

Sistema de Recomendação Sustentável para Máquinas Agrícolas com Técnicas de IA

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

¹Universidade Estadual de Campinas, Brasil

²SiDi – Instituto de Ciência, Tecnologia e Inovação

{r200219, c255785}@dac.unicamp.br

{lvillas, allanms}@unicamp.br

p.moura@sidi.org.br

Resumo. O setor agrícola tem um papel fundamental na economia brasileira, mas é também um dos principais emissores de Dióxido de Carbono (CO₂), impulsionado pela crescente mecanização e pelo uso intensivo de tratores pesados. A variabilidade no comportamento do operador e a carência de suporte à decisão em tempo real resultam em oscilações significativas no consumo de combustível e nas emissões de poluentes. Este trabalho propõe um sistema de recomendação baseado em Aprendizagem de Máquina (AM) para manter tratores em faixas ideais de operação. Utilizou-se uma Rede Neural Convolutiva (CNN) multitarefa, treinada com dados reais de sensores em quatro operações de campo, capaz de fornecer nove tipos de recomendações dinâmicas de RPM e velocidade. Os resultados experimentais demonstram que o modelo proposto alcançou um F1-Score superior a 99%, superando significativamente algoritmos clássicos como Random Forest e Gradient Boosting. A aplicação do sistema permitiu evitar 38,33% de CO₂ e gerou uma economia de 38,38% de diesel ao longo do ciclo de operação avaliado.

Abstract. The agricultural sector plays a fundamental role in the Brazilian economy, but it is also one of the main emitters of Carbon Dioxide (CO₂), driven by increasing mechanization and the intensive use of heavy tractors. Variability in operator behavior and the lack of real-time decision support result in significant fluctuations in fuel consumption and pollutant emissions. This work proposes a recommendation system based on Machine Learning (ML) to maintain tractors within ideal operating ranges. A multitasking Convolutional Neural Network (CNN), trained with real sensor data from four field operations, was used, capable of providing nine types of dynamic RPM and speed recommendations. The experimental results demonstrate that the proposed model achieved an F1-Score greater than 99%, significantly outperforming classic algorithms such as Random Forest and Gradient Boosting. The application of the system made it possible to avoid the emission of 38.33% of CO₂ and generated a gross saving of 38.38% liters of diesel over the evaluated operating cycle.

1. Introdução

É inegável que as ações humanas desde o início da era pré-industrial impactaram negativamente o clima no mundo. O *Our World in Data* relatou um crescimento exponencial a partir de 2000 em todo o mundo [Ritchie et al. 2023a]. De acordo com o

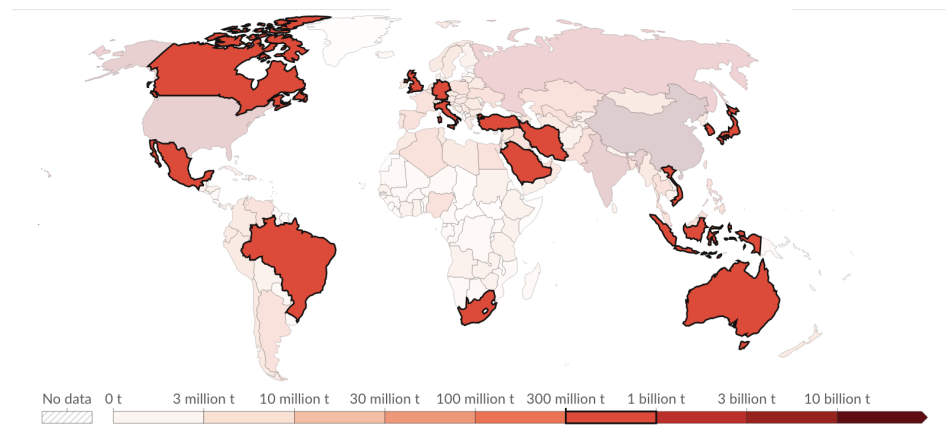


Figura 1. Emissões de dióxido de carbono (CO₂) provenientes de combustíveis fósseis e da indústria.

estudo, essas emissões continuam crescendo, atingindo cerca de 35 bilhões de toneladas a cada ano e são uma fonte de preocupação para as Nações Unidas. Este nível de emissões está gerando um grande número de mortes por poluição do ar e outras consequências diretas causadas pelos gases emitidos, sendo registrados em 2021 8 milhões de óbitos [Ritchie and Rosado 2025, Abd Alah and Ojekemi 2025]. Além disso, a emissão de Dióxido de carbono (CO₂) decorrente da queima de combustíveis fósseis e de atividades industriais vem apresentando um aumento gradual ao longo dos anos, conforme ilustrado na Figura 1 [Ritchie et al. 2023b]. Observa-se que o Brasil tem apresentado uma elevação progressiva em sua taxa de emissão, sendo que parcela significativa desses poluentes é associada aos sistemas de produção agrícola.

O Brasil apresentou 2,17 bilhões de toneladas de CO₂ em 2019, crescimento de 9,6% maior que em 2018. Destas emissões, 73% advêm de atividades agrícolas, totalizando 598,7 milhões de toneladas de CO₂ [Grilli 2020, Ritchie et al. 2023a]. Estes dados destacam a relevância do setor agrário nas emissões nacionais. A adoção de medidas como a eliminação do desmatamento, a recuperação de pastagens e a agricultura de baixo carbono (utilizando métodos de Aprendizado de Máquina (AM)) pode reduzir significativamente a pegada de carbono do agronegócio. Neste cenário, em 2025 o setor do agronegócio no Brasil apresentou um crescimento de 6,49% e destaca-se pela sua crescente automação [CEPEA - Centro de Estudos Avançados em Economia Aplicada 2026, Segatte 2025]. O uso intensivo 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.

