

Modelagem Preditiva e Interpretação de Emissões de Dióxido de Carbono em Máquinas Agrícolas com Técnicas de IA

Carnot Braun¹, Rafael O. Jarczewski¹, Leandro Villas¹,
Pedro Moura², Allan M. de Souza¹

¹Universidade Estadual de Campinas, Brasil

²SiDi – Instituto de Ciência, Tecnologia e Inovação

{c255785, r200219}@dac.unicamp.br

{lvillas, allanms}@unicamp.br

p.moura@sidi.org.br

Abstract. *Natural disasters, such as fires and extreme weather events, have intensified in recent years, driven by climate change and human activities. In this scenario, it becomes crucial to invest in research to reduce polluting gases, such as Carbon Dioxide (CO₂). However, current studies predominantly focus on emissions from countries and urban vehicles. The agricultural sector, however, contributes significantly to CO₂ emissions in Brazil. This work presents a benchmark of artificial intelligence models to predict emissions. We use data from two tractors, from the fuel, battery, engine and gear systems. We use pre-processing methods such as LIME, and the estimation of carbon emissions using fuel type and carbon intensity defined by the Brazilian Association of Automotive Engineering. Thus, we evaluated sixteen machine learning models, highlighting the XGBoost model, with the lowest RMSE of 0,01, demonstrating promising performance for prediction.*

Resumo. *Os desastres naturais, como queimadas e eventos climáticos extremos, têm se intensificado nos últimos anos, impulsionados por mudanças climáticas e atividades antrópicas. Nesse cenário, torna-se crucial investir em pesquisas para reduzir gases poluentes, como o Dióxido de Carbono (CO₂). Contudo, os estudos atuais focam predominantemente em emissões de países e veículos urbanos. O setor agropecuário, entretanto, contribui significativamente para as emissões de CO₂ no Brasil. Este trabalho apresenta um benchmark de modelos de inteligência artificial para prever emissões. Utilizamos dados de dois modelos de tratores, provenientes dos sistemas de combustível, bateria, motor e marcha. Utilizamos métodos de pré-processamento como LIME, e a estimativa de emissão de carbono usando tipo de combustível e intensidade de carbono definida pela Associação Brasileira de Engenharia Automotiva. Dessa forma, avaliamos dezesseis modelos de aprendizado de máquina, destacando-se o modelo XGBoost, com o menor RMSE de 0,01, demonstrando desempenho promissor para previsão.*

1. Introdução

As mudanças climáticas globais têm se tornado uma preocupação crescente, agravada pelo aumento expressivo das emissões de Dióxido de carbono (CO₂) desde

o período pré-industrial. Estudos indicam que essas emissões quase quadruplicaram desde 1990, atingindo aproximadamente 35 bilhões de toneladas por ano [Ritchie and Roser 2024]. Em resposta a esse cenário, acordos internacionais, como o Acordo de Paris, impulsionam países, incluindo o Brasil, a adotarem estratégias rigorosas para a redução de poluentes [Ministério do Meio Ambiente 2015, Associação Brasileira de Engenharia Automotiva 2025].

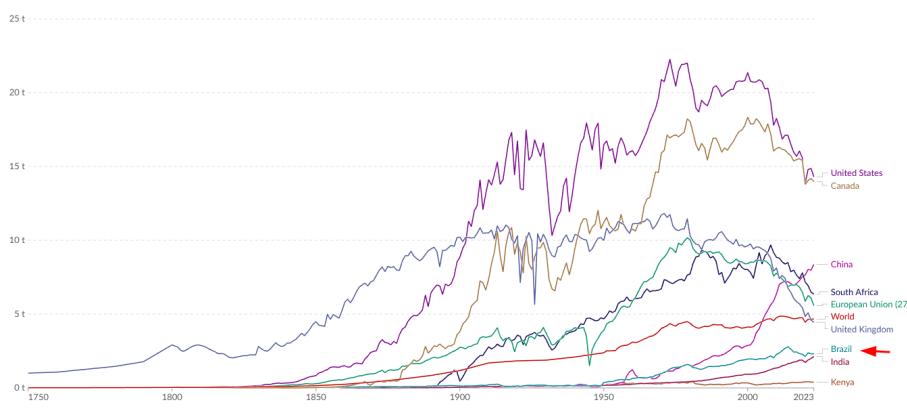


Figura 1. Emissões de dióxido de carbono (CO₂) de combustíveis fósseis e indústria.

Além disso, a emissão de CO₂ proveniente de combustíveis fósseis e atividades industriais está aumentando gradativamente ao longo dos anos, conforme podemos ver na Figura 1 [Ritchie et al. 2023]. Como podemos ver, o Brasil tem experimentado um aumento gradual em sua taxa de emissão, e grande parte dos poluentes são originados pelos meios de produção agrícola.

O Brasil emitiu 2,17 bilhões de toneladas de CO₂ em 2019, representando um aumento de 9,6% em relação a 2018. Destes, 73% são de atividades agropecuárias, totalizando 598,7 milhões de toneladas de CO₂ equivalente. Este dado destaca a relevância do setor agropecuário nas emissões nacionais, embora também evidencie seu potencial para práticas de sequestro de carbono. A adoção de medidas como eliminação do desmatamento, recuperação de pastagens e agricultura de baixo carbono (utilizando métodos de aprendizado de máquina) podem reduzir significativamente a pegada de carbono do agronegócio [Grilli 2020].

Nesse contexto, o setor agrícola destaca-se pela crescente mecanização, impulsionada pela demanda global por alimentos. A utilização intensiva de tratores e outras máquinas pesadas é essencial para garantir a produtividade, mas também representa uma fonte significativa de emissões de CO₂. O desafio, portanto, reside em conciliar a eficiência operacional com a mitigação dos impactos ambientais.

