

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 01/08/2024.

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CAMPUS DE JABOTICABAL**

**ESTIMANDO XCO_2 EM CULTIVOS DE ARROZ E CANA-DE-
AÇÚCAR A PARTIR DO SISTEMA WOFOST**

Henrique Fontellas Laurito

Engenheiro Agrônomo

2024

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CAMPUS DE JABOTICABAL

**ESTIMANDO XCO₂ EM CULTIVOS DE ARROZ E CANA-DE-
AÇÚCAR A PARTIR DO SISTEMA WOFOST**

Discente: Henrique Fontellas Laurito

Orientador: Prof. Dr. Glauco de Souza Rolim

**Dissertação apresentada à Faculdade de
Ciências Agrárias e Veterinárias – Unesp,
Campus de Jaboticabal, como parte das
exigências para a obtenção do título de
Mestre em Produção Vegetal**

2024

L386e

Laurito, Henrique Fontellas

Estimando XCO₂ em cultivos de arroz e cana-de-açúcar a partir do sistema WOFOST / Henrique Fontellas Laurito. -- Jaboticabal, 2024
120 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim

1. Aprendizado do computador. 2. Sensoriamento remoto. 3.
Mudanças climáticas. 4. Agricultura sustentável. 5. Python
(Linguagem de programação de computador). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de
Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTIMANDO XCO₂ EM CULTIVOS DE ARROZ E CANA-DE-AÇÚCAR A PARTIR DO SISTEMA WOFOST

AUTOR: HENRIQUE FONTELLAS LAURITO

ORIENTADOR: GLAUCO DE SOUZA ROLIM

Aprovado como parte das exigências para obtenção do Título de Mestre em Agronomia (Produção Vegetal), pela Comissão Examinadora:

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Presencial)
Departamento de Engenharia e Ciências Exatas / FCAV UNESP Jaboticabal

Prof. Dr. LUCAS EDUARDO DE OLIVEIRA APARECIDO (Participação Virtual)
Departamento de Engenharia Agrícola/Agrometeorológica/Climatologia Agrícola / Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais - Muzambinho/MG

Prof. Dr. ALAN RODRIGO PANOSSO (Participação Presencial)
Departamento de Engenharia e Ciências Exatas / FCAV UNESP Jaboticabal-SP

Jaboticabal, 01 de fevereiro de 2024

gov.br Documento assinado digitalmente
LUCAS EDUARDO DE OLIVEIRA APARECIDO
Data: 02/02/2024 12:58:39-0300
Verifique em <https://validar.itl.gov.br>

DADOS CURRICULARES DO AUTOR

HENRIQUE FONTELLAS LAURITO – Nascido em 01 de setembro de 1996, em Ribeirão Preto, São Paulo. Engenheiro Agrônomo formado pela Faculdade de Ciências Agrárias e Veterinárias FCAV/UNESP – Campus de Jaboticabal em 2022. Durante a graduação, concluiu sua primeira iniciação científica, em 2018, denominada “Genômica e transcriptômica aplicada à determinação dos mecanismos moleculares de resistência a metais em rizóbios: Parte 1: Estudo do genoma de isolados de *Rhizobium* e Ensifer”, sob orientação da Profa. Dra. Lúcia Maria Carareto Alves, fomentado pelo PIBIC/CNPq. Também concluiu a Iniciação Científica, em 2021, sob orientação da Profa. Dra. Mara Cristina Pessôa da Cruz, fomentado pela FAPESP, cujo tema foi: “Frações de carbono e nitrogênio mineralizável no solo em sistema de integração lavoura pecuária”, tema de seu TIC. Ingressou no Mestrado, pelo programa de pós-graduação Produção Vegetal (CAPES 6) em 2021, na linha de pesquisa de Agricultura Digital, sob a orientação do Prof. Dr. Glauco de Souza Rolim, desenvolvendo o trabalho intitulado “Estimando XCO₂ em cultivos de arroz e cana-de-açúcar a partir do sistema WOFOST”. Durante o período, o autor desenvolveu o pacote python denominado “XCO₂ Daily Extractor” (XCODEX) e o disponibiliza gratuitamente para utilização pública.

