Um Estudo Comparativo de Técnicas de Aprendizado de Máquina para a Predição de Temperatura em Regeneradores

Fabrício R. Ferreira * **Lucas A Quaresma** * **Filipe W. Mutz** ** **Leandro C. Resendo** *

* *Instituto Federal do Espírito Santo, ES, (e-mails: frferreira.vix@gmail.com; lucas.quaresma1@gmail.com; leandro@ifes.edu.br).*
** *Universidade Federal do Espírito Santo, ES, (e-mail: filipemtz@gmail.com)*

Abstract: This article examines the application of machine learning models, specifically XGBoost (XGB) and LightGBM (LB), among others, for predicting hot blast stove temperatures in an integrated steel mill. Unlike previous studies, the dataset used in this investigation does not exhibit time series characteristics, complicating the use of algorithms that depend on such features. The dataset, provided by a steel mill in Brazil, underwent an initial feature pre-selection through expert interviews, followed by Principal Component Analysis (PCA). Preprocessing steps included outlier removal using the Interquartile Range (IQR) and missing value imputation with moving averages. The models were evaluated using metrics such as R^2 and RMSE. After hyperparameter tuning via GridSearchCV, LB and XGB demonstrated superior performance across both metrics. The results indicate the significant effectiveness of these models, with LB showing a slight advantage.

Resumo:
Este artigo analisa a aplicação de modelos de aprendizado de máquina, XGBoost (XGB), LightGBM (LB) e outros, na previsão de temperaturas de regeneradores em uma usina siderúrgica integrada. Diferentemente dos trabalhos encontrados na literatura, os dados usados nesta investigação não possuem o comportamento de séries temporais, o que impossibilita o uso de algoritmos especializados que consideram essa característica. Utilizando uma base de dados fornecida por uma siderúrgica no Brasil, inicialmente realizou-se uma pré-seleção de atributos através de entrevistas com especialistas seguida do uso do método de Análise de Componentes Principais (PCA). O pré-processamento incluiu a remoção de outliers usando o Intervalo Interquartil (IRQ) e imputação de valores faltantes com média móvel. Os modelos foram avaliados com métricas como R^2 e RMSE, nas quais, após ajustes de hiperparâmetros via GridSearchCV, o LB e o XGB apresentaram os melhores resultados para ambas as métricas. Os resultados indicam uma eficácia significativa dos modelos, com uma ligeira vantagem do LB.

Keywords: Hot Blast Stove; HBS; random forests; light Gradient Boosted Trees; KNN.
Palavras-chaves: Hot Blast Stove; HBS; random forests; light Gradient Boosted Trees; KNN.

1. INTRODUÇÃO

O processo de fabricação de ferro em um Alto-Forno (AF) é o cerne do processo tradicional de fabricação de aço, representando cerca de 65% do consumo total de energia na indústria siderúrgica Zhou et al. (2019). De acordo com Sun et al. (2020), a produção de aço é responsável por 5% do consumo global de energia e por uma grande parte das emissões globais de carbono. Visando à redução dos custos ligados ao consumo de energia e à diminuição das emissões de CO_2, a indústria siderúrgica tem se empenhado em encontrar soluções inovadoras, novas fontes de energia e otimizações em processos.

Dentre os processos de otimização, destaca-se a reutilização de subprodutos do processo siderúrgico. Para a geração de energia térmica o subproduto gás de alto-forno (BFG, do inglês *Blast Furnace Gas*) ganha destaque por seu volume de produção capacidade calorífica. Durante a produção do aço, o minério de ferro reage com carbono e oxigênio, em alta temperatura dentro do AF, gerando o BFG que é formado principalmente por CO e CO_2. O BFG desempenha um papel crucial na eficiência do processo siderúrgico, sendo reutilizado para reaquecer o ar através de estruturas chamadas de regeneradores (HBS, do inglês *Hot Blast Stoves*). Essa prática não apenas otimiza o uso

⋆ Os autores agradecem ao apoio da FAPES e CAPES (processo 2021-2S6CD, nº FAPES 132/2021) por meio do PDPG (Programa de Desenvolvimento da Pós-Graduação, Parcerias Estratégicas nos Estados).

de recursos, mas também reduz os custos operacionais e as emissões de gases de efeito estufa.

Os regeneradores são essenciais na siderurgia, sendo responsáveis por fornecer ar em altas temperaturas, aproximadamente 1.200°C, necessário para o processo nos Alto-Fornos, para a produção do aço Koyfman et al. (2021). Os regeneradores trabalham em paralelo e em ciclos. Enquanto um regenerador sopra o ar quente para o AF, perdendo calor, o(s) outro(s) são aquecidos. Em geral, são necessários entre 2 a 4, regeneradores trabalhando juntos para manter uma produção constante de aço.

Na Figura 1 representa o processo de operação de dois regeneradores em paralelo, e dividido em duas fases: (a) fase de *on-gas* e (b) fase de *on-blast*. Durante o período *on-gas*, o BFG é queimado para aquecer os tijolos refratários que compõem a estrutura do regenerador. Uma vez devidamente aquecido, durante o período *on-blast*, o ar aquecido no regenerador é fornecido ao alto-forno. Cada ciclo completo é composto por quatro períodos, sendo dois períodos *on-gas* em azul e dois períodos *on-blast* em vermelho Şahin and Morari (2008).