Para enfrentar esse desafio, torna-se fundamental o desenvolvimento de modelos computacionais capazes de estimar com precisão as emissões provenientes do uso de maquinário agrícola. Mais do que simplesmente prever, esses modelos devem permitir uma análise aprofundada dos dados operacionais, extraiendo padrões relevantes e identificando as variáveis que mais influenciam as emissões. Essa abordagem orientada por dados (*data mining*) possibilita a otimização do desempenho dos modelos, além de fornecer *insights* valiosos para a tomada de decisões no campo.

Este trabalho realiza um estudo entre dezesseis modelos diferentes para estimar as emissões de CO₂ geradas por tratores agrícolas. A metodologia envolve a análise de dados coletados por sensores embarcados de dois tratores. Cada sensor monitora variáveis como rotação do motor, nível de combustível, seleção de marchas, carga do motor e temperatura. A partir dessa base, comparamos o desempenho dos modelos a fim de analisar qual deles teria o melhor desempenho para capturar as complexas relações não-lineares entre os fatores operacionais e as emissões.

Além da modelagem, este trabalho enfatiza o papel da interpretabilidade como elemento central para a confiança e a utilidade prática do sistema proposto. Para tanto, técnicas como o *Local Interpretable Model-agnostic Explanations* (LIME) [Ribeiro et al. 2016] são aplicadas, permitindo compreender a contribuição individual de cada variável nas previsões do modelo. Dessa forma, o sistema não apenas oferece previsões precisas, mas também atua como uma ferramenta explicativa, útil para operadores, engenheiros e formuladores de políticas.

Ao unir precisão preditiva e interpretabilidade, este trabalho contribui com: i) diferente dos métodos da literatura, não simulamos os dados, mas sim, utilizamos dados operacionais de campo de duas máquinas agrícolas reais. ii) Realizamos um *benchmark* de dezesseis modelos de aprendizado de máquina para emissão de carbono a fim de compreender o melhor método para o cenário. iii) Este trabalho também auxilia no desenvolvimento de agricultura sustentável proporcionando *insights* sobre modelos e métricas relevantes para o problema de emissão de CO₂.

As seções subsequentes deste artigo estão organizadas da seguinte forma: a Seção 2 apresenta os principais trabalhos relacionados, destacando abordagens existentes para a previsão e redução de emissões em veículos; a Seção 3 detalha a proposta metodológica, incluindo o processo de coleta e tratamento de dados, seleção de atributos; Em seguida Seção 4, explicamos o fluxo do *benchmark*, quais métricas utilizamos e modelos selecionados; a Seção 5 discute os resultados obtidos, com ênfase na capacidade preditiva do modelo e nos ganhos decorrentes da aplicação de técnicas de interpretabilidade; e, por fim, a Seção 6 apresenta as conclusões do trabalho e propõe direções para pesquisas futuras.

2. Trabalhos Relacionados

Recentemente, trabalhos têm explorado o uso de técnicas de aprendizado de máquina para a previsão e mitigação de emissões de CO₂, utilizando dados operacionais coletados em tempo real de veículos. Modelos baseados em arquiteturas recorrentes, como as Redes *Long Short-Term Memory* (LSTM), e Redes Neurais Profundas (DNNs) têm se destacado pela capacidade de capturar padrões temporais e relações não lineares entre variáveis, tais como velocidade, aceleração, temperatura e carga do motor [Vega and Perkins 2023, Jin 2024, de Souza et al. 2020].

Como observado por Jin *et al.*, a crescente utilização de redes neurais, especialmente arquiteturas *feedforward* e recorrentes, tem mostrado resultados promissores na previsão das emissões de carbono, além de contribuir significativamente para a otimização dos modelos de previsão [Jin et al. 2024]. Outros estudos comparam diferentes técnicas para identificar qual delas melhor atende aos seus objetivos, como o trabalho de [Silva et al. 2024a], que analisa três abordagens distintas: uma baseada em regras, uma

lógica *fuzzy* e uma DNN simples. Durante a pesquisa, a DNN se destacou como a mais eficaz na redução de CO₂, evidenciando o potencial dessa tecnologia.

Complementarmente, uma linha de investigação concentra-se na otimização operacional visando à redução de emissões. Estratégias como a troca de marchas em pontos ideais [Silva et al. 2024b] e o planejamento inteligente de rotas [Banerjee et al. 2024] têm sido empregadas como soluções práticas para mitigar emissões durante a operação veicular. Tais métodos incorporam variáveis contextuais, como topografia, densidade de tráfego e consumo de combustível, permitindo recomendações personalizadas em tempo real. A integração dessas abordagens com sistemas de controle embarcados e sensores tem demonstrado eficácia em veículos comerciais e de carga, contribuindo para a tomada de decisão autônoma em campo.

Outro aspecto amplamente discutido na literatura é a qualidade e o preparo dos dados utilizados na modelagem. Técnicas como remoção de *outliers*, normalização de variáveis e imputação de valores ausentes são essenciais para garantir a robustez dos modelos preditivos e prevenir vieses decorrentes do ruído dos sensores [Smith and Wang 2024, Lee and Zhang 2024]. A ausência de um tratamento sistemático pode comprometer a generalização dos modelos, sobretudo em cenários com alta variabilidade operacional.

Em paralelo, técnicas de interpretabilidade vêm ganhando protagonismo no desenvolvimento de modelos preditivos transparentes. Ferramentas como LIME [Ribeiro et al. 2016] e SHAP (*Shapley Additive Explanations*) [Lundberg and Lee 2017] têm sido amplamente adotadas em aplicações de aprendizado de máquina, especialmente na área de transportes. Ao quantificar a contribuição individual de cada variável para uma previsão, essas técnicas promovem transparência e aumentam a confiança dos especialistas e operadores na utilização dos modelos. Estudos recentes demonstram a aplicabilidade dessas ferramentas em domínios industriais e agrícolas, facilitando a validação e a interpretação de modelos complexos.

Apesar dos avanços, observa-se uma lacuna na literatura quanto à aplicação integrada dessas abordagens no contexto da agricultura de precisão. Embora trabalhos como [Ma et al. 2023] proponham abordagens baseadas em *deep learning* para a previsão em tempo real das emissões em máquinas agrícolas, a maioria dos estudos concentra-se em veículos urbanos ou logísticos, sem considerar as especificidades operacionais de tratores e demais máquinas agrícolas - tais como combustível, motor, bateria e marcha.

