

MODELO PREDITIVO PARA ANÁLISE DO CICLO DE VIDA NO CONTEXTO DO PROGRAMA NACIONAL DE BIOCOMBUSTÍVEIS

Alvaro Luz Alves Coutinho¹.

Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ/USP), Piracicaba, SP.

<http://lattes.cnpq.br/6700608461027458>

RESUMO: As metas globais de descarbonização estabelecidas no âmbito da UNFCCC impulsionaram o desenvolvimento de instrumentos de regulação baseados no mercado. No Brasil, o Renovabio instituiu os Créditos de Descarbonização como mecanismo de incentivo à produção e uso de biocombustíveis com menor Intensidade de Carbono. Neste estudo, avaliamos a potencial redução de emissões de gases de efeito estufa na etapa agrícola da cadeia do etanol de cana-de-açúcar de primeira geração na região Centro-Sul do Brasil, a partir da modelagem de Análise de Ciclo de Vida e técnicas de Aprendizado de Máquina Automatizado. Foram definidos seis cenários de mitigação, variando a intensidade de redução no uso de diesel e nitrato de amônio. O cenário de mitigação acelerada de ambos insumos proporciona a redução acumulada de 2,6 milhões toneladas de CO₂ equivalente, o que representaria até R\$ 76,97 milhões em valor de mercado, em 2023. A abordagem integrada contribui metodologicamente para análise de sensibilidade dos efeitos de mitigação de emissões de GEE no contexto do sistema Renovabio.

PALAVRAS-CHAVE: Biocombustíveis. Aprendizado de Máquina. Análise do Ciclo de Vida.

PREDICTIVE MODEL FOR LIFE CYCLE ASSESSMENT IN CONTEXT OF BRAZIL'S NATIONAL BIOFUELS PROGRAM

ABSTRACT: Global decarbonization targets established under the UNFCCC have driven the development of market-based regulatory instruments. In Brazil, Renovabio introduced Decarbonization Credits as an incentive mechanism for the production and use of biofuels with lower Carbon Intensity. In this study, we assess the potential reduction of greenhouse gas emissions in the agricultural stage of the first-generation sugarcane ethanol production chain in Brazil's central-southern region, using Life Cycle Assessment modeling and Automated Machine Learning techniques. Six mitigation scenarios were defined, varying the intensity of reductions in the use of diesel and ammonium nitrate. The accelerated mitigation scenario for both inputs would lead to a cumulative reduction of 2.6 million tons of CO₂ equivalent, representing up to R\$ 76.97 million in market value by 2023. The integrated

approach contributes methodologically to the sensitivity analysis of GHG mitigation effects within the RenovaBio system context.

KEY-WORDS: Biofuels. Machine Learning. Life-cycle Assessment.

INTRODUÇÃO

A Convenção-Quadro das Nações Unidas sobre a Mudança do Clima estabelece esforços para reduzir as emissões de gases de efeito estufa (GEE) por meio de metas de descarbonização (LÁZARO et al, 2023). Um dos procedimentos para regulação das emissões de GEE são as ferramentas de medição chamadas *cap-and-trade* (UNFCCC, 2024). Essa metodologia cria um tipo de commodity atrelada às metas de redução da Intensidade de Carbono (IC) em um dado setor da economia (BENTO; VIEIRA FILHO, 2023). Os mercados de carbono traduzem uma unidade de crédito a uma tonelada de CO₂ equivalente (UNFCCC, 2024). De forma complementar, o Acordo de Paris estabelece a metodologia de contabilidade e transparência para promover a autodeclaração das metas climáticas para cada país subscrito (BODANSKY, 2021).

Essas metas chamadas de Contribuição Nacionalmente Determinada (NDC, em inglês) são comunicadas de forma quinquenal com informações que denotam as medidas de mitigação doméstica (UNFCCC, 2024). A última NDC brasileira, nos termos do Acordo de Paris, propôs a redução para 1,32 bilhões tCO₂eq (-48%) e 1,20 bilhões tCO₂eq (-53%) (ano base 2005) nos anos de 2025 e 2030, respectivamente (OBSERVATÓRIO DO CLIMA, 2021) (BRASIL, 2023). Para o setor de Bioenergia e Combustíveis foi inovado os Créditos de Descarbonização (CBIOS) instituídos pelo Programa Nacional de Biocombustíveis (BRASIL, 2017).