“Não é sinal de saúde estar ajustado a uma sociedade doente.”

Jiddu Krishnamurti (1895-1986)

Dedico àqueles que trabalham incansavelmente para garantir a segurança alimentar em um mundo em constante transformação, onde as mudanças climáticas ameaçam a produção de alimentos e a sobrevivência de muitas espécies. Que sua dedicação e esforços inspirem outros a se juntarem à luta pela sustentabilidade e preservação do meio ambiente.

AGRADECIMENTOS

Agradeço ao CNPq pelo fomento ao processo 130068/2022-5.

Agradeço ao meu orientador, Glauco de Souza Rolim, pelos ensinamentos e parceria durante meu trajeto no mestrado. Tenho grande admiração e respeito pela maneira alegre, descontraída e paciente que ensina seus alunos. Graças a você, posso afirmar que me encontrei nesta área da qual leciona com tanto gosto. Muito obrigado.

Agradeço aos meus colegas de departamento que contribuíram com minha formação, em especial o Prof. Dr. Newton La Scala e suas contribuições extremamente pertinentes e elucidativa.

Agradeço à minha família por me apoiar e me dar a oportunidade de estudar em uma universidade pública de excelência, como é a Unesp. Muito obrigado.

Agradeço à minha namorada, Thais Mayra Padovani, por me incentivar e apoiar. Você é um porto seguro para mim. Seu companheirismo foi fundamental para me tornar uma pessoa melhor. Muito obrigado.

A todos que contribuíram para o meu desenvolvimento como pesquisador.

MUITO OBRIGADO!

SUMÁRIO

Página

LISTA DE ABREVIATURAS	v
LISTA DE TABELAS.....	viii
LISTA DE FIGURAS	xi
CAPÍTULO 1 – Considerações Gerais.....	15
1. INTRODUÇÃO	15
1.1. Hipóteses	16
1.2. Objetivos	16
1.2.1. Gerais.....	16
1.2.2. Específicos	16
2. REVISÃO DE LITERATURA.....	17
2.1. Mudanças climáticas	17
2.1.1. El Niño e mudanças climáticas	18
2.2. Tratados e conferências	18
2.3. Agricultura como agente das alterações climáticas.....	20
2.4. Os impactos das mudanças climáticas na agricultura.....	20
2.4.1. Cana-de-açúcar.....	21
2.4.2. Arroz	22
2.5. Ações mitigadoras	22
2.6. Estudo sobre as emissões de GEEs.....	23
2.6.1. Estudo in situ	23
2.6.2. Sensoriamento remoto	24
2.7. Modelos de cultivo	25
2.8. Modelos de aprendizado de máquina	26
2.9. Modelos agrupados	27
3. REFERENCIAS	28
CAPÍTULO 2 – Estimativa de XCO ₂ em cultivos de cana-de-açúcar e arroz com um ensemble de WOFOST e Random Forest	38
4. MATERIAL E MÉTODOS.....	38
4.1. Delimitação das localidades de estudo	38
4.2. Obtenção de dados	39
4.3. Modelo WOFOST	39
4.3.1. Condições climáticas.....	40

4.3.2. Condições do solo	40
4.4. Cultivo e manejo	41
4.4.1. Dióxido de carbono.....	42
4.4.2. Calibração do WOFOST	44
4.4.3. Correlação de Spearman.....	45
4.4.4. Tratamento de outliers.....	45
4.4.5. Random Forest.....	45
5. RESULTADOS E DISCUSSÃO	47
5.1. Calibração dos parâmetros de cultivo	47
5.2. Conversão da base numérica do XCO ₂ de ppm para kg.....	50
5.3. Resultados do modelo WOFOST.....	51
5.4. Modelo Random Forest	61
6. CONCLUSÃO	71
7. REFERÊNCIAS	72
CAPÍTULO 3 – Extracting daily data from NASA's xco ₂ with xcodex: a python package created for extraction and structuring.....	74
8. INTRODUCTION	75
9. MATERIAL AND METHODS.....	78
9.1. Introduction to XCODEX.....	78
9.2. Package dependencies	79
9.3. XCODEX in detail	79
9.3.1. Download	79
9.3.2. Extraction	80
9.4. Some applications of the XCODEX package	81
9.4.1. Mauna Loa	81
9.4.2. Other places on the planet.....	82
10. RESULT AND DISCUSSION	83
10.1. Mauna Loa	83
10.2. Other places	84
11. CONCLUSION	89
12. ACKNOWLEDGEMENTS	89
13. REFERENCES	90
CAPÍTULO 4 – Considerações finais	94
14. CONSIDERAÇÕES FINAIS	94
15. ANEXOS	95