Neste contexto, este trabalho propõe uma análise da integração sistemática entre modelos de aprendizado de máquina, pré-processamento rigoroso de dados e técnicas de interpretabilidade, aplicada ao contexto de tratores agrícolas. O objetivo é identificar o melhor modelo para predizer emissão de CO₂, preciso e transparente, com potencial para subsidiar práticas operacionais mais sustentáveis no setor agroindustrial. Diferentemente de estudos anteriores, nosso trabalho busca não apenas identificar potenciais modelos preditivo, mas também fornecer *insights* açãoáveis a operadores e engenheiros por meio de explicações compreensíveis acerca do comportamento do modelo.

3. Análise de Dados

Os dados coletados dos tratores podem ser divididos em quatro categorias: (i) *Fuel* sendo dados contendo informações gerais e específicas, como temperatura, gasto, tipo

e pressão; (ii) *Engine* os quais são sensores, vinculados à qualidade e estado do motor do veículo, dessa forma, conseguimos não só informações sobre torque e rotação, mas também informação de óleo, temperatura, pressão, etc.; (iii) *Gear* representa qual marcha da transmissão selecionada e qual marcha da transmissão atual; e (iv) *Battery* representando a voltagem da bateria.

Embora os dados exatos permaneçam confidenciais, em conformidade com os acordos da Lei Geral de Proteção de Dados (LGPD), as informações utilizadas neste estudo são tratadas sob rígidos protocolos de segurança e acesso restrito, a fim de preservar a privacidade e a integridade dos dados sensíveis. Tais medidas garantem que o manuseio dos dados esteja em total conformidade com as exigências legais, evitando qualquer exposição não autorizada e assegurando a proteção das informações dos envolvidos.

Nesta Seção, descrevemos detalhadamente os procedimentos adotados para a obtenção dos valores de emissão de CO₂, o pré-processamento, a análise exploratória e a seleção de atributos para a modelagem preditiva.

3.1. Como estimar a emissão de CO₂

A metodologia de cálculo “do poço à roda” para veículos no Brasil, adaptada da cartilha publicada pela [Associação Brasileira de Engenharia Automotiva]. Esta cartilha sintetiza a relação entre consumo energético κ , intensidade de carbono ι e emissões de CO₂, adaptável a tratores agrícolas mediante integração de telemetria. O consumo energético pode ser calculado de acordo com a Equação (1):

$$\kappa = \delta \mathcal{A} \quad (1)$$

onde δ e \mathcal{A} respectivamente representam a densidade energética do combustível em (MJ/l) e autonomia em (l/km).

O κ varia de acordo com os parâmetros operacionais (ex.: carga, velocidade, inclinação do terreno), capturados via telemetria, o que traria a necessidade de cada modelo possuir uma constante diferente.

Contudo, a intensidade de carbono ι é definida pelo combustível (ex.: diesel B7 = 82.40CO₂/MJ), o que torna essa variável constante, nesse aspecto, traz-se a possibilidade de explorar a emissão apenas com a autonomia do combustível. Além disso, também conseguimos extrair as seguintes informações:

- **Coeficientes auditados:** IC para etanol, diesel e eletricidade, calculados para a matriz energética brasileira.
- **Alinhamento regulatório:** Projeções compatíveis com o Rota 2030, que poderá incluir tratores em fases futuras.

Desta forma, conseguimos estimar o consumo de CO₂ seguindo a Equação (2):

$$CO_{2eq} = \kappa \iota \quad (2)$$

Desta forma, por meio da Equação (2), estimamos a emissão de carbono para cada momento da base de dados, considerando atributos do veículo, como variáveis mecânicas, nível de combustível e velocidade. Esses dados permitem treinar um regressor e melhorar a precisão na previsão de emissões futuras.

3.2. Pré-processamento e Análise Exploratória de Dados

Os dados brutos coletados passaram por diversas etapas de pré-processamento, visando assegurar sua consistência e qualidade analítica. Inicialmente, foi realizada uma Análise Exploratória de Dados (EDA) utilizando ferramentas visuais como histogramas, *box-plots* e mapas de correlação, que permitiram avaliar a distribuição dos dados e identificar possíveis anomalias. Para a detecção de valores discrepantes (*outliers*), utilizou-se o método do Intervalo Interquartil (IQR):

$$IQR = Q_3 - Q_1, \quad (3)$$

sendo que um valor v é considerado um *outlier* se:

$$v < Q_1 - 1,5 \times IQR \quad \text{ou} \quad v > Q_3 + 1,5 \times IQR. \quad (4)$$