Durante o período de *on-gas*, que ocorre na câmara de combustão conectada diretamente à torre dos regeneradores, denominada domo, é injetada uma mistura de gases compostos por BFG, gás de coqueria (COG), do inglês Coke Gas), gás natural (NG) e ar. Esses gases são utilizados como combustíveis para a gerar calor, aquecer os refratários. No domo do regenerador, são realizadas medições de temperatura que servem como referência para determinar a temperatura interna. Além disso, outras medições são realizadas, e é calculada a temperatura teórica da chama na câmara de combustão. A diferença entre a temperatura registrada no domo e as temperaturas das chamas de combustão fornece um indicador da eficiência do processo de troca térmica entre o gás em alta temperatura e os tijolos refratários. Como resultado, o sistema de gerenciamento de controle monitora e regula a temperatura do regenerador com base nessas informações e expectativas teóricas para a temperatura futura do domo.

O consumo de gases durante o período de queima e aquecimento dos tijolos refratários, ou seja, no período de *on-gas*, não apenas impacta diretamente os custos operacionais, mas também acarreta significativas implicações ambientais. Portanto, a capacidade de predizer a temperatura do domo do regenerador permitirá ao operador atualizar adequadamente o plano de ação, reajustando as variáveis de entrada para atingir a temperatura do domo alvo com maior eficiência energética. Além disso, esse controle aprimorado do processo, proporcionado pela predição da temperatura do domo, também contribui para prolongar a vida útil dos regeneradores, reduzir as paradas para manutenção e otimizar a utilização dos recursos Şahin and Morari (2008); Kwakernaak et al. (1970).

Este trabalho propõe a investigação de métodos de predição da temperatura do domo do regenerador, com base em aprendizado de máquina, como o primeiro passo em direção à otimização do consumo de gases desse sistema. Será analisado o desempenho de diversos modelos de aprendizado de máquina na previsão da temperatura do regenerador. Os resultados de diferentes algoritmos serão comparados, incluindo um algoritmo supervisionado para

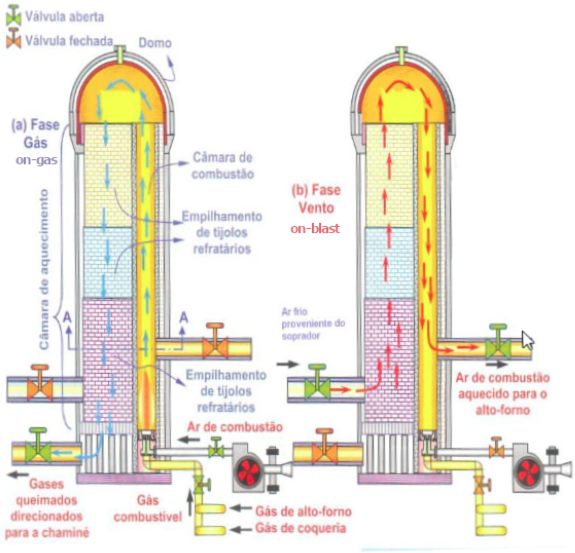

Figura 1. Fases do HBS. da Silveira Rizzo (2009)

regressão baseado em otimização convexa o *Support Vector Machine* (SVM), um algoritmo de ensemble o *Random Forest* (RF), dois algoritmos de Gradient Boosting, o *X-Gradient Boosting*, o (XGBoost) e o *LightGBM* (LB) - e um algoritmo baseado em instâncias *K-Nearest Neighbors* (KNN) que classifica novos pontos de dados com base na proximidade com os pontos de treinamento. Embora vários artigos sobre predição em ambientes siderúrgicos utilizem métodos específicos para séries temporais, como mencionado em Navarro et al. (2022), neste trabalho tais métodos não foram considerados devido ao comportamento inadequado dos dados, conforme demonstrado nos resultados. Os métodos investigados foram avaliados com dados reais de uma empresa siderúrgica. Além disso, os resultados indicam que nosso sistema é capaz de prever a temperatura do domo do regenerador com aproximadamente 30 minutos de antecedência, com os modelos SVM, RF, XGBoost, LB e KNN apresentando erro médio de 18.8418°C , 7.3367°C, 4.9155°C, 4.3683°C e 5.6697°C, respectivamente. Este trabalho contribui com: (i) uma abordagem distinta daquela comumente encontrada na literatura, ao não considerar séries temporais, como será explicado e justificado nas análises dos dados; e (ii) uma comparação abrangente entre vários métodos de aprendizado de máquina.

O restante do artigo está estruturado da seguinte forma: a Seção II apresenta um breve referencial teórico contextualizando a proposta. Na Seção III, é descrito o processo de pré-processamento dos dados, incluindo a seleção de atributos, a limpeza de dados e a redução de atributos. A Seção IV mostra os resultados numéricos da análise de predição, com foco nos métodos que apresentaram os melhores resultados, o XGB e o LB.

2. REFERENCIAL TEÓRICO

O processo de reutilização do BFG para aquecimento do ar no regenerador por meio da troca de calor é amplamente conhecido e explorado pela indústria. No entanto, esse processo é objeto de pesquisa contínua com o objetivo

de aumentar a eficiência energética, reduzir as emissões de CO_2 e os custos operacionais. Na década de 1970, estudos iniciais sobre a operação ideal de regeneradores em operação paralela escalonada foram abordados por Kwakernaak et al. (1970), no qual se buscava o modelo ótimo para a operação de um único regenerador de forma estacionária periódica.