ESTIMATIVA DE XCO₂ EM CULTIVOS DE CANA-DE-AÇÚCAR E ARROZ COM WOFOST E FLORESTAS ALEATÓRIAS

RESUMO – A concentração de dióxido de carbono (CO₂) no ar é um dos fatores que influenciam nas mudanças climáticas, que podem afetar a segurança alimentar e a qualidade de vida das pessoas, principalmente as mais vulneráveis. Por isso, é importante medir e estimar essa concentração em áreas onde se cultivam alimentos e fontes sustentáveis de energia, tais como o arroz e a cana-de-açúcar. Uma abordagem inovadora para estimar o XCO₂ envolve a combinação de modelos mecanísticos de cultivo, como o WOrld FOod STudies (WOFOST), que calcula o balanço de carbono em áreas agrícolas, com modelos de aprendizado de máquina, formando um conjunto integrado de modelos (ensemble). Sendo assim, o presente trabalho utilizou dados de produtividade (SIDRA) em grandes áreas contínuas cana-de-açúcar (sequeiro) e arroz (alagadas) em uma série histórica dados de 1984 a 2022, das principais regiões produtoras do Brasil sob a hipótese de que o XCO₂ poderia ser estimado a partir do ensemble dos modelos WOFOST com o Random Forest, usando dados de sensoriamento remoto (OCO-2/NASA) como fonte de XCO₂ observado. Os resultados confirmam a hipótese, com: coeficiente de determinação R^2 adj = 0.81, 0.85 e 0.75; RMSE=1.22, 1.17 e 1.3 ppm; MAE = 1.48, 1.37 e 1.7 ppm para os modelos globais, sob cultivo de cana e arroz, respectivamente.

Palavras-chave: aprendizado de máquina, sensoriamento remoto, mudanças climáticas, modelagem, python, sustentabilidade

ESTIMATION OF XCO₂ IN SUGARCANE AND RICE CROPS WITH AN ENSEMBLE OF WOFOST AND RANDOM FOREST

ABSTRACT – The concentration of carbon dioxide (CO₂) in the air is one of the factors that influence climate change, which can affect food security and the quality of life of people, especially the most vulnerable. Therefore, it is important to measure and estimate this concentration in areas where food and sustainable sources of energy, such as rice and sugarcane, are grown. An innovative approach to estimating XCO₂ involves combining mechanistic cultivation models, such as WOrld FOod STudies (WOFOST), which calculates the carbon balance in agricultural areas, with machine learning models, forming an ensemble of models. Therefore, the present work used productivity data (SIDRA) in large continuous areas of sugarcane (rainfed) and rice (flooded) in a historical series data from 1984 to 2022, from the main producing regions of Brazil under the hypothesis that XCO₂ could be estimated from the ensemble of WOFOST models with Random Forest, using remote sensing data (OCO-2/NASA) as a source of observed XCO₂. The results confirm the hypothesis, with R² adj = 0.81, 0.85 and 0.75; RMSE=1.22, 1.17 and 1.3 ppm; MAE = 1.48, 1.37 and 1.7 ppm for the global models, under sugarcane and rice cultivation, respectively.