Sivak e Schoettle [Sivak and Schoettle 2012] demonstraram que 30% das oscilações no consumo de combustível derivam do comportamento do condutor, especificamente da agressividade em acelerações, frenagens e no gerenciamento de marchas. Somados a isso, cenários que exigem reações imediatas a obstáculos e imprevistos elevam significativamente as emissões [Shahariar et al. 2022]. Diante desse contexto, embora a automação em veículos agrícolas avance, a intervenção humana permanece indispensável, exigindo que os operadores realizem pré-configurações complexas no veículo e nos implementos antes e durante a execução das tarefas. Surge, assim, a necessidade de sistemas

de recomendação que auxiliem o operador na tomada de decisão, garantindo que os ajustes da máquina estejam sempre alinhados à máxima eficiência energética.

Portanto, propomos um sistema de recomendação que integra técnicas avançadas de processamento de dados a um modelo de AM. O objetivo central é garantir que o operador mantenha-se dentro dos níveis recomendados de Rotação por Minuto (RPM) e Velocidade (V) durante a operação com tratores, visando diretamente à redução das emissões de CO₂. Embora o foco deste estudo seja o maquinário agrícola, o problema da variabilidade humana na condução e seu impacto nas emissões é transversal a frotas urbanas e de construção. A abordagem de *Green Computing* aqui proposta, utilizando sensoriamento e IA, dialoga diretamente com os desafios de poluição do ar enfrentados pelas grandes metrópoles. Além disso, esta abordagem diferencia-se por integrar dados reais de sensores provenientes de veículos agrícolas coletados em campo durante quatro operações distintas. As principais contribuições deste trabalho são:

- Sistema de recomendação especializado para operação agrícola capaz de fornecer 9 tipos de recomendação.
- Treinamento e validação em dados coletados em campo.
- Otimização e redução das emissões de CO₂ contribuindo com a sustentabilidade no agronegócio.

As seções subsequentes deste artigo estão organizadas da seguinte forma: A Seção 2 apresenta os principais trabalhos relacionados, destacando as abordagens existentes para sistemas de recomendação que para redução de emissões em veículos. A Seção 3 detalha a proposta metodológica da solução, incluindo o processo de coleta de dados e o desenvolvimento dos processos de rotulação. Em seguida Seção 4 mostra os resultados atingidos pela proposta. Finalmente, Seção 5 apresenta as conclusões e as possíveis pesquisas futuras.

2. Trabalhos Relacionados

A análise das emissões de CO₂ deve considerar tanto o agente emissor quanto os fatores que o influenciam. Banerjee et al [Banerjee et al. 2025], demonstraram que o uso de dados turísticos e sazonais pode otimizar rotas e reduzir o tráfego em regiões críticas, contribuindo para a diminuição das emissões. Os autores introduzem um indicador composto que integra não apenas as emissões de equivalentes de CO₂ baseadas no transporte, mas também variáveis de popularidade do destino e sazonalidade da demanda. Ao utilizar dados provenientes de plataformas como Tripadvisor, Google Trends e Airbnb, o estudo demonstra que a recomendação de rotas e destinos pode mitigar o impacto ambiental e social, evitando a sobrecarga das infraestruturas locais em períodos de pico. Essa perspectiva reforça a importância de uma visão sistêmica e orientada por dados, onde a compreensão das flutuações sazonais e do perfil da demanda é essencial para a formulação de estratégias eficazes na mitigação de emissões.

Da mesma forma, Monteiro et al. [Monteiro and Sousa 2024] adotam uma abordagem alinhada ao conceito “Well to Whell”, considerando todo o ciclo de vida dos veículos, desde a extração de insumos até o consumo de energia e o comportamento do condutor, destacando o impacto do tamanho e do desgaste de bateria. Além disso, os autores destacam que a sustentabilidade não é garantida apenas pela substituição tecnológica, identificando que modos de operação específicos, como o *Vehicle-to-Grid (V2G)*, podem

e elevar as emissões devido ao desgaste acelerado das baterias e às perdas energéticas nos ciclos de carga e descarga. Essa análise reforça a premissa de que a mitigação de gases poluentes exige a compreensão das interações entre os componentes do sistema e o comportamento operacional, validando a necessidade de estratégias que otimizem o uso dos recursos disponíveis.

Além disso, Lee et al. [Lee et al. 2025] investigam a importância de analisar os perfis de carga e a operação de sistemas híbridos (células de combustível e baterias) em navios de grande porte, identificando que as emissões de CO₂ são fortemente influenciadas pela estratégia de gerenciamento de energia. O estudo revela que operações de alta carga e a divisão de potência entre as fontes de energia são fatores críticos, demonstrando que uma distribuição ineficiente pode elevar significativamente a pegada de carbono. Essa análise reforça a necessidade de considerar as demandas específicas de cada fase operacional, destacando que a otimização em tempo real do sistema de propulsão é fundamental para garantir que o conjunto opere em sua faixa de máxima eficiência energética, independentemente das variações na carga de trabalho.