No estudo realizado por Şahin and Morari (2008), foi demonstrado que a quantidade de combustível utilizada durante o processo influencia diretamente o consumo de energia da operação. O objetivo do estudo foi minimizar o fornecimento de calor para os regeneradores, ao mesmo tempo em que se fornece ar quente para o alto-forno na temperatura e vazão necessárias.

A otimização de recursos é, provavelmente, um dos temas mais investigados nas indústrias siderúrgicas. Na busca por melhorias nos processos, uma das principais estratégias adotadas é a predição de estados em um sistema. Nesse sentido, a predição de temperatura nos diversos estágios da fabricação do aço é um dos temas mais relevantes neste contexto. Devido aos custos envolvidos, aos riscos no processo e ao impacto na qualidade do produto principal, que é o ferro gusa, o cenário mais amplamente investigado costuma ser o do alto-forno. Por exemplo, os trabalhos de Navarro et al. (2022) e Carmo et al. (2022) abordam a predição no contexto do AF. O primeiro realiza uma análise comparativa de métodos sem o uso de séries temporais para a predição de temperatura, enquanto o segundo propõe o uso de uma LSTM com dados multimodais, incluindo uma série temporal e dados de batelada do início do processo, para a predição da geração do BFG.

Tabela 1. Atributos pesos e porcentagem da variância.

	Variável	Peso	% Variância
1	CALOR_GERADO_ACUMULADO	0.976241	82.6951
2	PCI_GAS_MISTO_ACUMULADO	0.198358	16.8024
3	VAZAO_AR_ACUMULADO	0.062290	5.2764
4	CALOR_NECESSARIO_UNITARIO	0.019691	1.6679
5	PRESSAO_GAS_MISTO_MEDIA	0.013285	1.1253
6	TEMPERATURA_CHAMA_INICIO	0.008206	0.6951
7	TEMPERATURA_CHAMA_FIM	0.007772	0.6583
8	PRESSAO_AR_AQUECIDO_MEDIA	0.004398	0.3725
9	TEMPERATURA_AR_INICIO	0.004101	0.3473
10	TEMPERATURA_CHAMINE_FIM	0.003610	0.3057
11	TEMPERATURA_CHAMINE_INICIO	0.003536	0.2995
12	TEMPERATURA_GAS_MISTO_INICIO	0.002330	0.1973
13	TEMPERATURA_GAS_MISTO_FIM	0.002218	0.1878
14	TEMPERATURA_ANTERIOR_DOMO	0.000088	0.0074
15	ESTAGIO_ATUAL	0.000012	0.0009
16	CALOR_CHAMINE_ACUMULADO	0.000004	0.0003

No cenário dos regeneradores, há poucos trabalhos que abordam a predição da temperatura do domo. Destacamos aqui o trabalho de Matino et al. (2019), que propõe a predição do uso de gases nos regeneradores utilizando um modelo baseado na *Echo State Network* (ESN). Outras estratégias de investigação incluem o trabalho de Koyfman et al. (2021), que propõe um controle de processo dos regeneradores utilizando métodos de simulação numérica, e o trabalho de Tang and Liu (2015), que também propõe um controle do processo, mas utilizando um método baseado em redes neurais.

Na perspectiva deste trabalho, ao retrocedermos um passo, compreendemos que antes de otimizar o uso de gases, é necessário prever o comportamento do sistema. Nesse sentido, ao investigar a previsão da temperatura do regenerador, mencionamos o trabalho de Yang et al. (2020), que propõe um modelo utilizando uma *Deep Memory Echo State Network* (DMESN) para o problema em questão. No entanto, uma das premissas do método proposto é o uso de séries temporais, o que não corresponde às características dos dados tratados neste trabalho. A investigação aqui apresentada se inspirou no trabalho de Navarro et al. (2022), porém este trabalho aborda a previsão da temperatura dos regeneradores.

3. METODOLOGIA E EXPERIMENTOS

A metodologia adotada neste estudo seguiu os seguintes passos: seleção dos atributos por meio de entrevistas com especialistas e análise de componentes principais (PCA), pré-processamento dos dados com remoção de outliers utilizando o Intervalo Interquartil (IRQ) e substituição de valores faltantes, e finalmente, normalização dos dados.

3.1 Seleção dos Atributos

O estudo foi conduzido utilizando dados reais coletados de uma siderúrgica no Brasil. A base de dados consiste em 18.478 amostras coletadas no ano de 2023. Cada amostra inicialmente apresentava 94 variáveis de controle, juntamente com informações suplementares relacionadas às medições durante os processos *on-blast* e *on-gas*, provenientes de quatro regeneradores, utilizados para atender as necessidades de um AF. As amostras foram coletadas com um intervalo médio de 36 minutos entre as medições e organizadas em conjuntos distintos para cada um dos quatro HBS. Neste estudo, o foco foi no conjunto de amostras do regenerador de número 1 denominado HBS-1, totalizando 5684 amostras coletadas ao longo do ano de 2023.

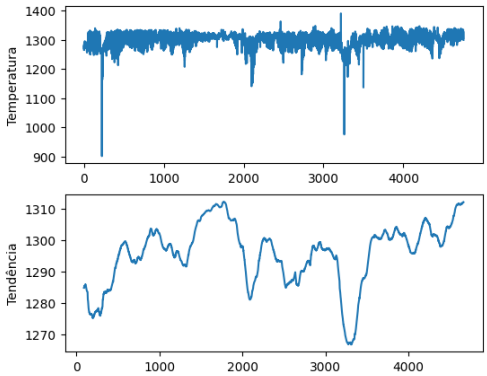

Figura 2. Temperatura de Domo ao longo do tempo.