Keywords: Machine Learning, Remote Sensing, Climate Change, Modeling, Python, Sustainability

LISTA DE ABREVIATURAS

DVS	Estádio de desenvolvimento (-)
LAI	Índice de área foliar (m m^{-1})
TAGP	Produção total acima do solo (kg ha^{-1})
TWSO	Massa seca total de órgãos de reserva (kg ha^{-1})
TWLTV	Massa seca total de folhas (kg ha^{-1})
TWST	Massa seca total de galhos/colmos (kg ha^{-1})
TRA	Taxa de transpiração (mm d^{-1})
RFTRA	Fator de redução na taxa de transpiração (-)
RD	Profundidade da zona radicular (cm)
WWLOW	Umidade total no perfil do solo (cm)
SM	Umidade do solo ($\text{cm}^3 \text{cm}^{-3}$)
GASST	Assimilação bruta total ($\text{kg CH}_2\text{O ha}^{-1}$)
MREST	Respiração de manutenção total ($\text{kg CH}_2\text{O ha}^{-1}$)
MRES	Taxa respiratória de manutenção real ($\text{kg CH}_2\text{O ha}^{-1}$)
PGASS	Taxa de assimilação potencial ($\text{kg CH}_2\text{O ha}^{-1}$)
GASS	Taxa de assimilação corrigida para déficit hídrico ($\text{kg CH}_2\text{O ha}^{-1}$)
ASRC	Assimilado líquido disponível ($\text{kg CH}_2\text{O ha}^{-1} \text{d}^{-1}$)
PMRES	Taxa Potencial de respiração para manutenção ($\text{kg CH}_2\text{O ha}^{-1} \text{d}^{-1}$)
DTGA	Assimilação bruta diária total ($\text{kg CH}_2\text{O ha}^{-1} \text{d}^{-1}$)
AMAX	Taxa máxima de assimilação de CO_2 ($\text{kg ha}^{-1} \text{hr}^{-1}$)
AMAXTB	Taxa máxima de assimilação de CO_2 em função de DVS ($\text{kg ha}^{-1} \text{hr}^{-1}$)

CFET	Fator de correção da evapotranspiração (-)
CVL	Fator de conversão de assimilados em folhas (kg kg^{-1})
CVO ...	Fator de conversão de assimilados para órgãos de assimilação (kg kg^{-1})
CVR.....	Fator de conversão de assimilados em raízes (kg kg^{-1})
CVS.....	Fator de conversão de assimilados para galhos/colmos (kg kg^{-1})
DEPNR.....	Número do grupo de cultivos para depleção de água no solo (-)
DTSMTB.....	Aumento diário da soma de temperatura ($^{\circ}\text{C d}$)
DVSEND	Estádio de desenvolvimento na colheita (-)
DVSI	Estádio inicial de desenvolvimento do cultivo (-)
EFFTB.....	Eficiência inicial do uso da luz em função da temperatura ($\text{J m}^{-2} \text{s}^{-1}$)
IAIRDU	Presença ou ausência de dutos aéreos nas raízes (-)
IDSL	Mudar para opções de desenvolvimento fenológico (0, 1, 2)
KDIFTB	Coeficiente de extinção luminosa em função da DVS (-)
Q10	Aumento relativo na taxa de respiração para manutenção (-)
RDC	Profundidade máx. do enraizamento (cm)
RDI	Profundidade inicial de enraizamento (cm)
RDMCR.....	Profundidade máx. de enraizamento do cultivo maduro (cm)
RDRRTB	Taxa de mortalidade de raízes em função do DVS ($\text{kg kg}^{-1} \text{d}^{-1}$)
RDRSTB.....	taxa de mortalidade de caules em função do DVS ($\text{kg kg}^{-1} \text{d}^{-1}$)
RFSETB	Fator de redução para senescência em função do DVS (-)
RGRLAI	Aumento relativo máx. no LAI ($\text{ha ha}^{-1} \text{d}^{-1}$)
RML.....	Taxa relativa respiratória para manutenção de folhas ($\text{kg kg}^{-1} \text{d}^{-1}$)
RMO.....	Taxa relativa respiratória para manutenção para reserva ($\text{kg kg}^{-1} \text{d}^{-1}$)