O Renovabio possui como princípio o atendimento das NDC por meio do incentivo ao aumento da participação de biocombustíveis na matriz energética, visando a redução de emissão GEE na produção, comercialização e uso (BRASIL, 2017) (BENTO; VIEIRA FILHO, 2023). As metas anuais de redução de emissão de GEE dentro do setor são projetadas em um horizonte decenal, em que o montante definido a cada distribuidor de combustível fóssil é proporcional à sua participação no mercado (ANP, 2023). Projeta-se nessa meta a redução programática e gradual da IC no setor de combustíveis em -11,37% (ano base 2018), estabelecendo para o final do decênio (2025-2034) a meta compulsória de 72,54 milhões de CBIOS (MME, 2024).

O princípio metodológico do Renovabio é a Análise de Ciclo de Vida (ACV), na forma de *well-to-wheel* (do poço à roda), seguindo as diretrizes estabelecidas pela norma ISO 14.040:2016 (ABNT, 2014). Considera-se as etapas agrícolas e industriais para cômputo da Nota de Eficiência Energética Ambiental (NEEA) de determinado volume de biocombustível produzido pelo emissor primário, expresso em gramas de CO₂ equivalente por MJ (SCACHETTI et al. 2018). A ACV incorpora todos os estágios do ciclo de vida do

produto, desde a extração de matérias-primas até tratamento de resíduos, o consumo de recursos naturais e os impactos ambientais. Também identifica oportunidades de melhoria no desempenho ambiental do produto ou atividade ao longo do ciclo de vida (XAVIER; CALDEIRA-PIRES, 2004).

A fase agrícola contribui significativamente para as emissões de GEE do etanol, sendo as principais práticas poluentes o uso de calcário, insumos nitrogenados, queima de resíduos agrícolas e consumo de combustível fóssil em operações mecanizadas (FOLEGATTI- MATSUURA, 2018). Na etapa agrícola mede-se o impacto da produção de matéria prima na emissão de GEE, expresso em $\text{kgCO}_2\text{eq/t}$ de matéria prima (FORNARO et al, 2023). Pinto (2023), aponta que a fase agrícola representa 86,8% da IC total da rota do etanol de primeira geração a base de cana-de-açúcar (E1GC), tendo como média 23.94 e desvio padrão de 5.1 $\text{gCO}_2\text{eq/MJ}$.

O valor de IC resultante da etapa agrícola é somado ao impacto da produção do biocombustível dentro da usina, considera-se o transporte de matéria prima, o nível de tecnologia e tipo de combustível produzido (FOLEGATTI- MATSUURA, 2018). A diferença entre a IC do biocombustível e de seu combustível substituto é feita para obter-se a Nota de Eficiência Energética Ambiental (NEEA, expressa em $\text{gCO}_2\text{eq/MJ}$). AACV utilizada pelo Renovabio é modelada utilizando a ferramenta RenovaCalc. Essa modelagem utiliza da base de dados ecoinvent v.3.1 e Global Feed LCA Institute (GFLI), além de informações da Embrapa, IBGE, Conab e de parâmetros setoriais para cada rota tecnológica disponível (RAMOS et al. 2024).

A ferramenta solicita ao usuário a inserção de parâmetros na etapa agrícola, expressos em volume de insumo utilizado por tonelada de biomassa (SCACHETTI et al. 2018). Modelos de ACV podem preconizar análises de sensibilidade para determinar parâmetros do sistema que contribuem mais ou menos para o resultado (GLADISH et al. 2018). Análises de sensibilidade são conduzidas definindo o modelo, suas variáveis independentes e dependentes, atribuindo funções de densidade de probabilidade e calculando um vetor de saída, finalmente, avaliando as influências e a importância relativa de cada relação de entrada e saída (HAMBY, 1994).

Para abordagens de estimação em modelos de ACV para produção agrícola utilizando bases de dados amplas e heterogêneas, modelos matemáticos tradicionais são limitados em identificar relações complexas (XUE ROMEIKO, 2020). Neste sentido, Aprendizagem de Máquina (ML, em inglês) é uma classe da inteligência artificial, ao qual inclui-se uma variedade de métodos de processamento de dados, sendo seus principais ramos, abordagens supervisionadas e não supervisionadas. Modelos de regressão ocupam a categoria do aprendizado supervisionado, o objetivo de regressões é prever valores de um ou mais variáveis resposta contínuos dado o valor dimensional de valores preditivos (BISHOP, 2006).

