

A Tabela VII e Figura 2 apresenta o desempenho dos quatro modelos de previsão. As métricas incluídas são o coeficiente de determinação, RMSE e o MAPE. Essas métricas são indicativas do quão bem cada modelo se ajusta aos dados de teste. Modelos com valores mais altos de R^2 e valores mais baixos de RMSE e MAPE são considerados mais precisos em suas previsões.

O desempenho sólido desses modelos com R^2 próximos a 0.8 sugere que eles são capazes de fazer previsões precisas, mas também ressalta a importância da consideração da capacidade de generalização. Um modelo com alta capacidade de generalização é capaz de fazer previsões precisas não apenas nos dados de treinamento, mas também em novos dados não vistos.

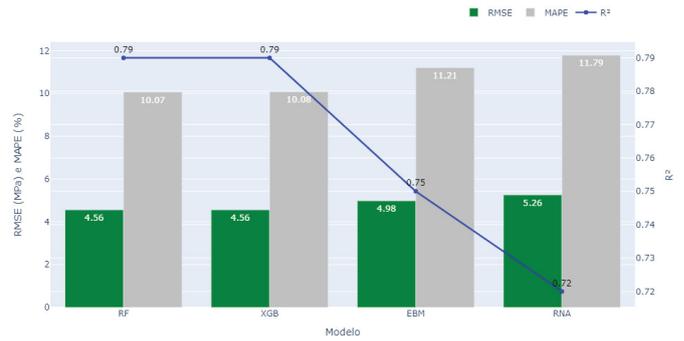


Figura 2. Gráfico com as métricas de avaliações dos modelos treinados
Fonte: O autor (2023)

Tabela VII
DESEMPENHO DOS MODELOS DE PREVISÃO

Modelo	R²	RMSE	MAPE (%)
RF	0,79	4,56	10,07
XGB	0,79	4,56	10,08
EBM	0,75	4,98	11,21
RNA	0,72	5,26	11,79

O MAPE, que representa o erro percentual absoluto médio, varia entre 10,07% e 11,79 % para os modelos, o que significa que as previsões têm uma diferença média de cerca de 10 % a 11 % em relação aos valores reais.

Uma maneira eficaz de avaliar o desempenho dos modelos de previsão é por meio da visualização dos valores reais e das previsões geradas por cada um deles. A Figura 3 compara os valores reais e previstos dos quatro modelos: *Random Forest*, *XGBoost*, *Explainable Boosting Machine* e Rede Neural Artificial.

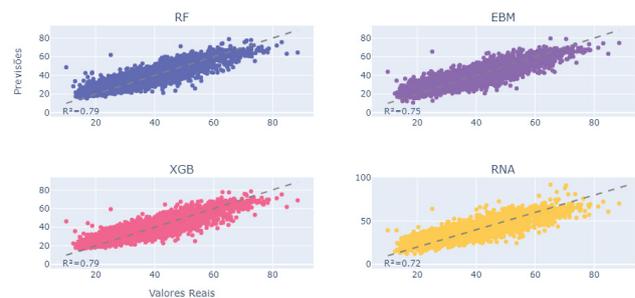


Figura 3. Gráfico com valores reais vs previstos dos modelos treinados
Fonte: O autor (2023)

Neste gráfico, cada modelo é representado por uma cor distinta para facilitar a identificação das previsões de cada um. Além disso, no gráfico, existe uma diagonal tracejada que representa a linha onde $x = y$. Idealmente, as previsões perfeitas deveriam estar exatamente sobre essa linha, indicando que as previsões correspondem exatamente aos valores reais.

Portanto, quanto mais próxima a distribuição dos pontos estiver da diagonal tracejada, melhor será o desempenho do modelo.

Os modelos EBM e RNA também mostram um desempenho razoável, embora haja uma dispersão um pouco maior entre as previsões e os valores reais. Isso sugere que esses modelos ainda são capazes de fazer previsões úteis, mas com um nível ligeiramente maior de variação.