RMR	Taxa relativa respiratória para manutenção de raízes ($\text{kg kg}^{-1} \text{d}^{-1}$)
RMS	Taxa relativa respiratória para manutenção de galhos ($\text{kg kg}^{-1} \text{d}^{-1}$)
PERDL ...	Taxa de mortalidade de folhas devido ao estresse hídrico ($\text{kg kg}^{-1} \text{d}^{-1}$)
RRI	Aumento diário na profundidade de enraizamento (cm d^{-1})
SLATB	Área específica foliar em função da DVS (ha kg^{-1})
SPA	Área específica de vagem (ha kg^{-1})
SPAN	Expectativa de vida da folha crescendo a 35°C (d)
SSATB	Área específica do caule em função da DVS (ha kg^{-1})
TBASE	Temperatura limiar inferior para envelhecimento das folhas ($^{\circ}\text{C}$)
TBASEM.....	Temperatura limite mais baixa para emergência ($^{\circ}\text{C}$)
TDWI	Peso seco total inicial do cultivo (ha kg^{-1})
TEFFMX.....	Temperatura máx. efetiva para emergência ($^{\circ}\text{C}$)
TMNFTB.....	Fator de redução da taxa de assimilação bruta ($^{\circ}\text{C}$)
TMPFTB	Fator de redução da AMAX em função da temperatura média ($^{\circ}\text{C}$)
TSUM1	Soma de temperatura desde a emergência até florescimento ($^{\circ}\text{C d}$)
TSUM2	Soma de temperatura desde o florescimento até a maturidade ($^{\circ}\text{C d}$)
TSUMEM....	Soma de temperatura desde a semeadura até a emergência ($^{\circ}\text{C d}$)

LISTA DE TABELAS

Tabela 1. Descrição das fontes de dados com suas respectivas resoluções espaciais e temporais.....	39
Tabela 2. Classificação de solos (Embrapa, 2023) em cada município, selecionados segundo o critério.....	41
Tabela 3. Descrição das variáveis atribuídas aos solos sob restrição hídrica com capacidade de drenagem.....	41
Tabela 4. Descrição dos resultados da simulação de produção do modelo WOFOST e suas respectivas escalas de grandeza.....	43
Tabela 5. Resultados da otimização das variáveis de cana-de-açúcar no município de Barretos-SP.....	95
Tabela 6. Resultados da otimização das variáveis de cana-de-açúcar no município de Barretos-SP (Continuação da Tabela 5).	96
Tabela 7. Resultados da otimização das variáveis de cana-de-açúcar no município de Barretos-SP (Continuação da Tabela 5).	97
Tabela 8. Resultados da otimização das variáveis de cana-de-açúcar no município de Morro Agudo-SP.....	98
Tabela 9. Resultados da otimização das variáveis de cana-de-açúcar no município de Morro Agudo-SP (Continuação da Tabela 8)	99
Tabela 10. Resultados da otimização das variáveis de cana-de-açúcar no município de Morro Agudo-SP (Continuação da Tabela 8)	100
Tabela 11. Resultados da otimização das variáveis de cana-de-açúcar no município de Goiatuba-GO.....	101

Tabela 12. Resultados da otimização das variáveis de cana-de-açúcar no município de Goiatuba-GO (continuação da Tabela 11).....	102
Tabela 13. Resultados da otimização das variáveis de cana-de-açúcar no município de Quirinópolis-GO.....	103
Tabela 14. Resultados da otimização das variáveis de arroz no município de Uruguaiana-RS.....	104
Tabela 15. Resultados da otimização das variáveis de arroz no município de Uruguaiana-RS (Continuação da Tabela 14)	105
Tabela 16. Resultados da otimização das variáveis de arroz no município de Uruguaiana-RS (Continuação da Tabela 14)	106
Tabela 17. Resultados da otimização das variáveis de arroz no município de Uruguaiana-RS (Continuação da Tabela 14)	107
Tabela 18. Resultados da otimização das variáveis de arroz no município de Santa Vitória do Palmar-RS.....	108
Tabela 19. Resultados da otimização das variáveis de arroz no município de Santa Vitória do Palmar-RS (continuação da Tabela 18)	109
Tabela 20. Resultados da otimização das variáveis de arroz no município de Santa Vitória do Palmar-RS (continuação da Tabela 18).	110
Tabela 21. Resultados da otimização das variáveis de arroz no município de Santa Vitória do Palmar-RS (continuação da Tabela 18)	111
Tabela 22. Resultados da otimização das variáveis de arroz no município de Turvo-SC	113