Dado um grupo de dados, composto de observações, onde junto com suas correspondentes variáveis resposta, o objetivo é prever o valor de t para cada novo valor de x . Através dessa distribuição condicional obtém-se previsões de tal forma a minimizar o valor esperado da função de perda, como por exemplo, o erro quadrado (BISHOP, 2006). Por meio do uso do teste destas funções de perda e pela otimização de hiperparâmetros, técnicas de ML automatizados (AutoML) realizam decisões baseadas nos dados apresentados pelos usuários (SALEHIN et al. 2024). AutoML possibilita determinar qual melhor modelo de regressão para explicar o conjunto de dados oferecidos sem necessidade de aprofundamento nos mecanismos inerentes ao funcionamento de cada modelo de aprendizado supervisionado (HUTTER; KOTTHOFF; VANSSCHOREN, 2019).

Para as safras de cana-de-açúcar de 2019, 2020 e 2021, seis estados representam 99,6% do total produzido no país, sendo São Paulo responsável por 57% da produção nacional (RAMOS et al, 2024). Estes estados pertencem a região canavieira centro-sul, que desempenha um papel importante na economia brasileira contribuindo significativamente para a matriz energética renovável e para o setor agroindustrial (SOUZA et al. 2015). Refere-se a uma área geográfica em que o clima favorável e a disponibilidade de terras propícias ao cultivo da cana-de-açúcar são fatores-chave que impulsionam a importância econômica dessa região (VEDANA et al. 2019).

Utilizando dados agrícolas primários das unidades produtoras de etanol certificadas entre 2018 e 2022, Ramos et al (2024) realiza a caracterização do sistema “típico” de produção da cana-de-açúcar a partir da média ponderada dos dados agrícolas, considerando os parâmetros técnicos presentes na RenovaCalc. O perfil “típico” estadual, teve o cálculo da IC realizado diretamente na RenovaCalc, obtendo valores entre 34,5 e 46,7 kgCO₂eq/t (v.7). Foram usados índices de eficiência calculados considerando área de 100 ha e a produção baseada em produtividade média de 68,67 t/ha de colmos.

As diferenças na IC da cana-de-açúcar entre os estados ocorreram principalmente em função das taxas de queima e na variação no consumo dos insumos (RAMOS et al. 2024). Pinto (2023), a partir da análise da NEEA do banco de dados de 167 usinas certificadas, aponta que a redução potencial de IC na fase agrícola é de 70%. Liu et al. (2023), utilizando dados de 67 usinas brasileiras, estimaram uma IC média de 35,2 gCO₂eq/MJ de etanol produzido, sendo as principais fontes de emissão identificadas são oriundas das emissões de N₂O no campo (24,3%), o uso de energia na fase de cultivo (24,2%) e o transporte do etanol (19,3%).

OBJETIVO

O objetivo principal deste trabalho é desenvolver um modelo preditivo, a partir da integração da Análise de Ciclo de Vida (ACV) e técnicas de Aprendizado de Máquina Automatizado (AutoML), para simular a Intensidade de Carbono (IC) na etapa agrícola da produção de etanol de primeira geração a partir da cana-de-açúcar (E1GC) na região

Centro-Sul do Brasil. A pesquisa visa modelar o sistema produtivo no contexto dos perfis validados pelo programa Renovabio, utilizando a ferramenta RenovaCalc como base para o cálculo da variável resposta. Como objetivos secundários, o estudo busca identificar as variáveis de maior influência na composição da Intensidade de Carbono agrícola; realizar uma análise de sensibilidade para quantificar o impacto de variações nos insumos mais relevantes; e, por fim, avaliar o potencial de mitigação de emissões de gases de efeito estufa (GEE) a partir da simulação de diferentes cenários de redução no uso de diesel e fertilizantes nitrogenados.