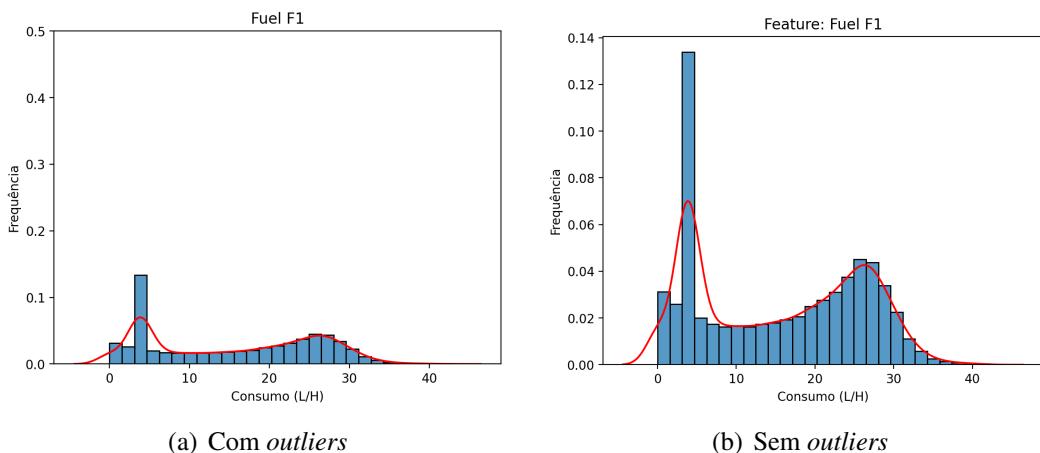


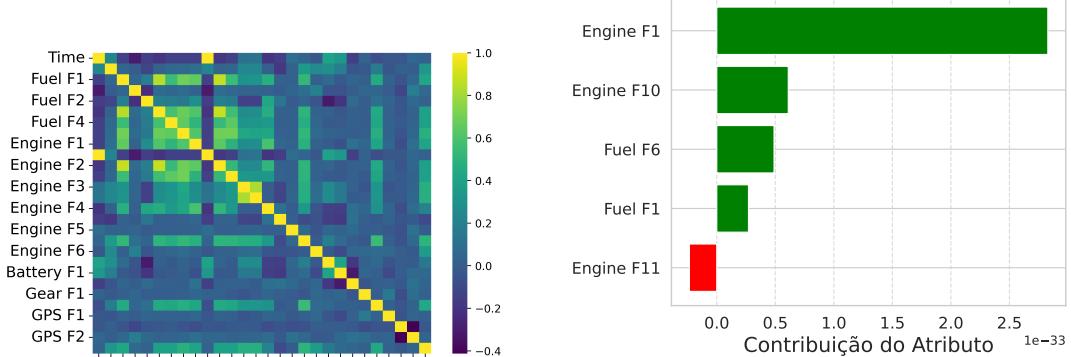
Figura 2. Comparação dos dados com e sem outliers.

Os *outliers* identificados foram removidos para evitar distorções nas análises estatísticas subsequentes e na modelagem preditiva. A Figura 2 ilustra, por meio de histogramas, a comparação de um atributo *Fuel*, entre os dados antes e depois da remoção dos valores extremos. Esse processo foi realizado para todas as variáveis, menos para os atributos *Gear*.

3.3. Seleção de Atributos e Análise de Correlação

A análise exploratória evidenciou que nem todas as variáveis disponíveis possuíam relevância significativa para a predição das emissões de CO₂. Assim, procedeu-se a uma análise de correlação detalhada, empregando tanto a correlação padrão quanto a correlação cruzada, com o intuito de identificar os atributos mais informativos.

Os resultados indicaram, por exemplo, que variáveis como o engate da marcha apresentaram forte correlação com o desempenho do motor e com os níveis de emissão de CO₂, enquanto atributos como a seleção de marcha demonstraram baixa relevância. Com base nessa análise, variáveis de baixa correlação — como as horas operacionais do motor — foram descartadas, visando reduzir a dimensionalidade e aumentar a eficiência do modelo. A Figura 3(a) apresenta a matriz de correlação das variáveis selecionadas, oferecendo uma visão abrangente das interdependências entre os atributos.



(a) Matriz de correlação entre os atributos selecionados.

(b) Importância dos atributos para a instância com menor erro, conforme LIME.

Além disso, Figura 3(a) sugere que, no conjunto de dados analisado, as variáveis dentro de cada grupo (como *Engine*, *Fuel*, *Gear* e *Battery*) apresentam correlações moderadas entre si, com algumas correlações mais fortes, como observado entre *Engine F1-F4*. Contudo, a correlação entre variáveis de diferentes grupos é fraca, o que indica que esses subsistemas funcionam de maneira relativamente independente. Adicionalmente, a variável *Time* não exibe correlação significativa com a maioria das outras variáveis, sugerindo a ausência de uma dependência temporal clara nos dados. Esses resultados indicam que, embora haja interdependência dentro de certos grupos, o comportamento geral dos dados é complexo, com pouca influência direta do tempo e interações limitadas entre os diferentes subsistemas analisados.

3.4. Aprimoramento da Interpretabilidade com LIME

Considerando que modelos de aprendizado de máquina complexos, como as redes neurais profundas, frequentemente se comportam como *caixas-pretas*, a interpretabilidade torna-se essencial para garantir a confiança nas previsões. Para mitigar essa limitação, foi aplicada a técnica LIME, que visa tornar as decisões do modelo mais transparentes.

O LIME atua gerando perturbações locais nos dados de entrada e construindo modelos interpretáveis (geralmente lineares) que aproximam o comportamento do modelo complexo em torno de uma instância específica. Essa abordagem possibilita quantificar a contribuição de cada atributo para uma previsão individual. Ao aplicar o LIME ao modelo de predição de emissões de CO₂, foi possível identificar quais variáveis, como a velocidade do motor, a temperatura do combustível ou o engate de marcha, têm maior influência sobre as previsões. Tal interpretabilidade não só valida a coerência do modelo, mas também facilita a adoção de suas recomendações por engenheiros e operadores. A Figura 3(b) ilustra a saída do LIME, destacando os atributos que mais contribuíram para aquela predição, seja negativamente ou positivamente. Neste caso, repare que a *Engine F1* tem um impacto positivo grande para a predição do exemplo, enquanto *Engine F11* tem um impacto negativo para aquela amostra.

Portanto, podemos resumir os passos necessários para o pré-processamento dos dados da seguinte forma:

- **Coleta de dados:** Aquisição de informações operacionais dos sensores dos sistemas de combustível, bateria, motor e transmissão.

- **Tratamento de outliers:** Identificação e remoção de valores extremos utilizando o método do IQR.
- **Análise exploratória:** Uso de técnicas visuais para inspecionar a distribuição dos dados e detectar anomalias.
- **Seleção de atributos:** Análise de correlação para identificar os atributos mais relevantes para a modelagem preditiva.
- **Interpretabilidade do modelo:** Aplicação da técnica LIME para aprimorar a transparência nas decisões do modelo.

A combinação de visualizações e técnicas explicativas forneceu uma base sólida para assegurar a qualidade dos dados e a eficácia da modelagem preditiva subsequente.