A Figura 2 apresenta a temperatura de Domo ao longo do tempo. No primeiro gráfico nota-se flutuações com picos e quedas significativas de temperatura, além da presença de *outliers*. A partir da marca de 3500, o gráfico de *trend* indica uma tendência crescente da temperatura. Constatou-se que a variância dos dados foi de 26.07°C. Adicionalmente, os gráficos apresentam pontos fora do padrão indicando ruídos e anomalias, que foram tratados conforme descrito. Sendo assim, os dados não foram caracterizados como uma série temporal, o que justifica a investigação dos métodos analisados neste trabalho. A base de dados original é composta por 94 variáveis, mas, com o objetivo de identificar os atributos mais relevantes para o objetivo do

estudo, foram realizadas entrevistas com especialistas do processo e, em seguida, foi utilizado um método estatístico para redução de dimensionalidade. Em uma análise inicial, foram removidas as variáveis do tipo chave primária das tabelas (ID), variáveis como registro de datas e variáveis de segunda ordem, como médias de outras variáveis. Como resultado parcial, selecionamos 26 dentre os 94 atributos originais. Posteriormente, foi aplicada a análise de componentes principais (PCA, *Principal Component Analysis*), conforme citado em Xie et al. (2014). Com a aplicação do PCA nessa base previamente selecionada, foi possível reduzir a dimensionalidade para 16 variáveis, conforme demonstrado nas 16 primeiras linhas da Tabela 1 cujos valores de peso são acima de 0. Segundo os resultados do PCA, os primeiros 3 componentes seriam capazes de representar quase 100% da variância total da variável alvo (temperatura do domo), conforme demonstrado na Tabela 1.No entanto, como não houve alteração significativa no custo computacional, foi decidido utilizar os 16 atributos previamente selecionados Adicionalmente, na tabela, são listados os atributos de entrada, e nas colunas está descrito o percentual de correlação com a variável alvo (peso) e a porcentagem da variância total do componente presente.

3.2 Pré-Processamento dos Dados

Além da preparação dos atributos mencionada, foi necessário realizar a limpeza e o pré-processamento dos dados, conforme os procedimentos detalhados a seguir. O primeiro procedimento foi remover registros duplicados, a fim de garantir a integridade e confiabilidade dos dados utilizados no conjunto de entrada.

O conjunto de dados utilizado neste estudo apresentou valores ausentes em alguns atributos. Para solucionar esse problema, aplicamos a técnica de imputação por média móvel, utilizando uma janela fixa que considera as 24 amostras mais recentes em relação ao valor ausente. Esse método abrange um período de aproximadamente 14 horas de operação, contemplando no mínimo um ciclo de *on-gas* e um ciclo de *on-blast*. A imputação por média móvel com uma janela de 24 amostras é eficaz para capturar a tendência e a sazonalidade dos dados, evitando que valores muito antigos influenciem indevidamente o preenchimento dos valores faltantes. No entanto, é importante destacar que essa técnica pode suavizar ou alterar os padrões originais dos dados, o que pode afetar a qualidade dos modelos caso haja um período prolongado de valores ausentes. Porém, esse não foi o caso no conjunto de dados.

Após o tratamento dos dados ausentes, prosseguimos com a filtragem dos dados utilizando uma técnica baseada no IQR (*Interquartile Range*), conforme a Equação 1. Essa estratégia visa tornar os dados mais comparáveis, reduzindo a influência de valores extremos e promovendo uma distribuição mais homogênea. Os limites inferior e superior foram estabelecidos com base nos quartis do conjunto de dados, conforme a Equação 2. Valores fora desses limites foram considerados como *outliers*. Para garantir a continuidade temporal, os *outliers* foram transformados em valores ausentes e em seguida aplicamos novamente o tratamento de imputação por média móvel.

$$X_{norm} = \frac{x - Q_1}{(IQR)}; \quad IQR = (Q_3 - Q_1) \tag{1}$$

$$Inferior = Q_1 - 1.5IQR; Superior = Q_3 + 1.5IQR \tag{2}$$

Para visualizar o impacto do tratamento de valores ausentes e *outliers* nas variáveis do conjunto de dados, utilizamos gráficos do tipo *ViolinPlot*, conforme apresentado na Figura 3. A Figura 3(A) apresenta os dados antes do processamento, enquanto a Figura 3(B) mostra as variáveis de maior peso de acordo com a Tabela 1 e os dados após o tratamento de valores ausentes e *outliers*. Ao analisar a Figura 3(B), observamos que os dados apresentam-se mais concentrados, com uma menor dispersão, evidenciado pela redução da altura do "violino". Além disso, a simetria dos violinos indica que a distribuição dos dados tornou-se mais simétrica após o tratamento.