Compreender os fatores que permitem recomendar mudanças diretas na condução do veículo é essencial para reduzir o consumo e a emissão de gases poluentes. Silva et al. [Silva et al. 2024] realizam uma análise comparativa entre três abordagens para o controle de troca de marchas. Redes Neurais, lógica fuzzy e métodos baseados em regras. O estudo utiliza variáveis como torque requerido, velocidade angular e temperatura do combustível para prever o escalonamento ideal, demonstrando que o uso de modelos de AM pode reduzir significativamente o consumo de combustível e a emissão de poluentes em motores de combustão interna. Os resultados ressaltam que a implementação dessas estratégias de controle não apenas melhora a eficiência energética, mas também preserva o desempenho dinâmico do veículo, evidenciando o potencial da inteligência artificial em transformar parâmetros operacionais brutos em decisões de condução sustentáveis.

Somado a isso, diversos estudos exploram sistemas de recomendação de troca de marcas especificamente voltada à redução de consumo de combustível e das emissões de CO₂. Nesse contexto, Zhang et al. [Zhang et al. 2019] propuseram uma estratégia que mantém o motor operando próximo à sua linha de eficiência ideal, alcançando uma economia de 4% no combustível e um ganho de 6% no desempenho de condução. Complementarmente, o uso de Algoritmo Genético (AG) permitiu a otimização simultânea de desempenho e consumo, encontrando equilíbrios (trade-offs) que reduzem significativamente os gases poluentes sem sacrificar a dirigibilidade [Kim and Lee 2017]. Adicionalmente, o desenvolvimento de sistemas de cruzeiro preditivo para veículos pesados demonstrou que a cootimização do torque e das marchas em tempo real pode gerar economias de até 7,9%, sem comprometer o tempo de viagem [Müller et al. 2024].

A análise comparativa consolidada na Tabela 1 revela uma convergência na literatura para o uso de modelos de AM e integração de dados de sensores como meio de otimizar o consumo energético. Contudo, a predominância de estudos voltados a veículos leves e pesados evidencia que as estratégias de mitigação de CO₂ estão fortemente vinculadas a padrões de condução urbana ou logística de carga. A variabilidade inerente às operações agrícolas, que demandam ajustes constantes em função da interação máquina-solo-implemento, ainda não é plenamente contemplada por sistemas de recomendação que considerem a multiplicidade de operações em tempo real. Essa

Tabela 1. Apanhado do principal domínio de aplicação de cada trabalho da literatura em comparação a proposta, assim como qual foi a abordagem técnica utilizada e as suas principais variáveis e sensores considerados.

Referência	Domínio de Aplicação	Abordagem Técnica	Principais Variáveis / Sensores
[Banerjee et al. 2025]	Mobilidade Urbana e Turismo	Indicadores compostos e integração de dados externos.	Popularidade de destinos, sazonalidade, Tripadvisor/Google.
[Monteiro and Sousa 2024]	Veículos Elétricos (EV)	Ciclo de vida e impacto de carga/descarga.	Desgaste de bateria, modos V2G, comportamento do condutor.
[Lee et al. 2025]	Sistemas Navais Híbridos	Gerenciamento de energia e divisão de potência.	Perfis de carga, células de combustível e baterias.
[Silva et al. 2024]	Motores a Combustão Interna	Controle de troca de marchas.	Torque, velocidade angular e temperatura do combustível.
[Zhang et al. 2019]	Veículos Leves	Otimização de eficiência via AG e linha de eficiência ideal.	Relação torque-marcha e desempenho de condução.
[Kim and Lee 2017]	Veículos Leves	Otimização de eficiência via AG	Desempenho de condução com base em variáveis de <i>engine</i> .
[Müller et al. 2024]	Veículos Pesados	Cruzeiro preditivo e co-otimização em tempo real.	Telemetria, torque e marchas.
Este Trabalho	Maquinário Agrícola	Sistema de Recomendação baseado em AM	Uso de dados reais, 4 perfis de operações distintas e foco em um dos maiores emissores.

lacuna sinaliza a necessidade de abordagens que priorizem o suporte à decisão em ambientes não-estruturados, onde o operador exerce papel central na eficiência do sistema, indo além da otimização de componentes isolados.

Em que pese o valor das estratégias isoladas e dos modelos focados em veículos leves ou sistemas navais revisados anteriormente, subsiste uma lacuna no suporte à decisão para operadores de máquina agrícola em cenários reais de campo. Para preencher essa lacuna, este trabalho propõe um sistema de recomendação baseado em AM que, diferentemente das abordagens puramente mecânicas, utiliza dados de sensores de quatro operações distintas para guiar o operador na manutenção dos níveis de RPM e V. Dessa forma, o foco desloca-se da automação rígida para uma assistência especializada e dinâmica, capaz de converter a variabilidade do ambiente agrícola em reduções concretas de CO₂ e ganhos em sustentabilidade.

3. Sistema de Recomendação

Esta seção detalha a arquitetura do sistema proposto, fundamentando desde a modelagem matemática das emissões de CO₂ e abrangendo desde a coleta de dados em campo até a definição da função de perda do modelo neural. A abordagem estrutura-se em um fluxo contínuo de monitoramento e decisão, projetado para operar em tempo real.