As Figuras 4 e 5 ilustram o potencial do Explainable Boosting Machine em explicar tanto localmente quanto globalmente as variáveis em relação à resistência à compressão do concreto. Enquanto métricas de desempenho como o coeficiente de determinação podem fornecer uma visão geral do ajuste do modelo, esses gráficos de interpretabilidade permitem uma exploração mais profunda das relações entre as variáveis independentes e a variável de resposta.

A análise global oferece uma visão abrangente das tendências e padrões que emergem no conjunto de dados como um todo. Isso permite identificar relações e interações entre as variáveis em um contexto mais amplo, revelando insights valiosos sobre o comportamento do concreto em diferentes cenários.

Por outro lado, a análise local proporcionada pelo EBM permite identificar como pequenas alterações nas variáveis afetam as previsões em nível individual. Isso é particularmente importante ao avaliar o impacto de variáveis específicas em situações ou casos particulares. Com essa abordagem, é possível identificar quais variáveis têm maior influência em cenários específicos, o que é fundamental para a tomada de decisões.

A Figura 4 apresenta a visualização global das principais características que influenciam o modelo treinado. Dentre os parâmetros avaliados, destacam-se elementos cruciais, como a resistência à compressão desejada do concreto (fck), a granulometria dos agregados e a finura do cimento. Estes parâmetros se destacam no gráfico, corroborando sua relevância, em consonância com as evidências encontradas na literatura.

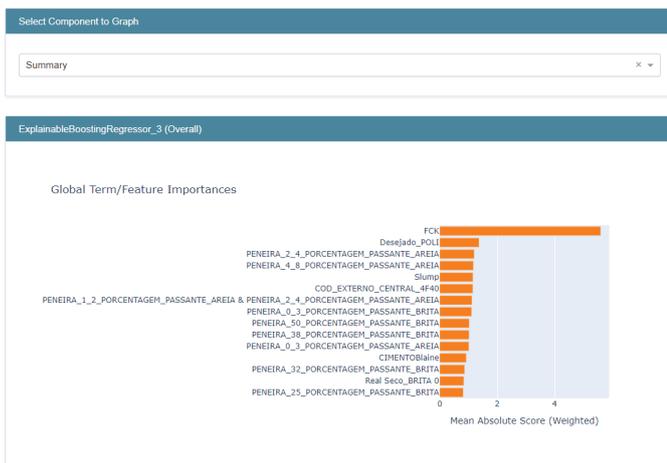


Figura 4. Visualização global da importância das características
Fonte: O autor (2023)

A interpretação local, Figura 5, ao contrário da explicação global que aborda os fatores mais importantes de forma geral, concentra-se em analisar como determinados parâmetros

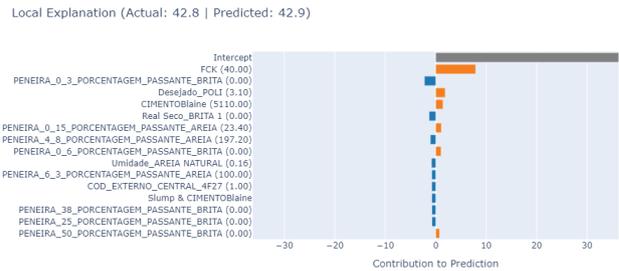


Figura 5. Visualização local de uma amostra com as influências das variáveis mais importantes
Fonte: O autor (2023)

específicos afetam diretamente o modelo treinado para uma amostra específica de dados.

Primeiramente, o valor da resistência à compressão desejada do concreto (fck) tem um impacto direto nas previsões do modelo. Um fck mais elevado geralmente resultará em uma maior resistência do concreto já que as proporções dos materiais já foram desenvolvidos para que o concreto atinja aquela resistência quando for produzido.