4. Benchmark

Para isso, analisamos dados operacionais coletados por sensores embarcados com o intuito de identificar padrões que orientem ajustes operacionais visando à otimização do consumo de combustível. Esta Seção descreve a metodologia adotada pelo nosso comparativo, com foco no tratamento e seleção de atributos, definição da arquitetura dos modelos e avaliação do impacto de variáveis críticas nas previsões.

4.1. Visão Geral do Processo

A Figura 3 apresenta o fluxo de processamento dos dados. Inicialmente, os dados dos veículos foram recebidos em formato bruto, com atributos distribuídos de forma desorganizada (1). Após a transformação estrutural, foi aplicado um filtro individual de atributos (2), reduzindo a dimensionalidade do conjunto de dados. Em seguida, o conjunto foi dividido em subconjuntos de treinamento e teste (3), com base em experimentos orientados por explicabilidade. Por fim, aplicou-se a normalização Min-Max (4), assegurando que todos os atributos permanecessem em escala compatível, sem vazamento de dados.

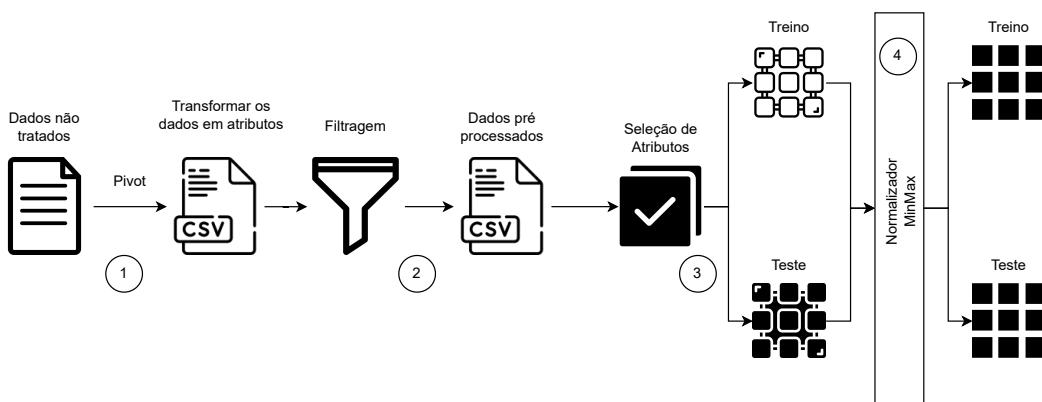


Figura 3. Visão geral do fluxo de dados utilizado na construção do modelo.

Métricas. Para avaliação dos modelos utilizamos, quatro métricas distintas, como MSE (Erro Quadrático Médio), MAE (Erro Absoluto Médio), RMSE (Raiz do Erro Quadrático Médio) e R2 (Coeficiente de Determinação). O MSE calcula a média dos quadrados das diferenças entre os valores reais e os previstos, penalizando grandes erros, o que pode ser útil para identificar discrepâncias significativas na previsão de CO₂. Já o

MAE mede a média dos erros absolutos, oferecendo uma visão mais direta da precisão do modelo sem amplificar os erros maiores, o que é útil para avaliações mais equilibradas. O RMSE é uma versão do MSE que, ao tirar a raiz quadrada, retorna os erros em uma unidade de medida mais próxima da variável original, facilitando a interpretação dos erros em contextos como a quantidade de CO₂ emitido. Por fim, o R2 mede a proporção da variabilidade nos dados que o modelo consegue explicar, ajudando a entender o quanto bem o modelo consegue capturar a dinâmica das emissões de CO₂ e sua capacidade de generalização. Essas métricas são fundamentais para ajustar e validar modelos preditivos que visam estimar com precisão os níveis de CO₂, auxiliando na tomada de decisões para mitigação das mudanças climáticas.

Nesta abordagem, foram exploradas diversas técnicas para prever as emissões de CO₂, abrangendo desde métodos estatísticos simples até estratégias avançadas de aprendizado profundo. Inicialmente, modelos lineares como a Regressão Linear (LR) foram considerados, dada sua capacidade de ajustar uma relação direta entre as variáveis preditoras e a emissão de CO₂, proporcionando uma interpretação clara dos resultados. Para lidar com possíveis problemas de multicolinearidade e reduzir o risco de *overfitting*, também foram aplicadas variações como a Ridge Regression (RR) e a Lasso Regression (Lasso), esta última auxiliando na seleção automática das variáveis mais relevantes, além do ElasticNet, que combina as vantagens dos métodos de penalização L1 e L2.

Adicionalmente, métodos baseados em árvores de decisão foram avaliados. O Decision Tree Regressor (DTR) segmenta os dados em regiões homogêneas, enquanto técnicas ensemble, como o Random Forest Regressor (RFR), o Gradient Boosting Regressor (GBR) e o AdaBoost Regressor, aumentam a robustez das previsões ao combinar os resultados de múltiplas árvores, sendo especialmente eficazes na modelagem de relações não lineares complexas.

Também foram investigadas abordagens baseadas em instâncias, como o K Nearest Neighbors Regressor (KNN), que realiza previsões com base na similaridade dos casos, e métodos probabilísticos, exemplificados pelo Gaussian Process Regressor (GPR), que modela a distribuição dos dados de maneira não paramétrica, proporcionando estimativas precisas mesmo em cenários de alta incerteza.

Por fim, técnicas de aprendizado profundo, como o MLP Regressor e o XGBoost, foram incorporadas para capturar relações intrincadas em grandes volumes de dados. Além disso, arquiteturas especializadas, como as Deep Neural Networks (DNN), as Recurrent Neural Networks (RNN) e suas variantes com Gated Recurrent Units (GRU), foram utilizadas para modelar dependências temporais e padrões evolutivos, aprimorando a capacidade de previsão em séries temporais.

Esta diversidade de modelos permite uma análise abrangente, contribuindo para identificar a abordagem mais adequada para a previsão das emissões de CO₂, bem como para compreender melhor as nuances e complexidades dos dados analisados.