Tabela 23. Resultados da otimização das variáveis de arroz no município de Turvo-SC (continuação da Tabela 22).....	114
Tabela 24. Resultados da otimização das variáveis de arroz no município de Turvo-SC (continuação da Tabela 22).....	115
Tabela 25. Resultados da otimização das variáveis de arroz no município de Turvo-SC (continuação da Tabela 22).....	116
Tabela 26. Resultados da otimização das variáveis de arroz no município de Forquilha-SC	117
Tabela 27. Resultados da otimização das variáveis de arroz no município de Forquilha-SC (continuação da Tabela 26).....	118
Tabela 28. Resultados da otimização das variáveis de arroz no município de Forquilha-SC (continuação da Tabela 26).....	119
Tabela 29. Resultados da otimização das variáveis de arroz no município de Forquilha-SC (continuação da Tabela 26).....	120

LISTA DE FIGURAS

Figura 1. Gráfico de produção média de arroz (A-C) e cana-de-açúcar (D-F) no período de 2015 a 2022.	38
Figura 2. Produtividade estimada pelo modelo WOFOST e observada pelo SIDRA para os municípios de: (A) Barretos; (B) Morro Agudo; (C) Quirinópolis; (D) Goiatuba; (E) Uruguaiana; (F) Santa Vitória do Palmar; (G) Turvo; (H) Forquilha.	48
Figura 3. Variação da Soma de temperatura desde a emergência até florescimento (TSUM1), no cultivo de cana-de-açúcar, Barretos-SP.	49
Figura 4. Temperatura média (A) e pressão atmosférica média (B) no cultivo da cana-de-açúcar; Temperatura média (C) e pressão atmosférica média (D) para o cultivo do arroz.	50
Figura 5. Resultado médio da simulação de produtividade do modelo WOFOST para o cultivo de cana-de-açúcar.	52
Figura 6. Correlação de Spearman entre os resultados do modelo WOFOST, XCO_2 observado e CO_2	53
Figura 7. Perfil de assimilação média de gás carbono no ano safra do cultivo de cana-de-açúcar (A) e arroz (B).	54
Figura 8. Comparação entre a assimilação bruta de CO_2 média dos locais estudados, na série histórica, em função do desenvolvimento do cultivo de cana-de-açúcar (A) e arroz (B). As linhas centrais correspondem à média móvel em janela de 80 dias. ...	55
Figura 9. Resultado médio da simulação de produtividade do modelo WOFOST para a cultivo do arroz.	56
Figura 10. Perfil de assimilação de CO_2 ao longo do ciclo de desenvolvimento da cana-de-açúcar, nos municípios de Barretos-SP (A), Morro Agudo-SP (B), Quirinópolis-GO	

(C) e Goiatuba-GO (D). As linhas centrais correspondem à média móvel em janela de 80 dias.....57

Figura 11. Perfil de assimilação de CO₂ ao longo do ciclo de desenvolvimento da cana-de-açúcar, nos municípios de Uruguaiana-RS (A), Santa Vitória do Palmar-RS (B), Turvo-SC (C) e Forquilha-SC (D). As linhas centrais correspondem à média móvel em janela de 80 dias.58

Figura 12. Perfil de assimilação médio dos locais, separados entre os anos da série histórica, em função do desenvolvimento do cultivo da cana-de-açúcar. As linhas centrais correspondem à média móvel em janela mensal.....59

Figura 13. Perfil de assimilação médio dos locais, separados entre os anos da série histórica, em função do desenvolvimento do cultivo do arroz. As linhas centrais correspondem à média móvel em janela mensal.60