Outro fator importante é a finura do cimento, nesse caso medido pelo método de Blaine. Conforme a Figura 5, a finura Blaine do cimento afeta diretamente o modelo, isto é, quanto maior o valor de Blaine do cimento, ou seja mais fino, maior será a resistência.

Além disso, a umidade da areia natural também desempenha um papel significativo. A quantidade de água presente na areia pode afetar a quantidade de água adicionada ao concreto, o que é crítico para a sua aplicação prática. Um teor de umidade mais alto ou mais baixo na areia pode alterar o valor da relação a/c e, conseqüentemente, influenciar diretamente na resistência à compressão.

Por último, a quantidade das britas passante na peneira de 0,3 mm também influencia as previsões do modelo. Isso está relacionado à granulometria dos agregados e pode afetar a textura e a demanda de água do concreto.

Assim, ao analisar a interpretação local, pode-se observar como cada um desses fatores específicos afeta as previsões do modelo em situações individuais, fornecendo insights valiosos para otimizar o desempenho do concreto em condições específicas de produção.

B. Discussões

Em síntese, esta pesquisa concluiu o processo de otimização dos hiperparâmetros de quatro modelos de aprendizado de máquina: *Random Forest*, *XGBoost*, *Redes Neurais Artificiais* e *Explainable Boosting Machines*, com o objetivo de aprimorar sua capacidade de prever a resistência à compressão do concreto. Após um árduo procedimento de busca e ajuste, identificaram-se os valores ideais para os hiperparâmetros de cada modelo, os quais estão prontos para serem aplicados no treinamento dos modelos finais.

Os resultados obtidos evidenciam um desempenho sólido, com coeficientes de determinação próximos a 0,8, indicando que os modelos são capazes de realizar previsões precisas. Esta pesquisa, no entanto, foi além da simples avaliação do R^2 , incorporando métricas adicionais, tais como o RMSE e o MAPE.

O Erro Percentual Absoluto Médio para os modelos variou de 10% a 11%, indicando que as previsões, em média, diferiram em até 11% dos valores reais. Além disso, a Raiz do Erro Médio Quadrático variou de 4,5 a 5,27, o que reflete a magnitude média dos erros entre as previsões e os valores reais. Esses resultados sugerem que as previsões obtidas com os modelos são robustas e confiáveis, o que é essencial para a tomada de decisões acertivas em aplicações práticas.

Para efeito de comparação, um estudo publicado no *Construction Materials* [12] relata valores de RMSE na faixa de 4,3 a 9,2 MPa e um coeficiente de determinação variando de 0,9 a 0,6. Os resultados do presente estudo se alinham bem com os do estudo de referência, indicando que os modelos otimizados são competitivos em termos de precisão de previsão.

Além disso, a interpretabilidade do modelo proveniente do *Explainable Boosting Machine*, desvendou descobertas significativas sobre as variáveis que mais influenciam a resistência à compressão do concreto. Tanto a análise global quanto a interpretação local destacaram a importância de parâmetros como f_{ck} , a finura do cimento, a umidade da areia natural e a granulometria dos agregados. Essas descobertas corroboram a literatura e oferecem informações práticas para otimizar o design do concreto em diversas condições de produção.

Por fim, os modelos otimizados desta pesquisa representam uma ferramenta inestimável para a indústria de construção, permitindo prever com precisão a resistência à compressão do concreto e, ao mesmo tempo, compreender as relações entre os diversos parâmetros envolvidos. Essa abordagem contribui para a melhoria da qualidade e eficiência do setor da construção civil, com impactos positivos tanto do ponto de vista técnico quanto econômico. O conhecimento gerado por este estudo pode servir de base para futuras pesquisas e avanços na área da construção de materiais e engenharia civil.