Estimativa de emissões de CO₂. Antes de detalhar a arquitetura do sistema, é fundamental estabelecer uma das métricas alvo do estudo. A metodologia para o cálculo de emissões baseia-se no conceito “do poço à roda” (*Well-to-Wheel*), adaptada das diretrizes da Associação Brasileira de Engenharia Automotiva (AEA) [Associação Brasileira de Engenharia Automotiva]. Neste modelo, a emissão total de equivalentes de carbono (CO_{2eq}) é derivada do produto entre o consumo energético

(κ) e a intensidade de carbono do combustível (ι), conforme a Equação (1):

$$CO_{2eq} = \kappa \iota \quad (1)$$

O coeficiente ι é tratado como uma constante auditada para a matriz energética brasileira (ex: Diesel B7 ≈ 82.40 g CO_2/MJ), garantindo alinhamento regulatório com programas como o Rota 2030. Em contrapartida, o consumo energético κ é uma variável dinâmica, calculada pela Equação (2):

$$\kappa = \delta \mathcal{A} \quad (2)$$

onde δ representa a densidade energética do combustível (MJ/l) e \mathcal{A} a autonomia instantânea (l/km ou l/h). Ao integrar dados de telemetria, o sistema captura as flutuações de κ geradas por variáveis mecânicas (carga, velocidade e inclinação), permitindo atribuir um valor preciso de emissão para cada instância da base de dados e viabilizando o treinamento supervisionado do modelo.

Arquitetura do Sistema. Com a métrica de emissão definida, o sistema é estruturado conforme a visão geral apresentada na Figura 2.

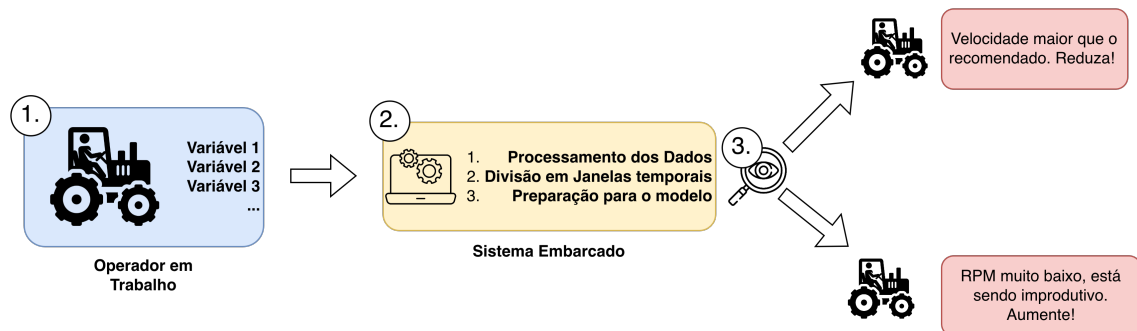


Figura 2. Visão geral do sistema de recomendação: (1) Coleta de variáveis em tempo real durante a operação; (2) Processamento embarcado com janelamento temporal; (3) Inferência multitarefa gerando recomendações de ajuste.

O fluxo de trabalho, apresentado na Figura 2, divide-se em três etapas que conectam a operação física ao suporte à decisão em tempo real:

1. **Operação e Coleta (Entrada de Dados):** Enquanto o operador conduz o trator em sua rotina de trabalho, diversos sensores monitoram o estado da máquina. Este processo gera um fluxo contínuo de dados telemétricos, representados por múltiplas variáveis (Variável 1, 2, 3, etc.), que abrangem parâmetros do motor e da transmissão.
2. **Processamento Embarcado (Tratamento e Estruturação):** Os dados brutos são enviados para o **Sistema Embarcado**, onde ocorre a inteligência de processamento local em três subetapas:
 - *Processamento dos Dados:* Limpeza e normalização dos sinais recebidos para eliminar ruídos.

- *Divisão em Janelas Temporais (windowing)*: Segmentação do fluxo contínuo de dados em blocos de tempo específicos, permitindo que o modelo analise o comportamento recente e não apenas um ponto isolado.
 - *Preparação para o modelo*: Formatação final dos dados para que sejam compatíveis com a arquitetura de aprendizado de máquina ou algoritmos de decisão utilizados.
3. **Análise e Recomendação (Saída de Feedback)**: Após o processamento, o sistema atua como um observador crítico (representado pelo ícone da lupa). O modelo analisa os padrões das janelas temporais e fornece *feedback* imediato ao operador através de alertas visuais ou sonoros. Conforme ilustrado, o sistema pode emitir recomendações corretivas específicas, como:
- **Alerta de Segurança/Eficiência**: "Velocidade maior que o recomendado. Reduza!", para evitar desgaste ou acidentes.
 - **Alerta de Produtividade**: "RPM muito baixo, está sendo improdutivo. Aumente!", visando otimizar a performance da máquina e o consumo de combustível.

Coleta de dados. Os dados foram coletados em uma fazenda com 3 tratores diferentes e 4 operações distintas (Distribuidor de Calcário, Grade Niveladora, Carreta Graneleira, Plantio). Cada operação foi dividida em 2 grupos, *Normal (N)*: onde o operador de máquina foi instruído a operar nas melhores condições e com melhor eficiência de combustível e *Agressivo (A)*: onde o operador foi instruído a conduzir a máquina com frenagens bruscas, acelerações agressivas, configurações de RPM e V inadequadas para operação, aumentando o consumo de combustível, reduzindo a eficiência e emitindo maior quantidade de CO₂. Ademais, ressalta-se que todos os dados foram anonimizados. Em conformidade com a Lei Geral de Proteção de Dados (LGPD) e protocolos de sigilo industrial, informações sensíveis sobre os modelos específicos dos veículos e a propriedade são mantidas sob acesso restrito.