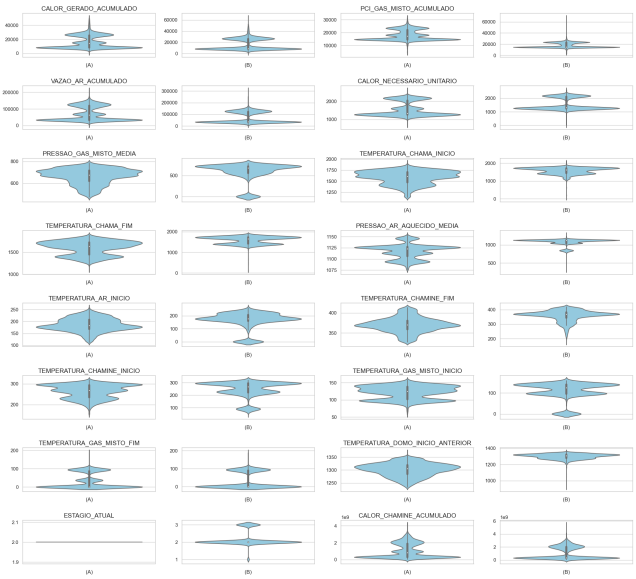

Figura 3. *ViolinPlot* para comparar os dados tratados - (A) antes e (B) depois do tratamento dos dados

.

No passo seguinte, realizamos a normalização das variáveis com o objetivo de transformar todas as variáveis do conjunto na mesma ordem de grandeza. Foi utilizada a técnica de *Min-Max Scaling*, apresentada na Equação 3. A normalização foi feita para todas as variáveis.

$$X_{normal} = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{3}$$

Por fim, foi utilizado o método de validação cruzada, que divide os dados em conjuntos de treinamento e teste, conforme descrito por Salazar et al. (2022). Neste estudo, a divisão foi feita com 80% das amostras destinadas ao conjunto de treinamento 0 restantes ao conjunto de teste.

Por outro lado, a validação cruzada *k-fold* é uma alternativa à abordagem do conjunto de validação. Esta técnica separa os dados em k dobras de aproximadamente o mesmo tamanho. Em seguida, a validação cruzada é realizada k vezes, nas quais o subconjunto k específico é aplicado como conjunto de teste, enquanto as $k - 1$ dobras restantes

são utilizadas como dados de treinamento para treinar os parâmetros do modelo, e o erro de generalização é calculado sobre os dados de teste. Finalmente, o procedimento é repetido k vezes, alternando a dobra do teste, e eventualmente estimando o erro de validação cruzada $k - fold$ como o erro médio de predição sobre k modelos, conforme Hastie et al. (2009) e James et al. (2013).

3.3 Metodologia

Como mencionado, a investigação neste trabalho incluiu a análise de diferentes modelos de predição, utilizando quatro abordagens distintas de inteligência artificial. As técnicas empregadas foram classificadas e selecionadas com base em sua relevância e eficácia demonstradas em estudos anteriores, como o de Choi et al. (2022). Foram testados o algoritmo KNN (k-Nearest Neighbors), que é adequado para classificar dados com base na proximidade ou similaridade com exemplos conhecidos; e três técnicas de aprendizado ensemble, que são o *Random Forest (RF)*, *XGBoost* (XGB) e *LightGBM* (LB), conhecidos por sua robustez e capacidade de lidar com grandes conjuntos de dados e complexidades variáveis. Além disso, foi testada a *Support Vector Machine* (SVM), um tipo de algoritmo de aprendizado supervisionado utilizado para análise de classificação e regressão, apresentando bons resultados especialmente em classificação binária.

O processo de treinamento dos modelos iniciou-se com a utilização do subconjunto de dados designado para treinamento. Cada modelo foi treinado utilizando suas configurações padrão, permitindo uma avaliação inicial de desempenho. Durante essa fase, as métricas R^2 e RMSE foram coletadas para analisar a eficácia dos modelos sob essas condições iniciais. Após o treinamento, os modelos foram submetidos a testes utilizando o conjunto de dados de teste separado previamente, o que permitiu avaliar como cada modelo generaliza para novos dados. Finalmente, as mesmas métricas de desempenho foram coletadas e comparadas para ambos os cenários, treinamento e teste, proporcionando uma visão abrangente sobre a capacidade de cada modelo em lidar com o problema proposto. Este processo de treinamento e teste é crucial para identificar os modelos mais promissores e ajustar suas configurações para otimizar o desempenho.

Na etapa subsequente de comparação dos modelos, foi realizada uma busca de hiperparâmetros utilizando a função *GridSearchCV*. Este método sistemático de otimização automatiza o processo de seleção de hiperparâmetros, testando uma variedade de combinações possíveis para determinar aquelas que maximizam o desempenho do modelo, conforme PRIYA et al. (2022). Cada conjunto de hiperparâmetros é avaliado por meio da técnica de validação cruzada $k - fold$, garantindo assim uma avaliação correta do desempenho dos modelos em diferentes subconjuntos de dados. O conjunto ótimo de hiperparâmetros é selecionado com base em uma métrica de desempenho específica, conforme exemplificado em Navarro et al. (2022). Essa abordagem assegura que cada modelo final esteja bem ajustado para generalizar efetivamente em novos dados, aumentando a precisão e a eficiência do aprendizado de máquina aplicado.