5. Resultados

Nesta Seção, analisamos todos os resultados coletados acerca dos modelos explorados, assim como o impacto que a mineração inicial dos dados e o tratamento de interpretabilidade trouxeram.

Na Tabela 1, observamos que os modelos lineares, como KR, RR, Lasso e ElasticNet, apresentaram um desempenho insatisfatório, com R2 variando de -0.23 a -0.04 , indicando que não foram capazes de capturar bem os padrões dos dados. As Redes Neurais também obtiveram os piores resultados dentre os modelos avaliados, com RNN, GRU e DNN apresentando os piores valores de R2, chegando a -15.46 , -5.34 e -7.06 , respectivamente, além de métricas de erro elevadas. Em contraste, o KNN e o GPR tiveram desempenhos intermediários, com R2 variando entre -0.04 e 0.41 , sendo o primeiro superior ao segundo. A DTR obteve um R2 de 0.13 , superando os modelos lineares, mas com valores inferiores aos métodos de ensemble. Os modelos RFR e AdaBoost se destacaram com R2 de 0.52 e 0.49 , respectivamente, enquanto o GRB apresentou um desempenho inferior, com R2 negativo. O melhor desempenho foi obtido pelo XGBoost, que alcançou os menores valores de MSE, MAE e RMSE, além do maior R2 (0.54), destacando-se como a abordagem mais eficaz entre as avaliadas.

Tabela 1. Sumarização das métricas dos melhores modelos e seus desvios padrões.

| Modelos | Métricas | | | |
|-------------------|---|---|---|---|
| | MSE | MAE | RMSE | R2 |
| LR | 0.00063 ± 0.00118 | 0.01877 ± 0.01694 | 0.02528 ± 0.01694 | -0.22731 ± 0.02461 |
| RR | 0.00062 ± 0.00112 | 0.01857 ± 0.01667 | 0.02495 ± 0.01667 | -0.19552 ± 0.02391 |
| Lasso | 0.00054 ± 0.00094 | 0.01548 ± 0.01732 | 0.02324 ± 0.01732 | -0.03666 ± 0.02282 |
| ElasticNet | 0.00054 ± 0.00094 | 0.01548 ± 0.01732 | 0.02324 ± 0.01732 | -0.03666 ± 0.02282 |
| DTR | 0.00045 ± 0.00125 | 0.01481 ± 0.01536 | 0.02134 ± 0.01536 | 0.12578 ± 0.02033 |
| RFR | 0.00025 ± 0.00077 | 0.01089 ± 0.01148 | 0.01583 ± 0.01148 | 0.51897 ± 0.01582 |
| GRB | 0.00063 ± 0.00132 | 0.02122 ± 0.01374 | 0.02528 ± 0.01374 | -0.22707 ± 0.01914 |
| AdaBoost | 0.00026 ± 0.00093 | 0.00980 ± 0.01309 | 0.01635 ± 0.01309 | 0.48644 ± 0.01590 |
| SVR | 0.00302 ± 0.00391 | 0.04735 ± 0.02789 | 0.05496 ± 0.02789 | -4.79790 ± 0.02935 |
| KNN | 0.00030 ± 0.00103 | 0.00974 ± 0.01460 | 0.01755 ± 0.01460 | 0.40819 ± 0.01752 |
| GPR | 0.00054 ± 0.00112 | 0.01662 ± 0.01634 | 0.02331 ± 0.01634 | -0.04345 ± 0.02321 |
| MLP | 0.00115 ± 0.00194 | 0.02562 ± 0.02231 | 0.03398 ± 0.02231 | -1.21666 ± 0.03201 |
| XGBoost | 0.00023 ± 0.00077 | 0.01001 ± 0.01175 | 0.01544 ± 0.01175 | 0.54229 ± 0.01539 |
| DNN | 0.00420 ± 0.00445 | 0.05554 ± 0.03341 | 0.06482 ± 0.03341 | -7.06498 ± 0.03625 |
| GRU | 0.00332 ± 0.00171 | 0.05502 ± 0.01719 | 0.05764 ± 0.01719 | -5.34121 ± 0.02033 |
| RNN | 0.00862 ± 0.00896 | 0.07913 ± 0.04860 | 0.09287 ± 0.04860 | -15.45995 ± 0.05612 |

Para os modelos de redes neurais RNN e GRU, foram testados cinco tamanhos de contextos (5, 10, 15, 20 e 30), conforme apresentado na Tabela 2. O tamanho do contexto determina quantos passos anteriores são utilizados para realizar a previsão. De modo geral, observa-se que o aumento do contexto tende a melhorar o desempenho, mas contextos excessivamente grandes podem degradar a performance.

Na Tabela 2, observamos que, para contextos com tamanho menor, como 5 e 10, os erros permanecem elevados e o R2 assume valores fortemente negativos, sugerindo que os modelos não conseguem capturar bem a estrutura dos dados. Para a GRU, o R2 melhora de -4.48 (contexto 5) para -2.20 (contexto 10), enquanto na RNN, a variação é de -2.67 para -2.08 , indicando um ganho de desempenho, mas ainda insuficiente para serem melhores que apenas escolher a média. Com contextos de tamanho intermediário, entre 15 e 20, há melhoria significativa na performance da GRU, com o R2 subindo para -0.61 e -0.39 , respectivamente, acompanhada pela redução nos erros. Já na RNN, a variação apresenta comportamento sem padrão, com piora expressiva para contexto 15 (-7.34) e uma leve recuperação para 20 (-1.45). No entanto, ao expandir a contexto para 30, ambos os modelos sofrem uma deterioração severa no desempenho: a GRU atinge um R2 de -11.27 , enquanto a RNN retorna a -4.35 , acompanhados por um aumento significativo no MSE e RMSE. Esses resultados indicam um problema de *Vanishing Gradients*, ou seja, quando os gradientes ficam tão pequenos que impedem o aprendizado do modelo. Já para contextos intermediários tendem a oferecer um melhor equilíbrio entre erro e capacidade preditiva.