METODOLOGIA

Este estudo aborda uma sistemática de ML supervisionado que visa modelar e simular a IC, expressa em $\text{gCO}_2\text{eq/t}$ de cana-de-açúcar, associada à produção agrícola da cana no Brasil no contexto dos perfis validados pela política Renovabio segundo Ramos et al. (2024). A metodologia sugerida tem como referência o método proposto por Silva et al. (2011) segue abordagem quantitativa, composta por simulação estocástica, modelagem preditiva automatizada e análise de cenários, conforme descrito nas etapas a seguir. A análise de sensibilidade é baseada nos trabalhos de Kinpara (2020) e Scachetti et al. (2018). As análises foram realizadas em ambiente computacional do *Google Colab*, a partir de diferentes bibliotecas em *Python* 3.11.

Foram considerados para modelagem: os corretivos utilizados no preparo de solo (kg/t cana), fertilizantes sintéticos utilizados (kg/t cana), quantidade de fertilizantes orgânicos e/ou organominerais (V/t cana) e as fontes energéticas utilizadas no processo produtivo, por exemplo, diesel (L/t cana) e eletricidade (kWh/t cana) (FOLEGATTI-MATSUURA, 2018). A base de dados utilizada incluiu 48 variáveis preditivas. Foi conduzida uma simulação com 1.000 amostras sintéticas, utilizando distribuições normais parametrizadas com médias e desvios padrão fornecidos por estado (Ramos et al. 2018). A variável resposta é a IC da etapa agrícola do cultivo de cana-de-açúcar, calculada por meio do RenovaCalc.

A base de dados simulada foi dividida em conjuntos de treino e teste. A modelagem da variável resposta foi realizada utilizando abordagem *AutoML* e a identificação das variáveis preditoras com maior influência sobre a IC foi realizada por meio de múltiplas abordagens complementares de análise de importância de atributos. Com base nos insumos de maior impacto e pela análise de sensibilidade foram definidos cenários hipotéticos de mitigação de carbono. A simulação dos cenários foi realizada por meio de função que altera os valores das colunas correspondentes por meio de multiplicação por fatores de redução.

Os dados ajustados foram submetidos ao modelo *Bayesian Ridge Regression* previamente treinado para estimar a nova IC associada a cada cenário. As IC estimadas foram multiplicadas pela produção estadual anual de cana-de-açúcar (em toneladas) para estimar as emissões totais em tCO_2eq por estado. Foram considerados os principais estados produtores da região Centro-Sul: São Paulo (SP), Goiás (GO), Minas Gerais (MG)

e Mato Grosso do Sul (MS).

RESULTADOS E DISCUSSÃO

O modelo com melhor desempenho identificado pelo AutoML foi o *Bayesian Ridge Regression*, que obteve erro absoluto médio (MAE) de 0,331, erro quadrático médio (MSE) 0,825 e coeficiente de determinação (R^2) de 0,948. Os hiperparâmetros adotados incluíram baixa regularização nos termos *alpha_1*, *alpha_2*, *lambda_1* e *lambda_2* (todos em 10^{-6}), permitindo maior flexibilidade no ajuste dos coeficientes. O modelo estimou automaticamente os valores iniciais (*alpha_init*, *lambda_init*), ajustou o intercepto e utilizou convergência com tolerância de 0.001, resultando em um ajuste eficiente e preciso para os dados avaliados.


Foi realizada a avaliação de importância das variáveis para ranquear os insumos que mais influenciam a IC. Esse procedimento tem como objetivo quantificar a contribuição de cada variável preditora no comportamento da variável resposta. A análise evidencia o nitrato de amônio, a uréia, fosfato monoamônico (MAP) e o diesel BX como os quatro insumos com maior importância relativa no modelo. A Tabela 1 apresenta os valores de média e desvio padrão para os quatro insumos de maior impacto, bem como para a variável resposta do modelo, a IC.

Tabela 4. Média e desvio padrão para os insumos de maior impacto e para variável resposta (IC).

Variável	un.	Média	Desvio Padrão
Nitrato de amônio	kg/t	0,413	0,220
Ureia	kg/t	0,239	0,139
Diesel - BX	L/t	1,161	0,597
Fosfato Monoamônico (MAP)	kg/t	0,080	0,029
Intensidade de Carbono (IC)	gCO ₂ eq/t	26,057	4,026

Análise de sensibilidade possui o propósito de aferir a confiabilidade nos resultados finais da modelagem em ACV (EUROPEAN COMMISSION - JRC, 2010). Análise local de sensibilidade (ALS) possui como objetivo avaliar o impacto nas variáveis resposta a partir de uma pequena perturbação nos insumos de referência (WEI et al. 2014). Neste sentido, a partir do modelo de regressão, é possível propor a ALS para os insumos de maior impacto na IC do sistema estudado. A sensibilidade é expressa como o coeficiente da variação absoluta da variável resposta (IC) em relação a uma variação percentual dos insumos de maior impacto identificados (uréia, diesel, nitrato de amônia e fosfato MAP).