Figura 14. Desempenho do Treinamento e Teste do modelo de Random Forest global (cana+arroz).....61

Figura 15. Desempenho do treinamento e teste do modelo de Random Forest para a cultivo de cana-de-açúcar.62

Figura 16. Desempenho do treinamento e teste do modelo de Random Forest para a cultivo do arroz.62

Figura 17. Importância relativa das variáveis para a construção do modelo global (cana + arroz).....64

Figura 18. Importância relativa das variáveis para a construção do modelo da cana.65

Figura 19. Importância relativa das variáveis para a construção do modelo do arroz.66

Figura 20. Impacto de cada variável independente no modelo de RF global (cana + arroz). Variáveis do eixo Y apresenta importância das variáveis em ordem decrescente. Eixo X (valores SHAP) representam o impacto de cada variável na previsão de XCO ₂	68
Figura 21. Impacto de cada variável independente no modelo de RF (cana).	69
Figura 22. Impacto de cada variável independente no modelo de RF (arroz)	70
Figure 23. Graphical description of a file of type nc4, a) vectors of latitude, longitude and time, b) Breakdown of the crossing of latitude and longitude over time (t). Modified from Liu et al. (2018)	77
Figure 24. XCODEX package flowchart, with steps A) Download the Global XCO ₂ data, B) Organization of the downloaded files, C) Extraction of temporal data for each desired location, D) Organization of the final data E) recovering missing data and adding to the first nc4 folder.	78
Figure 25. Monthly CO ₂ concentration values for the Keeling series (Tans; Keeling, 2023) and XCO ₂ extracted by the XCODEX package on the period of jan/2015 to dec/2021.....	84
Figure 26. Linear regression of adjusted R ² , RMSE and EME values of the model between XCODEX values and obtained by the Mauna Loa observatory.	84
Figure 27. Map showing the localities and average values of XCO ₂ (ppm) from January 2015 to December 2021.....	85
Figure 28. Monthly averages of XCO ₂ (ppm) in the studied period extracted from the XCODEX package.....	86

Figure 29. Comparison of the XCO_2 increase of the selected locations with those obtained at Mauna Loa, extracted with the XCODEX package, during the historical series.....87

Figure 30. Monthly average of XCO_2 in the distinct locations of the northern and southern hemisphere.....89

CAPÍTULO 1 – Considerações Gerais

1. INTRODUÇÃO

As mudanças climáticas afetam o Brasil de diversas formas, colocando em risco a sua biodiversidade, segurança energética, produção agrícola e a sua saúde pública. As atividades humanas, principalmente o desmatamento, a queima de combustíveis fósseis e a agropecuária, são as principais responsáveis pelo aumento das emissões de gases de efeito estufa (GEEs), que intensificam o aquecimento global.

A agropecuária brasileira é um dos maiores emissores de GEEs do mundo, e um dos mais vulneráveis aos seus efeitos. As mudanças climáticas já provocam alterações nos padrões de chuva e temperatura, intensificando eventos extremos como secas, enchentes, ondas de calor e incêndios florestais. Esses fenômenos têm impactos negativos na disponibilidade de água, produção de alimentos, geração de energia, conservação da natureza e qualidade de vida da população. Em decorrência disto, é importante desenvolver novas ferramentas para estimar a concentração de gases de efeito estufa na atmosfera e compreender seus possíveis impactos sobre a agricultura.

Nesse sentido, o presente estudo propõe a criação de uma integração entre um modelo mecanístico de cultivo e um modelo de aprendizado de máquina (ensemble) com o objetivo de estimar a concentração molar de CO₂ em coluna de ar seco (XCO₂) na atmosfera. Esta concentração estimada é o resultado do balanço de carbono em áreas agrícolas e visa entender os impactos potenciais na produção de cana-de-açúcar e arroz.

Para alcançar isso, o modelo mecanístico de cultivo utilizado foi o World Food Studies (WOFOST) para simular a produtividade desses cultivos em áreas de produção de cana e arroz. Enquanto isso, o modelo de machine learning escolhido foi o Random Forest, que é um modelo robusto e eficiente para correlação de diversas variáveis. A partir deste ensemble, estimamos a concentração de XCO₂, utilizando os resultados de balanço de carbono gerados pelo WOFOST.