Os resultados obtidos foram avaliados comparativamente, utilizando o Coeficiente de Determinação R^2 como métrica principal para aferir a precisão dos modelos, conforme descrito em Alshboul et al. (2024) e apresentado na Equação 4. O R^2 mede a proporção da variância dos valores reais que é previsível a partir dos valores previstos pelo modelo, oferecendo um indicativo de quão bem as variáveis independentes explicam a variável dependente. Adicionalmente, os modelos selecionados foram analisados utilizando a métrica da Raiz Quadrada do Erro Quadrático Médio (RMSE), que calcula a média dos quadrados dos erros, isto é, a diferença entre os valores previstos pelo modelo e os valores reais. Essa métrica fornece uma ideia da dispersão dos erros em relação aos valores reais, sendo útil para entender o quão próximos os valores previstos estão dos valores observados. A fórmula matemática do RMSE é apresentada na Equação 5.

$$R^2 = \frac{SQ_{exp}}{SQ_{tot}}; \text{ onde:}$$
$$SQ_{tot} = \sum_{i=1}^{n}(y_i - \overline{y})^2 \text{ e } SQ_{exp} = \sum_{i=1}^{n}(\hat{y} - \overline{y})^2 \tag{4}$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^{N} E_t^2}{N}} \tag{5}$$

Para os modelos de melhor desempenho, também foram avaliadas as métricas de Erro Absoluto Médio do inglês *Mean Absolute Error* (MAE) e Erro Percentual Absoluto Médio do inglês *Mean Absolute Percentage Error* (MAPE). O MAE mede a média dos valores absolutos dos erros entre as previsões do modelo e os valores reais, oferecendo uma perspectiva direta da magnitude média dos erros de previsão, sem considerar a direção (positiva ou negativa) desses erros, conforme Wang and Lu (2018). Enquanto, o MAPE expressa o erro como uma porcentagem do valor real, proporcionando uma visão intuitiva do erro em termos relativos, o que é útil para comparar a precisão entre diferentes conjuntos de dados ou modelos com escalas variáveis, conforme De Myttenaere et al. (2016).

4. RESULTADOS E DISCUSSÕES

A análise dos resultados dos modelos de previsão, incluindo RF, XGB, LB, KNN e SVM, mostrou que, mesmo sem ajustes de hiperparâmetros, esses modelos conseguem explicar uma grande parte da variância dos dados, como indicado pelos valores relativamente altos de R^2 (0.8864817 para RF, 0.8104346 para XGB, 0.8270889 para LB, e 0.0.7404702 para KNN). Isso sugere que os modelos têm uma capacidade razoável de prever a temperatura de domo, destacando a eficácia dos algoritmos utilizados sob condições padrão em um contexto de validação cruzada *K-fold*. No entanto, os valores elevados de RMSE para os modelos KNN e SVM (2.73998043 e 4.76192148, respectivamente) indicam que, apesar da boa explicação da variância, as previsões podem ser imprecisas em termos absolutos, sugerindo a ocorrência de erros significativos nas previsões. Essa congruência entre R^2 alto e RMSE elevado indica a necessidade de ajustes nos hiperparâmetros dos modelos para melhorar a precisão das previsões.

As tabelas 2 e 3 apresentam os resultados das métricas R^2 e RMSE dos métodos investigados, antes e depois do ajuste dos hiperparâmetros, respectivamente. Esses ajustes de hiperparâmetros foram obtidos utilizando a validação cruzada *k-fold* e *GridSearch* com busca por gradiente. Em linhas gerais, as tabelas mostram uma melhoria modesta no RMSE para a maioria dos modelos. Apesar de ser uma melhoria pequena, ela é significativa no contexto da fabricação de ferro gusa, na qual otimizações aparentemente mínimas podem impactar significativamente a eficiência e a qualidade do processo produtivo. Este ajuste e a quantificação do ganho demonstram a eficácia das técnicas de otimização de hiperparâmetros. Por fim, como os métodos XGB e LB apresentaram os melhores resultados, esses métodos serão analisados em maior profundidade.

Tabela 2. Performance dos Modelos, antes do ajuste dos hiperparâmetros.

	R^2		RMSE (°C)	
Modelos	Train	Test	Train	Test
SVM	0.2628644	0.2338812	4.61806880	4.76192148
RF	0.9771563	0.8864817	1.93760341	2.95443643
XGB	0.9973483	0.8104346	1.13097500	3.35851990
LB	0.9442689	0.8270889	2.42157484	3.28219123
KNN	0.9086527	0.7404702	2.73998043	3.63291285

Tabela 3. Performance dos Modelos, depois do ajuste dos hiperparâmetros.

	R^2		RMSE	
Modelos	Train	Test	Train	Test
SVM	0.9508448	-0.0012592	2.3467445	5.0914893
RF	0.8564123	0.71483633	3.0679821	3.7194759
XGB	0.9697478	0.83274270	2.0785601	3.2550260
LB	0.9856362	0.87040695	1.7254021	3.0538916
KNN	0.8845410	0.74144871	9.8953529	7.7346356

A Figura 4 apresenta os gráficos de dispersão que comparam as temperaturas de domo previstas pelos modelos XGB e LB com as temperaturas ideais teóricas, tanto na fase de treinamento quanto na fase de teste. Nos gráficos, a linha vermelha pontilhada indica erro 0 ou seja, uma predição perfeita da temperatura de domo, enquanto os pontos azuis indicam a predição obtida pelos métodos analisados. Adicionalmente, à esquerda estão os experimentos de treinamento e à direita estão os experimentos de teste, enquanto os gráficos superiores são gerados pelo LB e os inferiores pelo XGB. Os resultados indicam uma forte correlação dos modelos na predição das temperaturas de domo com a temperatura ideal a ser atingida. Nos gráficos de teste (à direita), embora as temperaturas de domo preditas estejam mais dispersas, em sua maioria ainda se encontram próximas à linha de predição ideal, sugerindo que os modelos foram capazes de prever as tendências de temperaturas esperadas no domo.