Tabela 2. Resultados variando o tamanho do contexto para RNN e GRU

| Modelo | Contexto | MSE | MAE | RMSE | R2 |
|--------|----------|---|---|---|--|
| GRU | 5 | 0.00287 ± 0.00242 | 0.05035 ± 0.01839 | 0.05360 ± 0.01839 | -4.48430 ± 0.01839 |
| | 10 | 0.00167 ± 0.00197 | 0.03296 ± 0.02425 | 0.04092 ± 0.02425 | -2.19625 ± 0.04057 |
| | 15 | 0.00084 ± 0.00141 | 0.02312 ± 0.01758 | 0.02905 ± 0.01758 | -0.61045 ± 0.02736 |
| | 20 | 0.00072 ± 0.00113 | 0.02055 ± 0.01742 | 0.02695 ± 0.01742 | -0.38606 ± 0.02568 |
| | 30 | 0.00642 ± 0.00302 | 0.07759 ± 0.02017 | 0.08017 ± 0.02017 | -11.26690 ± 0.02046 |
| RNN | 5 | 0.00192 ± 0.00367 | 0.03266 ± 0.02922 | 0.04383 ± 0.02922 | -2.66607 ± 0.04280 |
| | 10 | 0.00161 ± 0.00269 | 0.03190 ± 0.02446 | 0.04020 ± 0.02446 | -2.08469 ± 0.03700 |
| | 15 | 0.00437 ± 0.00352 | 0.05950 ± 0.02882 | 0.06611 ± 0.02882 | -7.34189 ± 0.06267 |
| | 20 | 0.00128 ± 0.00225 | 0.02869 ± 0.02148 | 0.03584 ± 0.02148 | -1.45162 ± 0.03150 |
| | 30 | 0.00280 ± 0.00324 | 0.04452 ± 0.02865 | 0.05295 ± 0.02865 | -4.35052 ± 0.05103 |

A Figura 4 apresenta a porcentagem de erros relativos de emissão real de CO_2 , calculada através da Equação (2), obtidas pelos quatro melhores modelos treinados. Em Figura 4(a), observa-se que o modelo DTR apresenta maior instabilidade entre os modelos avaliados, devido à sua natureza baseada em divisões discretas dos dados, sendo incapaz de representar em completude os valores reais. Ou seja uma dificuldade em capturar as pequenas variações contínuas da emissão real de CO_2 , resultando em uma representação menos suave e com perda de nuances importantes.

Por outro lado, ao analisarmos o GRB em Figura 4(b), pode-se notar uma melhoria na predição, comparada a obtida pelo DTR. Perceba que a porcentagem de erro é mais próxima de zero, ainda que apresente picos no erro, o modelo começa a responder melhor às flutuações sutis do sinal real. Por conta da sensibilidade às variações torna a curva mais próxima da realidade.

Ao observar as figuras 4(c) e 4(d), RFR e XGBoost respectivamente, nota-se uma

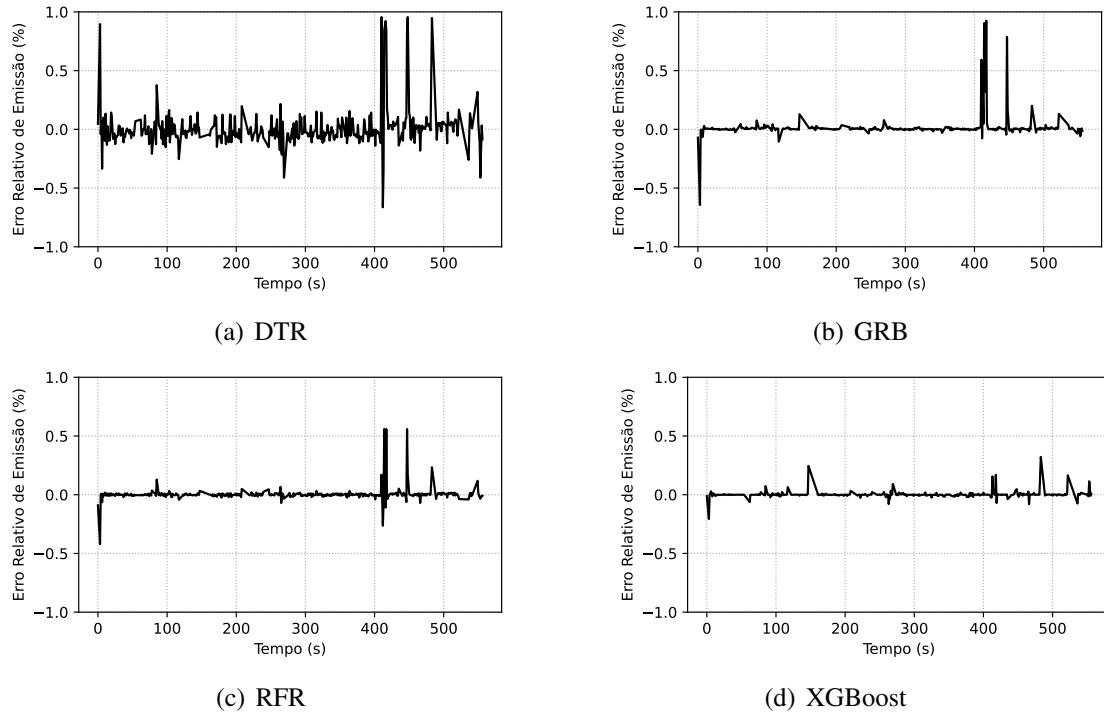


Figura 4. Previsão dos dados de teste para os 4 melhores modelos ao longo do tempo (segundos).

estabilidade maior das previsões. RFR apresenta um ruído maior que o XGBoost, que por sua vez, demonstra menores picos no erro relativo, além de todos valores serem abaixo de 50% do erro real. Isso sugere que o XGBoost não apenas tem uma maior sensibilidade às variações locais, mas também é capaz de modelar a emissão de CO₂ de forma mais contínua e coerente com o comportamento real do sistema.