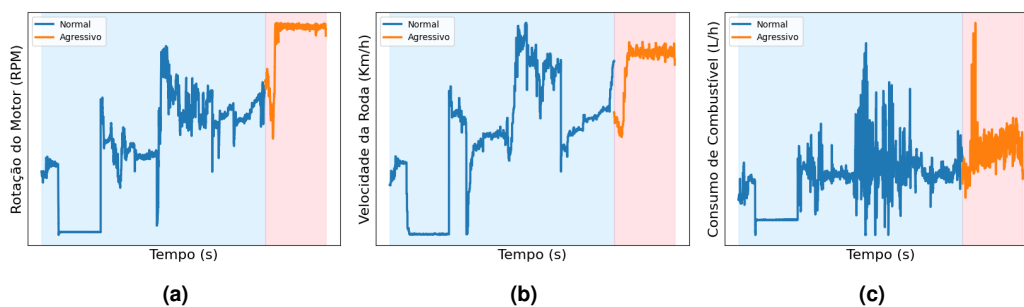


Figura 3. Exemplos dos dados coletados: 3a mostra o comportamento do motor em cada perfil, 3b mostra o comportamento da velocidade, 3c mostra o comportamento do consumo de combustível.

Como podemos observar, a Figura 3 mostra o comportamento das variáveis estudadas para uma operação, tanto N quanto A. Podemos perceber que ambos atingem os mesmos intervalos muito parecidos, porém o que difere são os padrões temporais das amostras.

A fim de garantir que os modelos absorvam mudanças temporais e detectem padrões de mudanças no comportamento de acordo com o tempo, adicionamos um janelamento através de *Lagged Features* para cada uma das variáveis utilizadas, ou seja,

RPM, V e o consumo de combustível. Através de um *gridsearch* identificamos que o janelamento ideal corresponde a 9s. Não há sobreposição de amostras entre janelas.

Definição do modelo. A arquitetura proposta, CNN-Recomendation (CNN-R), baseia-se em uma rede neural profunda multitarefa. O núcleo do modelo consiste em um bloco convolucional unidimensional que atua como extrator de características temporais, processando janelas deslizantes dos sinais dos sensores para capturar padrões dinâmicos da operação. Após a extração de *features* temporais, o modelo integra variáveis auxiliares estáticas ao vetor de características global. A tomada de decisão é realizada por duas cabeças de classificação independentes, permitindo a predição simultânea de diferentes categorias operacionais, ou seja, os estados recomendados de RPM e V como demonstrado na Figura 4.

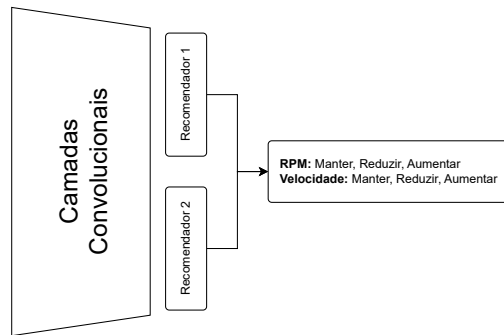


Figura 4. Arquitetura do modelo de recomendação.

O processo de treinamento do modelo é guiado por uma função de custo multitarefa, fundamentada na minimização simultânea do erro de predição de ambas as cabeças de classificação. Formalmente, a função de perda total L_{total} é definida como uma combinação linear das perdas individuais:

$$L_{total} = L_1(y_1, \hat{y}_1) + \lambda L_2(y_2, \hat{y}_2) \quad (3)$$

onde L_1 e L_2 representam a entropia cruzada categórica (Categorical Cross-Entropy) para as predições de RPM e V, respectivamente. Para uma classificação multi-classe com C categorias, a perda L_{CE} para um único exemplo é calculada como:

$$L_{CE}(y, \hat{y}) = - \sum_{c=1}^C y_c \log \left(\frac{e^{\hat{y}_c}}{\sum_{j=1}^C e^{\hat{y}_j}} \right) \quad (4)$$

Nesta formulação, y representa o vetor one-hot do rótulo real e \hat{y} denota o vetor de logits (saídas brutas) gerado pela rede. O termo $\frac{e^{\hat{y}_c}}{\sum_{j=1}^C e^{\hat{y}_j}}$ corresponde à função softmax, que normaliza os logits em uma distribuição de probabilidade. O hiperparâmetro $\lambda = 3$ é introduzido como um fator de ponderação escalar, conferindo maior peso à segunda tarefa de classificação. Isso é necessário visto que a V mostrou-se mais complexa de representar, acreditamos que é por conta da volatilidade superior a RPM que é mais sensível as operações manuais do operador. Essa estratégia de ponderação é adotada para priorizar a convergência de variáveis operacionais críticas, garantindo que o agente de recomendação apresente maior robustez nos parâmetros que impactam diretamente a eficiência energética e o consumo de combustível.

4. Resultados

Esta seção apresenta as análises dos experimentos realizados. Na Seção 4.1 apresentamos as métricas utilizadas para avaliar o modelo de recomendação. A Seção 4.2 descreve os resultados obtidos.

4.1. Métricas

Para quantificar a eficácia da arquitetura proposta e permitir a comparação com modelos da literatura, foram utilizadas quatro métricas fundamentais baseadas na matriz de confusão: Acurácia, Precisão, Revocação (Recall) e F1-Score. A utilização conjunta desses indicadores é essencial para garantir que o sistema de recomendação seja robusto tanto na identificação de estados de regime quanto nas transições operacionais.