A Figura 5 ilustra o desempenho dos modelos LB (acima) e XGB(abaixo), comparando as predições dos modelos (linha pontilhada vermelha) com os dados reais (linha azul) de temperatura. Adicionalmente, como na Figura 4, a esquerda estão os resultados do treinamento e à direita os resultados do teste. Como esperado, nos gráficos de treinamento de ambos os modelos, foi observada uma alta precisão na fase de treinamento, evidenciada pela sobreposição da linha pontilhada vermelha com a linha contínua azul. Nos gráficos de teste, da Figura 5 observa-se que em algumas comparações as linhas não se sobrepõem perfeitamente, indicando erros pontuais na predição. Essas

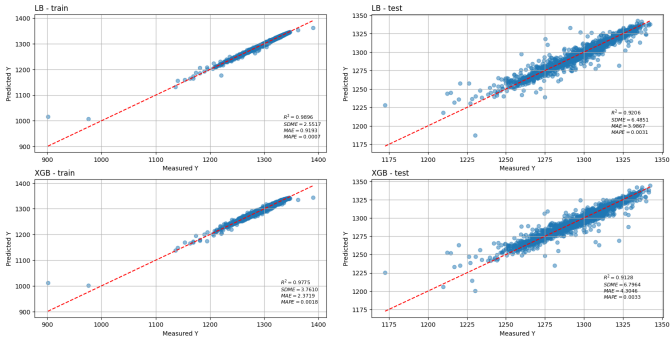

Figura 4. Gráficos de dispersão comparando a predição dos métodos XGB e LB com a temperatura ideal teórica.

discrepâncias são notadas apenas em situações nas quais os dados sugerem uma inversão na tendência da temperatura de domo, possivelmente devido a mudanças entre as fases de *on-gas* e *on-blast*. Este padrão nos gráficos de linha sinaliza áreas específicas nas quais os modelos podem necessitar de ajustes ou melhorias para lidar com as dinâmicas de mudança de fase, visando aprimorar a precisão das previsões. Ainda sobre os gráficos de teste, visualmente, é quase imperceptível que no gráfico LB-Test há menos desvios em relação à linha azul do que no gráfico XGB-Test. Assim, para uma comparação mais precisa apresentamos a Tabela 4 com as métricas MAE e MAPE. Pela tabela observamos que o modelo LB tem um desempenho ligeiramente melhor do que o XGB.

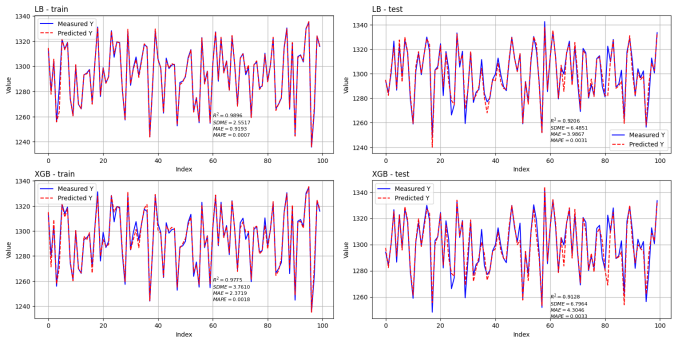

Figura 5. Comparação da predição dos métodos XGB e LB

Tabela 4. Resultado das métricas MAE e MAPE para os modelos LB e XGB.

	MAE		MAPE	
Modelos	Train	Test	Train	Test
LB	0.9193	3.9867	0.0007	0.0031
XGB	2.3719	4.3046	0.0018	0.0033

5. CONCLUSÃO

Este trabalho abrangeu um estudo completo para analisar o desempenho de métodos de aprendizado de máquina na predição da temperatura de regeneradores em uma usina siderúrgica integrada. Os métodos de predição selecionados para essa investigação foram escolhidos levando em consideração que os dados utilizados não configuram uma série temporal. Dessa forma, os métodos investigados foram *Support Vector Machine* (SVM), *Random Forest* (RF), *X-Gradient Boosting (XGB)*, *LightGBM* (LB) e *K-Nearest Neighbors*(KNN)

Seguindo o roteiro de uma análise de predição completa, inicialmente foi feita uma seleção de atributos. Para isso, foram realizadas entrevistas com especialistas, seguidas pela aplicação do método de Análise de Componentes Principais (PCA). Das 94 variáveis originais, 16 foram selecionadas para prosseguir com a investigação. Os dados faltantes e os *outliers* foram identificados com a técnica *Min-Max Scaling* e tratados usando a média móvel das últimas 12 amostras. Em seguida, procedeu-se à filtragem dos dados com a técnica de *IQR*. Para ilustrar o impacto dessa transformação, foi analisado um gráfico tipo *violin-plot* das métricas antes e depois da transformação.

Com o objetivo de aprimorar o desempenho das previsões, foi empregada a ferramenta de ajuste de parâmetros dos métodos, denominada *GridSearchCV*. Através da avaliação das métricas R^2 e RMSE, foi destacou-se o impacto da calibração dos parâmetros na qualidade das previsões. Por fim, os resultados mostram que os melhores desempenhos foram obtidos pelos métodos XGB e LB.