Figura 1. Sensibilidade da intensidade de carbono em função do uso dos insumos agrícolas.




A Figura 1 ilustra a análise de sensibilidade: o eixo horizontal ilustra a redução percentual do insumo, variando de 0% (uso total atual) a 100% (eliminação completa do insumo), enquanto o eixo vertical apresenta a IC prevista. A cada 1% de redução no uso de uréia, estima-se uma diminuição de 0,0106 kgCO₂eq/t. O impacto é mais expressivo para o nitrato de amônio e o diesel, cujas reduções de 1% implicam em decréscimos médios de 0,0309 kgCO₂eq/t e 0,0370 kgCO₂eq/t, respectivamente. Já o fosfato MAP apresenta influência mais modesta, com uma redução média estimada de 0,0023 kgCO₂eq/t a cada 1% de diminuição de uso.

Os seis cenários de mitigação avaliados neste estudo foram definidos com base na aplicação progressiva de reduções percentuais nos insumos de maior coeficiente de sensibilidade e elasticidade: o Nitrato de Amônio e o Diesel. Foram considerados dois níveis de intensidade de mitigação, redução gradual (1% ao ano) e redução acelerada (2% ao ano), e três combinações distintas de tratamento: i) redução exclusiva do nitrato de amônio; ii) redução exclusiva do diesel; e iii) redução simultânea de ambos os insumos. Esses cenários foram aplicados cumulativamente ao longo do período de 2017 a 2023. Os cenários que combinam a mitigação simultânea de ambos insumos resultam nas maiores reduções acumuladas de IC, com destaque para o cenário de redução acelerada de ambos insumos, que atinge 0,95 kgCO₂eq/t de biomassa em 2023.

A Figura 2 exibe os resultados em termos absolutos, isto é, a redução total agregada das emissões de GEE expressa em tCO₂eq para cada cenário e ano. Os valores foram obtidos a partir da multiplicação das reduções estimadas de IC pelas quantidades totais de produção agrícola anual nos seis estados analisados (IBGE, 2025). Os resultados indicam que o cenário com redução acelerada de ambos os insumos (2% ao ano) evitaria cerca de 2,6 milhões de toneladas de CO₂ equivalente até 2023. Com o cenário mais conservador,

com redução gradual de ambos insumos, resultam em reduções acumuladas superiores a 1 milhão de tCO₂eq ao longo do período de análise.

Figura 2. Projeção da redução de GEE (tCO₂eq) para diferentes cenários entre 2017 e 2023.



A Tabela 5 apresenta uma estimativa do potencial de mitigação de emissões de GEE decorrente da aplicação do cenário de redução acelerada de ambos os insumos na atividade canvieira para produção de E1GC da região Centro-Sul do Brasil no contexto do Renovabio, para o período de 2019 a 2023. Essa análise tem como base a projeção de redução cumulativa da IC e sua conversão em emissões evitadas e potenciais ganhos econômicos com CBIOs a partir das metas definidas e média de valor de mercado (MME, 2025).

Tabela 5. Resumo das projeções em redução de IC, GEE evitado, percentual da meta e ganho nominal pela adoção do cenário de redução acelerada dos insumos.

Ano	un.	2019	2020	2021	2022	2023
Produção	(milhões t)	691,11	694,78	651,09	660,12	712,68
Redução IC	(kg CO2eq/t)	0,41	0,54	0,68	0,81	0,95
GEE evitado	(mil t CO2eq)	281,56	377,40	442,09	537,87	677,47
Meta CBIO	(t CO2eq)	16,80	28,70	41,00	49,80	59,60
Perc. da meta	(%)	1,676%	1,315%	1,078%	1,080%	1,137%
Valor méd. CBIO	(R\$)	---	R\$ 43,66	R\$ 39,31	R\$ 111,63	R\$ 113,61
Valor nominal	(mi R\$)	---	R\$ 16,48	R\$ 17,38	R\$ 60,04	R\$ 76,97

As metas anuais de descarbonização estabelecidas pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) para o RenovaBio no mesmo período variaram de 16,80 milhões a 59,60 milhões de tCO₂eq, as emissões evitadas pela adoção do cenário representaram entre 1,08% e 1,68% das metas anuais de CBIOS. A precificação das emissões evitadas com base no valor médio de mercado dos CBIOS permite estimar ganhos econômicos potenciais de até R\$ 76,97 milhões em 2023, considerando as reduções relacionadas ao cenário adotado.