Em conclusão, os modelos de ensemble, em particular o XGBoost, demonstraram ser os mais eficazes para prever as emissões de CO₂, superando outros métodos tanto em precisão quanto em sensibilidade às flutuações dos dados. A análise detalhada das previsões confirmou que o XGBoost apresenta o melhor equilíbrio entre ajuste aos picos e suavidade nas transições, sendo o modelo mais robusto para capturar as complexidades do sistema. Embora a GRB tenha mostrado um desempenho satisfatório, os métodos de ensemble, especialmente o XGBoost, mostraram-se superiores em termos de performance, validando sua escolha como o melhor modelo para as previsões em nosso estudo.

6. Conclusão

Este trabalho apresentou a análise de uma abordagem baseada em inteligência artificial para estimar e reduzir as emissões de CO₂ em dois tratores, com foco na integração entre técnicas de aprendizado profundo, pré-processamento rigoroso de dados e interpretabilidade por meio do LIME. A partir da coleta e análise de dados operacionais de sensores embarcados, conseguimos construir um benchmark de experimentos e identificar peculiaridades de dezenas de diferentes modelos para a tarefa de predição de CO₂.

Os experimentos demonstraram que a seleção adequada de atributos é fundamental para a qualidade das previsões. Modelos treinados com conjuntos reduzidos e bem

escolhidos de variáveis apresentaram desempenho superior em termos de generalização, especialmente quando guiados por ferramentas de interpretabilidade. Adicionalmente, os experimentos demonstraram que embora modelos complexos sejam úteis para a maioria dos casos, soluções como XGBoost ultrapassam por conta da sua natureza e robustez contra ruídos.

Os resultados obtidos reforçam o papel da IA como aliada estratégica na construção de soluções sustentáveis para o setor agrícola, permitindo não apenas prever emissões com alta acurácia, mas também compreender os fatores que mais as influenciam. A transparência proporcionada por técnicas como o LIME aumenta a confiança no uso dos modelos e abre espaço para decisões mais embasadas por parte de operadores, engenheiros e formuladores de políticas públicas.

Como trabalho futuro, pretende-se explorar abordagens mais sofisticadas para previsão em horizontes temporais maiores, como modelos híbridos e técnicas baseadas em séries temporais, além de expandir a base de dados com diferentes tipos de máquinas e condições operacionais. A incorporação de estratégias adaptativas de otimização em tempo real também se mostra promissora para reduzir emissões de forma contínua e personalizada.

Agradecimentos

Este projeto foi apoiado pelo Programa Mobilidade e Inovação Verde (Mover), linha VI, conectividade veicular. Fundação de Apoio à UFMG (Fundep). Projeto CO2nnect, nº 29271*13.

Referências

- Associação Brasileira de Engenharia Automotiva. Associação Brasileira de Engenharia Automotiva. <https://wwwaea.org.br/home/>. Acesso em: 3 abr. 2025.
- Associação Brasileira de Engenharia Automotiva (2025). Manifesto AEA em defesa da descarbonização.
- Banerjee, A. et al. (2024). Modeling sustainable city trips. *arXiv preprint arXiv:2401.00001*.
- de Souza, A. M., Braun, T., Botega, L. C., Villas, L. A., and Loureiro, A. A. F. (2020). Safe and sound: Driver safety-aware vehicle re-routing based on spatiotemporal information. *IEEE Transactions on Intelligent Transportation Systems*, 21(9):3973–3989.
- Grilli, M. (2020). Agropecuária foi responsável por 73% da emissão de co₂ do Brasil em 2019. *Revista Globo Rural*. Acesso em: 31 mar. 2025.
- Jin, L. (2024). Predição de emissões de co₂ em veículos agrícolas usando redes neurais profundas. *Journal of Agricultural Engineering*, 56(1):45–53.
- Jin, Y., Sharifi, A., Li, Z., Chen, S., Zeng, S., and Zhao, S. (2024). Carbon emission prediction models: A review. *Science of The Total Environment*, page 172319.
- Lee, K. and Zhang, H. (2024). Detecção e tratamento de outliers em dados de emissões para aprendizado de máquina. *Journal of Environmental Informatics*, 38(2):89–97.
- Lundberg, S. M. and Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.

- Ma, L., Chen, W., Zhao, R., et al. (2023). A deep learning framework for real-time emission prediction in agricultural machinery. *IEEE Access*, 11:111111–111123.
- Ministério do Meio Ambiente (2015). Acordo de Paris.
- Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). Explaining black box predictions using LIME. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 1135–1144.
- Ritchie, H., Rosado, P., and Roser, M. (2023). Data page: Per capita CO_2 emissions. <https://ourworldindata.org/grapher/co-emissions-per-capita>. Parte da publicação "CO₂ and Greenhouse Gas Emissions". Dados adaptados do Global Carbon Project e várias fontes. Acesso em: 31 mar. 2025.
- Ritchie, H. and Roser, M. (2024). CO_2 emissions.
- Silva, F. L., Eckert, J. J., Miranda, M. H., da Silva, S. F., Silva, L. C., and Dedini, F. G. (2024a). A comparative analysis of optimized gear shifting controls for minimizing fuel consumption and engine emissions using neural networks, fuzzy logic, and rule-based approaches. *Engineering Applications of Artificial Intelligence*, 135:108777.
- Silva, F. L. et al. (2024b). Optimized gear shifting controls for emission reduction. *Engineering Applications of Artificial Intelligence*, 95:104–112.
- Smith, J. and Wang, Y. (2024). Pré-processamento de dados para modelos de aprendizado de máquina na predição de emissões. *Environmental Modelling & Software*, 145:105–113.
- Vega, A. and Perkins, R. (2023). Avaliação de algoritmos de aprendizado de máquina na previsão de emissões em veículos agrícolas. *Revista Brasileira de Engenharia Agrícola*, 43(2):123–130.