- **Acurácia:** Representa a fração total de recomendações corretas (tanto para permanência quanto para ajustes de RPM e V) em relação ao total de amostras avaliadas. Embora seja um indicador de desempenho global, ela é complementada pelas demais métricas para evitar interpretações enviesadas em classes desbalanceadas.
- **Precisão:** Refere-se à capacidade do modelo em não classificar incorretamente uma operação como sendo de uma determinada categoria. No contexto deste trabalho, uma alta precisão indica que, quando o sistema recomenda um ajuste (como incremento de marcha), há uma alta probabilidade de que esse ajuste seja de fato necessário, minimizando “alarmes falsos” para o operador.
- **Revocação (Recall):** Mede a capacidade do modelo em identificar corretamente todas as instâncias de uma classe específica. Um *recall* elevado garante que o sistema não ignore oportunidades críticas de otimização, identificando prontamente todos os momentos em que o veículo sai das faixas ideais de RPM e V.
- **F1-Score:** Define-se como a média harmônica entre a Precisão e a Sensibilidade. Esta métrica é o indicador de desempenho mais robusto para o sistema de recomendação, pois exige que o modelo mantenha um equilíbrio entre a exatidão das sugestões e a abrangência da detecção de falhas operacionais.

Além das métricas de classificação, o trabalho utiliza indicadores de sustentabilidade para validar a eficácia prática da solução:

- **Consumo de Combustível (L/h e Total):** Mensura a eficiência energética direta. A redução do consumo por hora e do volume acumulado de diesel é o principal indicador de redução de custos operacionais para o produtor.
- **Emissões de CO₂ (Kg):** Calculada com base no fator de conversão do combustível consumido, esta métrica quantifica o benefício ambiental direto. A redução em kg de CO₂ evitados serve como evidência da contribuição do sistema para a agenda de agricultura de baixo carbono.

4.2. Análise dos experimentos

Dada a carência de estudos focados em sistemas de recomendação aplicados ao cenário agrícola, este trabalho investigou o desempenho de diferentes arquiteturas de aprendizado de máquina para validar a solução proposta. O modelo desenvolvido foi submetido a um processo de treinamento estendido por 50 épocas, cuja evolução e convergência podem ser observadas na Figura 5.




Figura 5. Convergência do treinamento executado por 50 épocas.

Para fins de validação, a arquitetura proposta foi comparada a três modelos de classificação amplamente consolidados na literatura. A Tabela 2 apresenta o desempenho dessas abordagens utilizando o conjunto de testes, composto por dados inéditos ao processo de treinamento, conforme as métricas detalhadas na Seção 4.1. Os resultados indicam um desempenho superior da arquitetura CNNR, que alcançou um F1-Score de 99% e índices de precisão e sensibilidade (recall) superiores a 0,99. Entre os métodos convencionais, o Random Forest apresentou-se como baseline mais competitivo, com acurácia de 0,8501. Em contraste, o algoritmo Gradient Boosting exibiu o desempenho mais modesto, com uma precisão de 0,5439, sugerindo uma vulnerabilidade maior a falsos positivos em comparação às demais técnicas avaliadas.

Tabela 2. Comparação entre diferentes modelos de ML para recomendação.

Modelo	Acurácia	Precisão	Recall	F1-Score
CNNR	0.996418	0.996253	0.996729	0.996486
Random Forest	0.850155	0.868157	0.841910	0.848343
Logistic Regression	0.773196	0.800428	0.764810	0.710920
Gradient Boosting	0.753769	0.543994	0.664554	0.590541

Em síntese, os resultados experimentais indicam a adequação do modelo proposto para o domínio de recomendação agrícola, apresentando desempenho superior ao dos classificadores convencionais testados. A vantagem da arquitetura CNNR frente ao Random Forest, segundo o algoritmo com melhor performance, é apoiada pela estabilidade das métricas, que se mantiveram em patamares próximos a 0,99. Tais evidências apontam para a viabilidade desta abordagem e a sugerem como uma forte candidata para a implementação do sistema de recomendação.

Também nos aprofundamos na análise das matrizes de confusão para as duas saídas de recomendação, conforme ilustrado na Figura 6. A arquitetura demonstrou uma capacidade superior de classificação com grande maioria das predições concentrada na diagonal principal, o que ratifica a precisão observada nas métricas globais.

No que diz respeito à recomendação V, observa-se um volume ligeiramente superior de classificações incorretas quando comparado à primeira cabeça do modelo. Es-

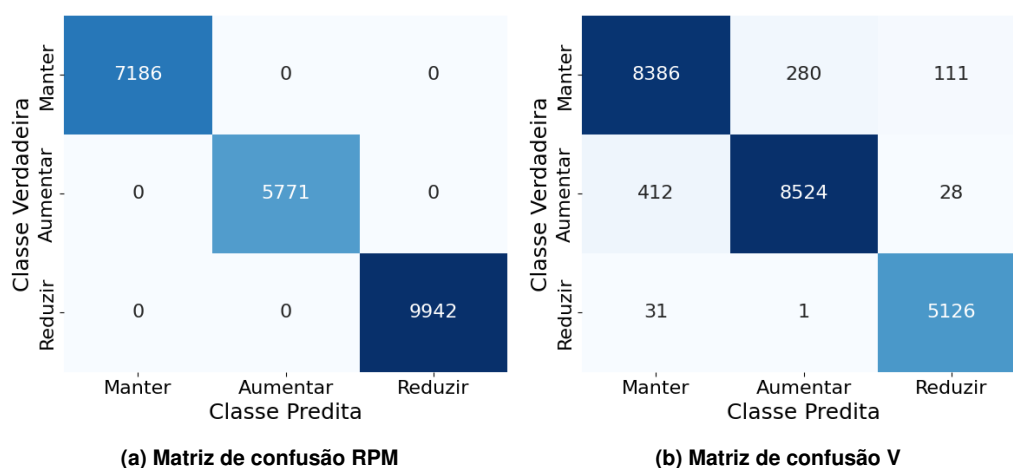


Figura 6. Matriz de confusão para cada cabeça de predição.