Explorando os modelos que obtiveram os melhores desempenhos nas métricas R^2 e RMSE, foi feito uma análise visual dos gráficos de comparação, incluindo os *scatter plots* da temperatura ideal teórica com as predições e uma comparação da temperatura medida com a prevista. Essa análise revelou que ambos os modelos, XGB e LB, proporcionam predições precisas, embora o LB aparentemente apresente uma ligeira vantagem. Para quantificar essa vantagem foi apresentado as métricas MAE e MAPE.

Como sugestão para trabalhos futuros, esses resultados poderão ser incorporados em um método de otimização que visa reduzir o consumo de gases utilizados na queima para aquecimento do regenerador, ampliando assim a eficiência operacional na usina siderúrgica.

AGRADECIMENTOS

Os autores agradecem ao apoio da FAPES e CAPES (processo 2021-2S6CD, nº FAPES 132/2021) por meio do PDPG (Programa de Desenvolvimento da Pós-Graduação, Parcerias Estratégicas nos Estados).

REFERÊNCIAS

Alshboul, O., Almasabha, G., Shehadeh, A., and Al-Shboul, K. (2024). A comparative study of lightgbm, xgboost, and gep models in shear strength management of sfrc-sbws. In *Structures*, volume 61, 106009. Elsevier.

Carmo, M., Mutz, F., and Resendo, L. (2022). Improving steel making off-gas predictions by mixing classification and regression multi-modal multivariate models. In *Anais do XIX Encontro Nacional de Inteligência Artificial e Computacional*, 37–48. SBC, Porto Alegre, RS, Brasil. doi:10.5753/eniac.2022.227570.

Choi, H.J., Kim, S., Kim, Y., and Won, J. (2022). Predicting frost depth of soils in south korea using machine learning techniques. *Sustainability*, 14(15), 9767.

da Silveira Rizzo, E.M. (2009). *Processo de fabricação de ferro-gusa em alto-forno*. ABM.

De Myttenaere, A., Golden, B., Le Grand, B., and Rossi, F. (2016). Mean absolute percentage error for regression models. *Neurocomputing*, 192, 38–48.

Hastie, T., Tibshirani, R., Friedman, J.H., and Friedman, J.H. (2009). *The elements of statistical learning: data mining, inference, and prediction*, volume 2. Springer.

James, G., Witten, D., Hastie, T., Tibshirani, R., et al. (2013). *An introduction to statistical learning*, volume 112. Springer.

Koyfman, O., Simkin, O., Klimov, Y., and Scherbakov, S. (2021). Using of intelligence analysis of technological parameters database for implementation of control subsystem of hot blast stoves block acs. In *CMIS*, 145–157.

Kwakernaak, H., Tijssen, P., and Strijbos, R. (1970). Optimal operation of blast furnace stoves. *Automatica*, 6(1), 33–40.

Matino, I., Dettori, S., Colla, V., Weber, V., and Salame, S. (2019). Two innovative modelling approaches in order to forecast consumption of blast furnace gas by hot blast stoves. *Energy Procedia*, 158, 4043–4048.

Navarro, L.C., Amorim, L.L., Berriel, R., Paixão, T.M., Rampinelli, V., Wasem, L.A., Quaresma, L., Badue, C., De Souza, A.F., and Oliveira-Santos, T. (2022). Temperature prediction in blast furnaces: a machine learning comparative study. In *2022 35th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, volume 1, 192–197. IEEE.

PRIYA, S.M. et al. (2022). Hyper tuning using gridsearchcv on machine learning models for prognosticating dementia.

Şahin, A. and Morari, M. (2008). Optimizing control of hot blast stoves in staggered parallel operation. *IFAC Proceedings Volumes*, 41(2), 1982–1987.

Salazar, J.J., Garland, L., Ochoa, J., and Pyrcz, M.J. (2022). Fair train-test split in machine learning: Mitigating spatial autocorrelation for improved prediction accuracy. *Journal of Petroleum Science and Engineering*, 209, 109885.

Sun, W., Wang, Z., and Wang, Q. (2020). Hybrid event-, mechanism-and data-driven prediction of blast furnace gas generation. *Energy*, 199, 117497.

Tang, Y.W. and Liu, X. (2015). Hot blast stove temperature control system based on neural network predictive control. In *Designing and Researching of Machines and Technologies for Modern Manufacture*, volume 709 of *Applied Mechanics and Materials*, 281–284. Trans Tech Publications Ltd. doi:10.4028/www.scientific.net/AMM.709.281.

Wang, W. and Lu, Y. (2018). Analysis of the mean absolute error (mae) and the root mean square error (rmse) in assessing rounding model. In *IOP conference series: materials science and engineering*, volume 324, 012049. IOP Publishing.

Xie, S., Krishnan, S., et al. (2014). Dynamic principal component analysis with nonoverlapping moving window and its applications to epileptic eeg classification. *The Scientific World Journal*, 2014.

Yang, Y., Zhao, X., and Liu, X. (2020). A novel echo state network and its application in temperature prediction of exhaust gas from hot blast stove. *IEEE Transactions on Instrumentation and Measurement*, 69(12), 9465–9476.

Zhou, H., Zhang, H., and Yang, C. (2019). Hybrid-model-based intelligent optimization of ironmaking process. *IEEE Transactions on Industrial Electronics*, 67(3), 2469–2479.