CONSIDERAÇÕES FINAIS

Este estudo apresenta um método de análise da sensibilidade geral do modelo adotado pela política. Os limites do sistema estudado, a coleta e simulação dos dados, a definição da modelagem por regressão e a análise de sensibilidade são operações feitas a partir da estrutura de ACV do E1GC da RenovaCalc. O modelo de ML supervisionado apresentou boa condição preditiva e demonstra uma alternativa para análise de sensibilidade para sistemas de ACV. Dois insumos foram identificados como os que possuem maior potencial de impacto na IC: Nitrato de Amônio e Diesel, pois demonstram, dentro da modelagem do RenovaCalc, que possuem maior coeficiente de sensibilidade.

O estudo aponta que diminuições graduais do uso destes insumos geram reduções na IC do modelo de forma mais eficiente do que outros insumos estudados. Isso implica na formulação de planos de manejo que possam atender esse objetivo de melhoria no perfil climático da produção de cana-de-açúcar no contexto Renovabio. De forma geral, a redução da IC não atende somente as metas da política, como possui potencial em conversão para ganhos financeiros devido a tradução de tCO₂eq evitado do sistema produtivo para CBIOS. Outros estudos devem ser realizados pela ótica da IE para aferir se esta redução de insumos proposta também afere-se ao ganho energético.

REFERÊNCIAS

ABNT. **NBR ISO 14040** Gestão ambiental – Avaliação do ciclo de vida – Princípios e estrutura. Rio de Janeiro: versão corrigida, 2014.

ANP. **Despacho ANP nº 322**, de 31 de Março de 2023. Brasília: Diário Oficial da União, 2023.

BENTO, José A. N.; VIEIRA FILHO, José E. R. **O Crédito de Descarbonização (CBIO) e sua relação com o mercado de Carbono**. In: FILHO, J. E. R. V.; GASQUES, J. G. (Org.) Agropecuária Brasileira: evolução, resiliência e oportunidades. Rio de Janeiro: IPEA, 2023.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. Springer New York, NY, 2006. ISBN:978-0-387-31073-2

BODANSKY, Daniel. **Paris Agreement**. United Nations Audiovisual Library of International

Law. United Nations, 2021.

BRASIL. **Lei nº 13.576, de 26 de dezembro de 2017.** Dispõe sobre a Política Nacional de Biocombustíveis (RenovaBio) e dá outras providências.. Diário Oficial da União, Brasília, DF, 2017.

BRASIL. **Nationally Determined Contribution (NDC) to the Paris Agreement under the UNFCCC.** Brasília, 2023

EUROPEAN COMMISSION – JRC. **International Reference Life Cycle Data System (ILCD) Handbook – General guide for Life Cycle Assessment – Detailed guidance.** 1. ed. Luxembourg: Publications Office of the European Union, 2010.

FOLEGATTI-MATSUURA, Marília I. S. et al. **RenovaCalc:** a calculadora do programa RenovaBio. Brasília: VI Congresso Brasileiro sobre Gestão do Ciclo de Vida, 2018.

FORNARO, Daniel H.; SANTOS, Jeronimo A.; MARJOTTA-MAISTRO, Marta C. **Funcionamento da renovacalc:** uma visão aplicada à produção do etanol de primeira geração. São Paulo: Revista GeSec, 2023.

GLADISH, Daniel W.; DARNELL, Ross; THORBURN, Peter J.; HALDANKAR, Bhakti. **Emulated Multivariate Global Sensitivity Analysis for Complex Computer Models Applied to Agricultural Simulators.** Journal of Agricultural, Biological, and Environmental Statistics, 2018.

HAMBY, D. M. **A Review of Techniques for Parameter Sensitivity Analysis of Environmental Models.** Environmental Monitoring and Assessment, 1994. p. 135-154

HUTTER, Frank; KOTTHOFF, Lars; VANSSCHOREN, Joaquin (eds.). **Automated Machine Learning: Methods, Systems, Challenges.** Cham: Springer, 2019.