ses erros, contudo, ocorrem predominantemente entre classes adjacentes (por exemplo, a confusão entre o estado de permanência e a recomendação de incremento ou decréscimo leve). Esse comportamento é comum em dados de sensores reais de campo, onde as transições operacionais e ruídos de leitura podem criar zonas de incerteza nas fronteiras de decisão do modelo.

Por outro lado, a matriz referente à RPM apresenta desempenho bastante satisfatório, com raros casos de falsos-negativos. A alta densidade na diagonal principal em ambas as matrizes indica que o modelo não apenas aprendeu os padrões estáticos de cada operação, mas também demonstra capacidade para lidar com a variabilidade inerente aos dados coletados nos quatro diferentes cenários agrícolas avaliados.

Além da acurácia métrica, também realizamos uma análise teórica sobre a adesão estrita às recomendações do sistema, usando como base o consumo médio do melhor cenário das operações mostrado na Figura 7. Dessa forma, caso as recomendações sejam estritamente seguidas, conseguimos observar uma redução de 38,1% nas emissões totais de CO₂, indicando um potencial para a otimização direta dos processos mecanizados. Considerando o consumo de combustível referente ao trajeto percorrido, podemos estimar uma redução de 38,14% sobre o volume total, como demonstrado na Figura 8.

Os dados por operação indicam que o Nivelamento foi o fator de maior economia nominal, com 60,4% de ganho de eficiência, enquanto a operação de Plantio demonstrou o maior potencial de otimização relativa, atingindo 88,7% de redução nas emissões e no consumo. Em contrapartida, as variações negativas observadas nas operações de Distribuidor de Calcário e Carreta Graneleira (-1,9% e -20,6%, respectivamente) sugerem gargalos operacionais onde o consumo real superou o estimado, destacando a importância do monitoramento contínuo. Essas duas operações possuem um comportamento distinto das demais, sendo caracterizadas por frequentes variações de velocidade em função do relevo, o que pode justificar os resultados atípicos observados. Tais indicadores apontam que a correção do comportamento do operador em tempo real pode ser um caminho promissor para a redução do custo operacional por hectare e para favorecer o agronegócio de baixa emissão.




Figura 7. Estimativa da redução relativa de consumo e emissões de CO₂.

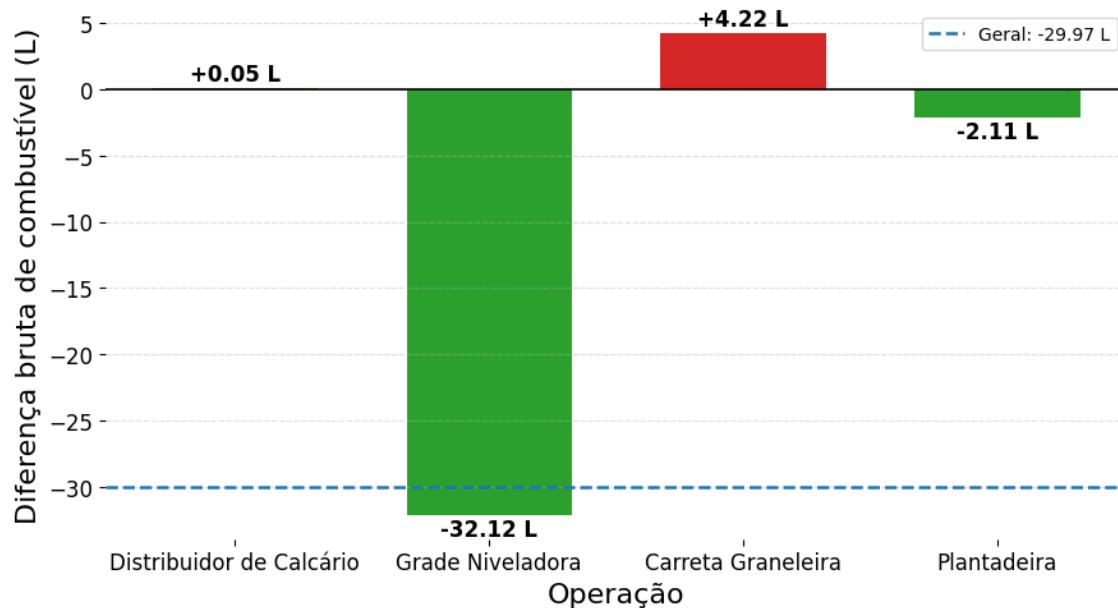


Figura 8. Estimativa da redução relativa de litros de combustível utilizado.

5. Conclusão

Este estudo apresentou o desenvolvimento e a validação de um sistema de recomendação inteligente voltado à otimização da operação de tratores agrícolas, fundamentado na convergência entre sensoriamento remoto e aprendizado de máquina. Diante do imperativo global de mitigação das mudanças climáticas, a solução proposta indicou que a integração de modelos de AM com dados de telemetria em tempo real pode ir além da análise descritiva, contribuindo para a transição do monitoramento passivo para uma ferramenta ativa

de suporte à decisão e sustentabilidade no campo.