C. Trabalhos futuros

Para trabalhos futuros, há um amplo espaço para aprimorar o modelo de previsão da resistência do concreto. À medida que a demanda por concretos mais sustentáveis e economicamente viáveis continua a crescer, torna-se essencial também incorporar a curva granulométrica dos materiais finos como parte integrante do modelo preditivo. Isso permitirá que o modelo atenda às expectativas do mercado, proporcionando soluções que otimizem o empacotamento da mistura, reduzam a quantidade de cimento e, assim, contribuam para a redução da pegada de CO_2 , ao mesmo tempo em que oferecem economias de custos significativas. Além disso, considerar a composição mineralógica das britas e areias, bem como a incorporação de diferentes tipos de cimento, para além do CIIIF ou CIIIE, pode tornar o modelo mais genérico e aplicável a uma variedade

mais ampla de situações. Esses aprimoramentos permitirão uma previsão mais precisa e abrangente da resistência do concreto, atendendo a diversas necessidades da indústria da construção.

REFERÊNCIAS

- [1] AMERICAN CONCRETE INSTITUTE (ACI), "Building code requirements for structural concrete." Norma Técnica, 2022.
- [2] AMERICAN SOCIETY FOR TESTING AND MATERIALS (ASTM) International, "Standard test method for compressive strength of cylindrical concrete specimens." Norma Técnica, 2021.
- [3] BRITISH STANDARDS INSTITUTION (BSI), "Concrete – part 1: Specification, performance, production, and conformity." Norma Técnica, 2016.
- [4] EUROPEAN COMMITTEE FOR STANDARDIZATION (CEN), "Testing hardened concrete – part 3: Compressive strength of test specimens." Norma Técnica, 2019.
- [5] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO), "Testing of concrete – part 1: Sampling of fresh concrete." Norma Técnica, 2004.
- [6] S. H. Kosmatka, B. Kerkhoff, and W. C. Panarese, *Design and Control of Concrete Mixtures*. United States: Portland Cement Association, 14 ed., 2002.
- [7] M. S. Mamlouk and J. P. Zaniewski, *Materials for Civil and Construction Engineers*. United States: Pearson, 4 ed., 2017.
- [8] P. K. Mehta and P. J. M. Monteiro, *Concrete: Microstructure, Properties, and Materials*. Berkeley, California: McGraw-Hill, 3 ed., 2013. Department of Civil and Environmental Engineering, University of California at Berkeley.
- [9] M. N. Amin, W. Ahmad, K. Khan, and A. F. Deifalla, "Optimizing compressive strength prediction models for rice husk ash concrete with evolutionary machine intelligence techniques," *Case Studies in Construction Materials*, vol. 18, p. e02102, 2023.
- [10] M. Jibril, M. Zayyan, S. I. Malami, A. Usman, B. A. Salami, A. Rotimi, and S. Abba, "Implementation of nonlinear computing models and classical regression for predicting compressive strength of high-performance concrete," *Applications in Engineering Science*, vol. 15, p. 100133, 2023.
- [11] M. Kumar and D. S. T.N., "Genetic programming based compressive strength prediction model for green concrete," *Materials Today: Proceedings*, 2023.
- [12] G. Liu and B. Sun, "Concrete compressive strength prediction using an explainable boosting machine model," *Case Studies in Construction Materials*, vol. 18, p. e01845, 2023.
- [13] W. Z. Taffese and L. Espinosa-Leal, "Multitarget regression models for predicting compressive strength and chloride resistance of concrete," *Journal of Building Engineering*, vol. 72, p. 106523, 2023.
- [14] J. Rahman, K. S. Ahmed, N. I. Khan, K. Islam, and S. Mangalathu, "Data-driven shear strength prediction of steel fiber reinforced concrete beams using machine learning approach," *Engineering Structures*, vol. 233, p. 111743, 2021.
- [15] X. Liu, H. Jing, and P. Yan, "Statistical analysis and unified model for predicting the compressive strength of coarse recycled aggregate opc concrete," *Journal of Cleaner Production*, vol. 400, p. 136660, 2023.
- [16] H. Imran, N. Al-Abdaly, M. Shamsa, A. Shatnawi, M. Ibrahim, and K. Ostrowski, "Development of prediction model to predict the compressive strength of eco-friendly concrete using multivariate polynomial regression combined with stepwise method," *Materials*, vol. 15, no. 1, p. 317, 2022.
- [17] M. T. Ribeiro, S. Singh, and C. Guestrin, "Anchors: High-precision model-agnostic explanations," in *Proceedings of the 32nd AAAI Conference on Artificial Intelligence*, pp. 1527–1535, 2018.
- [18] C. Molnar, "Interpretable machine learning," 2020.
- [19] F. Doshi-Velez and B. Kim, "Towards a rigorous science of interpretable machine learning," *arXiv preprint arXiv:1702.08608*, 2017.
- [20] Z. C. Lipton, "The mythos of model interpretability," in *Proceedings of the 2016 ICML Workshop on Human Interpretability in Machine Learning*, pp. 1–6, 2016.
- [21] H. Nori, S. Jenkins, P. Koch, and R. Caruana, "Interpretml: A unified framework for machine learning interpretability," *Microsoft Corporation*, 2020.
- [22] A. Neville, *Concrete Technology*. Pearson Education Limited, 2011.
- [23] XGBOOST, "Xgboost documentation." <https://xgboost.readthedocs.io/en/stable/>, 2023. Acesso em 04 de agosto de 2023.