IBGE. **Tabela 1612 - Área plantada, área colhida, quantidade produzida, rendimento médio e valor da produção das lavouras temporárias.** SIDRA, Brasil, 2025. Disponível em: <<https://sidra.ibge.gov.br/tabela/1612>> Acesso em: 26 de jun. 2025

KINPARA, Daniel I. **Economia para além dos custos:** aplicação da análise de sensibilidade para a tomada de decisão agropecuária. Embrapa Cerrados Planaltina, DF, 2020.

LAZARO, Lira L. B. et al. **What is green finance, after all? – Exploring definitions and their implications under the Brazilian biofuel policy (RenovaBio).** Journal of Climate Finance, 2023.

LIU, H. et al. **Life cycle greenhouse gas emissions of Brazilian sugarcane ethanol.** Argonne National Laboratory, 2023.

MINISTÉRIO DE MINAS E ENERGIA. **Despacho do Presidente da República.** Nº 65, de 11 de dezembro de 2024. Resolução nº 14, de 10 de dezembro de 2024, do Conselho Nacional de Política Energética - CNPE. Brasil, 2024.

MINISTÉRIO DE MINAS E ENERGIA. **Balanço Renovabio.** Brasília, DF, 2025. Disponível

em: <<https://www.gov.br/mme/pt-br/assuntos/secretarias/petroleo-gas-natural-e-biocombustiveis/renovabio-1/balanco-renovabio>> Acesso em: 27 de jun. de 2025

OBSERVATÓRIO DO CLIMA. **Ação Civil Pública: contra o Ministério do Meio Ambiente e a União Federal**. Piracicaba, 2021.

PINTO, Alexandre da Silva Lara. **Análise da Intensidade de Carbono dos biocombustíveis no Brasil**. Fundação Getulio Vargas, Escola de Economia de São Paulo, 2023.

UNFCCC. **Emissions Trading: greenhouse gas emissions a new commodity**. 2024. Disponível em: <<https://unfccc.int/process/the-kyoto-protocol/mechanisms/emissions-trading>> Acesso em: 23 de jun. 2025

RAMOS et al. **Regionalização dos perfis típicos da produção de cana-de-açúcar para uso no Renovabio**. Empresa Brasileira de Pesquisa Agropecuária, Jaguariúna, SP, 2024.

SALEHIN, I. et al. Abu. **AutoML: A systematic review on automated machine learning with neural architecture search**. Journal of Information and Intelligence, v. 2, n. 1, p. 52-81, 2024.

SCACHETTI, Michelle T. et al. **A RenovaCalc aplicada ao Biocombustível Etanol de Cana-de-Açúcar**. Brasília: VI Congresso Brasileiro sobre Gestão do Ciclo de Vida, 2018.

SILVA, R. F. et al. **Prediction of Corn and Sugar Prices Using Machine Learning, Econometrics, and Ensemble Models**. Eng. Proc. 2021.

SOUZA, G. M.; VICTORIA, R. L.; JOLY, C. A.; VERDADE, L. M. **Bioenergy & Sustainability: bridging the gaps**. Scientific Committee on Problems of the Environment (SCOPE), São Paulo, 2015.

VEDANA, Roberta. et al. **Distribuição espacial da produtividade de cana-de-açúcar no Brasil**. Revista de Política Agrícola, Ano XXVIII, n. 4, 2019.

WEI, Wei et al. **How to Conduct a Proper Sensitivity Analysis in Life Cycle Assessment: Taking into Account Correlations within LCI Data and Interactions within the LCA Calculation Model**. Environmental Science & Technology, Washington, DC, 2014.

XAVIER, J. H. V.; CALDEIRA-PIRES, A. **Uso Potencial da Metodologia de Análise de Ciclo de Vida (ACV) para a Caracterização de Impactos Ambientais na Agricultura**. Brasília: Cadernos de Ciência & Tecnologia v. 21, n. 2, 2004.

XUE ROMEIKO, Xiaobo; LEE, Eun Kyung; SORUNMU, Yetunde; ZHANG, Xuesong. **Spatially and temporally explicit life cycle environmental impacts of soybean production in the U.S. Midwest**. Environmental Science & Technology, v. 54, n. 8, p. 4758-4768, 2020.