O desempenho da arquitetura CNNR foi um dos destaques dos resultados experimentais. Ao superar modelos estatísticos tradicionais e arquiteturas de base com um F1-Score superior a 99%, o sistema demonstrou boa capacidade de extração de características em dados não lineares e ruidosos. A análise das matrizes de confusão sugeriu que a abordagem multitarefa é eficaz para dissociar a complexidade das variáveis de motor e transmissão, mantendo a estabilidade preditiva mesmo em regimes de alta transitoriedade operacional, onde erros residuais limitaram-se a zonas de transição suave de velocidade que tendem a não comprometer a integridade da recomendação.

Além da acurácia métrica, a relevância desta pesquisa é reforçada pela quantificação do impacto ambiental e da eficiência energética através de uma modelagem baseada em faixas de eficiência operacional. A adesão estrita às recomendações do sistema apontou para uma redução de 38,1% nas emissões totais de CO₂. Sob a ótica do consumo de combustível, a otimização algorítmica demonstrou uma economia de diesel para um trajeto total, o que equivale a uma redução de 38,14% no volume total consumido. Tais indicadores apontam que a correção do comportamento do operador em tempo real pode ser um caminho promissor para a redução do custo operacional por hectare e para favorecer o agronegócio de baixa emissão.

Em suma, este estudo busca contribuir com a literatura ao oferecer uma metodologia de ciclo fechado que converte dados brutos em indicadores mensuráveis de sustentabilidade. Como etapas subsequentes, a pesquisa direciona-se para a transposição deste modelo para dispositivos de computação de borda, visando avaliar a latência do sistema em condições severas de campo. Adicionalmente, pretende-se expandir a base de dados para contemplar a variabilidade de implementos agrícolas e diferentes tipologias de solo, com o intuito de avaliar esta arquitetura como um componente relevante para o avanço da Agricultura 4.0.

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

- Abd Alah, F. F. M. B. and Ojekemi, O. S. (2025). Quantile analysis of economic growth, foreign direct investment, and renewable energy on co2 emissions in brazil: Insights for sustainable development. *Energies*, 18(9):2256.
- Associação Brasileira de Engenharia Automotiva. Associação Brasileira de Engenharia Automotiva. <https://www.aea.org.br/home/>. Acesso em: 3 abr. 2025.
- Banerjee, A., Mahmudov, T., Adler, E., Aisyah, F. N., and Wörndl, W. (2025). Modeling sustainable city trips: integrating CO₂e emissions, popularity, and seasonality into tourism recommender systems. *Information Technology amp; Tourism*, 27(1):189–226.

- CEPEA - Centro de Estudos Avançados em Economia Aplicada (2026). Pib do agronegócio brasileiro. Acessado em: 29 jan. 2026.
- Grilli, M. (2020). Agropecuária foi responsável por 73% da emissão de CO_2 do Brasil em 2019. *Revista Globo Rural*. Acesso em: 31 mar. 2025.
- Kim, S.-h. and Lee, H.-j. (2017). Gear shifting multi-objective optimization to improve vehicle performance, fuel consumption, and engine emissions. *International Journal of Automotive Technology*, 18(4):645–653.
- Lee, J. I., Cha, S. W., and and, H. S. Y. (2025). CO_2 emissions of fuel-cell battery hybrid system for large ships. *International Journal of Green Energy*, 22(1):1–8.
- Monteiro, F. and Sousa, A. (2024). CO_2 emissions resulting from large-scale integration of electric vehicles using a macro perspective. *Applied Sciences*, 14(14).
- Müller, A., Schmidt, M., and Becker, T. (2024). Real-time co-optimization of gear shifting and engine torque for predictive cruise control of heavy-duty trucks. *Mechanical Sciences and Engineering*, 12:102–115.
- Ritchie, H. and Rosado, P. (2025). Air pollution kills millions every year — where does it come from? *Our World in Data*. <https://ourworldindata.org/air-pollution-sources>.
- Ritchie, H., Rosado, P., and Roser, M. (2023a). Co and greenhouse gas emissions. *Our World in Data*. <https://ourworldindata.org/co2-and-greenhouse-gas-emissions>.
- Ritchie, H., Rosado, P., and Roser, M. (2023b). 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.
- Segatte, L. (2025). Agronegócio: tudo sobre o pilar da economia brasileira. Acessado em: 29 jan. 2026.
- Shahariar, G. H., Bodisco, T. A., Zare, A., Sajjad, M., Jahirul, M., Chu Van, T., Bartlett, H., Ristovski, Z., and Brown, R. J. (2022). Impact of driving style and traffic condition on emissions and fuel consumption during real-world transient operation. *Fuel*, 319:123874.
- Silva, F. L., Eckert, J. J., Miranda, M. H., da Silva, S. F., Silva, L. C., and Dedini, F. G. (2024). 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.
- Sivak, M. and Schoettle, B. (2012). Eco-driving: Strategic, tactical, and operational decisions of the driver that influence vehicle fuel economy. *Transport Policy*, 22:96–99.
- Zhang, W., Chen, L., and Wang, J. (2019). An optimal gear shifting strategy for minimizing fuel consumption based on engine optimum operation line. In *SAE Technical Paper Series*, number 2019-01-5055. SAE International.