[24] INTERPRET, “Explainable boosting machine (ebm) - interpret documentation.” <https://interpret.ml/docs/ebm.html>, 2023. Acesso em 26 de maio de 2023.

APÊNDICE
APÊNDICE A

Tabela VIII: Atributos da Base de Dados

Atributo	Tipo [unidade]	Descrição
R28 (Variável Dependente)	Númerica medida [MPa]	Resistência à compressão aos 28 dias do concreto real
FCK	Númerica especificada [MPa]	Resistência à compressão aos 28 dias do concreto no projeto
<i>PENEIRA_FUNDO_PORCENTAGEM_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na última peneira (curva granulométrica composta)
<i>PENEIRA_0_075_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,075 mm (curva granulométrica composta)
<i>PENEIRA_0_15_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,15 mm (curva granulométrica composta)
<i>PENEIRA_0_3_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,3 mm (curva granulométrica composta)
<i>PENEIRA_0_6_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,6 mm (curva granulométrica composta)
<i>PENEIRA_1_2_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 1,2 mm (curva granulométrica composta)
<i>PENEIRA_2_4_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 2,4 mm (curva granulométrica composta)
<i>PENEIRA_4_8_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 4,8 mm (curva granulométrica composta)
<i>PENEIRA_6_3_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 6,3 mm (curva granulométrica composta)
<i>PENEIRA_9_5_PORCENTAGEM_PASSANTE_AREIAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 9,5 mm (curva granulométrica composta)
<i>PENEIRA_FUNDO_PORCENTAGEM_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na última peneira (curva granulométrica composta)
<i>PENEIRA_0_075_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,075 mm (curva granulométrica composta)
<i>PENEIRA_0_15_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,15 mm (curva granulométrica composta)

Continua na próxima página

Tabela VIII – Continuação da página anterior

Atributo	Tipo [unidade]	Descrição
<i>PENEIRA_0_3_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,3 mm (curva granulométrica composta)
<i>PENEIRA_0_6_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 0,6 mm (curva granulométrica composta)
<i>PENEIRA_1_2_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 1,2 mm (curva granulométrica composta)
<i>PENEIRA_2_4_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 2,4 mm (curva granulométrica composta)
<i>PENEIRA_4_8_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 4,8 mm (curva granulométrica composta)
<i>PENEIRA_6_3_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 6,3 mm (curva granulométrica composta)
<i>PENEIRA_9_5_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 9,5 mm (curva granulométrica composta)
<i>PENEIRA_12_5_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 12,5 mm (curva granulométrica composta)
<i>PENEIRA_19_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 19 mm (curva granulométrica composta)
<i>PENEIRA_25_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 25 mm (curva granulométrica composta)
<i>PENEIRA_32_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 32 mm (curva granulométrica composta)
<i>PENEIRA_38_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 38 mm (curva granulométrica composta)
<i>PENEIRA_50_PORCENTAGEM_PASSANTE_BRITAS</i>	Númerica calculada [%]	Porcentagem passante na peneira 50 mm (curva granulométrica composta)
<i>RealSeco_AREIANATURAL</i>	Númerica medida [kg]	Quantidade real da areia natural sem umidade
<i>RealSeco_AREIAARTIFICIAL</i>	Númerica medida [kg]	Quantidade real da areia artificial sem umidade
<i>DesejadoSeco_AREIANATURAL</i>	Númerica especificada [kg]	Quantidade teórica da areia natural sem umidade
<i>DesejadoSeco_AREIAARTIFICIAL</i>	Númerica especificada [kg]	Quantidade teórica da areia artificial sem umidade
<i>Umidade_AREIANATURAL</i>	Númerica medida [%]	Umidade da areia natural
<i>Umidade_AREIAARTIFICIAL</i>	Númerica especificada [%]	Umidade da areia artificial
<i>RealSeco_BRITA_0</i>	Númerica medida [kg]	Quantidade real de Brita 0 sem umidade

Continua na próxima página

Tabela VIII – Continuação da página anterior

Atributo	Tipo [unidade]	Descrição
<i>RealSeco_BRITA_1</i>	Númerica medida [kg]	Quantidade real de Brita 1 sem umidade
<i>DesejadoSeco_BRITA_0</i>	Númerica especificada [kg]	Quantidade teórica de Brita 0 sem umidade
<i>DesejadoSeco_BRITA_1</i>	Númerica especificada [kg]	Quantidade teórica de Brita 1 sem umidade
<i>Umidade_BRITA_0</i>	Númerica medida [%]	Umidade da Brita 0
<i>Umidade_BRITA_1</i>	Númerica especificada [%]	Umidade da Brita 1
<i>RealSeco_CIMENTO</i>	Númerica medida [kg]	Quantidade real de cimento
<i>DesejadoSeco_CIMENTO</i>	Númerica especificada [kg]	Quantidade teórica de cimento
<i>RealSeco_ADITIVO</i>	Númerica medida [kg]	Quantidade real de aditivo
<i>DesejadoSeco_ADITIVO</i>	Númerica especificada [kg]	Quantidade teórica de aditivo
<i>RealSeco_AGUA</i>	Númerica medida [kg]	Quantidade real de água
<i>DesejadoSeco_AGUA</i>	Númerica especificada [kg]	Quantidade teórica de água
<i>Slump</i>	Númerica especificada [mm]	Abatimento do concreto
<i>CIMENTOBlaine</i>	Númerica medida [cm ² /g]	Finura do cimento pelo método de Blaine
<i>CIMENTOR28</i>	Númerica medida [MPa]	Resistência à compressão aos 28 dias do cimento expedido
<i>CIMENTO_CRESCIMENTO</i>	Númerica calculada [%]	Crescimento da resistência à compressão nas idades de 7 e 28 dias
<i>k%</i>	Númerica calculada [-]	Teor de argamassa do concreto
<i>ac_real</i>	Númerica calculada [-]	Relação água/cimento real do concreto
<i>ac_terica</i>	Númerica calculada [-]	Relação água/cimento teórica do concreto
<i>TIPO</i>	Catagórica	Tipo do cimento (CPIIF, CPIIE, CPIV)
<i>TIPO_ADITIVO</i>	Catagórica	Tipo de aditivo (MID RANGE, POLIPLASTIFICANTE, SUPERPLASTIFICANTE)
<i>COD_EXTERNO_CENTRAL</i>	Catagórica	Código da central (A, B, C, D, etc.)