Os resultados obtidos mostraram que o modelo de machine learning foi capaz de estimar a concentração de XCO_2 . Esses resultados são importantes porque permitem uma melhor compreensão dos impactos das mudanças climáticas sobre a agricultura. Com essa compreensão, é possível desenvolver estratégias para mitigar esses impactos e garantir a segurança alimentar e hídrica da população.

11. CONCLUSION

Faced with the complexity of handling nc4 files, the XCODEX package was able to download and extract daily XCO₂ data in distinct locations in an uncomplicated way and with no plain trend in the data. It should be considered that, because these are data obtained by remote sensing, the maximum and minimum values of XCO₂ are less representative when compared with measurements at the terrestrial level, *in situ*. However, the temporal variability of these data is like the terrestrial one and are of fundamental importance for understanding the behavior of sources and sinks on a global scale.

12. ACKNOWLEDGEMENTS

We would like to express our gratitude to Newton La Scala for his insightful considerations and contributions to our work. We would also like to thank Glauco de Souza Rolim for this invaluable mentoring and guidance throughout this research.

13. REFERENCES

BOESCH, H.; BAKER, D.; CONNOR, B.; CRISP, D.; MILLER, C. Global Characterization of CO₂ Column Retrievals from Shortwave-Infrared Satellite Observations of the Orbiting Carbon Observatory-2 Mission. *Remote Sensing*, [s. l.], v. 3, n. 2, p. 270–304, 2011.

BOND-LAMBERTY, B.; BAILEY, V. L.; CHEN, M.; GOUGH, C. M.; VARGAS, R. Globally rising soil heterotrophic respiration over recent decades. *Nature*, [s. l.], v. 560, n. 7716, p. 80–83, 2018.

BRAD WEIR; LESLEY OTT; OCO-2 SCIENCE TEAM (2022). OCO-2 GEOS Level 3 daily, 0.5x0.625 assimilated CO₂ V10r. Goddard Earth Sciences Data and Information Services Center (GES DISC), [s. l.], 2022. Disponível em: <https://disc.gsfc.nasa.gov/datasets/OCO2_GEOS_L3CO2_DAY_10r/summary>. Acesso em: 19 mar. 2023.

CIAIS, P.; TAN, J.; WANG, X.; ROEDENBECK, C.; CHEVALLIER, F.; PIAO, S.-L.; MORIARTY, R.; BROQUET, G.; LE QUÉRE, C.; CANADELL, J. G.; PENG, S.; POULTER, B.; LIU, Z.; TANS, P. Five decades of northern land carbon uptake revealed by the interhemispheric CO₂ gradient. *Nature*, [s. l.], v. 568, n. 7751, p. 221–225, 2019.

CONNOR, B.; BÖSCH, H.; MCDUFFIE, J.; TAYLOR, T.; FU, D.; FRANKENBERG, C.; O'DELL, C.; PAYNE, V. H.; GUNSON, M.; POLLOCK, R.; HOBBS, J.; OYAFUSO, F.; JIANG, Y. Quantification of uncertainties in OCO-2 measurements of XCO₂: simulations and linear error analysis. *Atmospheric Measurement Techniques*, [s. l.], v. 9, n. 10, p. 5227–5238, 2016.

CROWELL, S. M. R.; RANDOLPH KAWA, S.; BROWELL, E. V.; HAMMERLING, D. M.; MOORE, B.; SCHAEFER, K.; DONEY, S. C. On the Ability of Space-Based Passive and Active Remote Sensing Observations of CO₂ to Detect Flux Perturbations to the Carbon Cycle. *Journal of Geophysical Research: Atmospheres*, [s. l.], v. 123, n. 2, p. 1460–1477, 2018.

ELDERING, A.; WENNBERG, P. O.; CRISP, D.; SCHIMEL, D. S.; GUNSON, M. R.; CHATTERJEE, A.; LIU, J.; SCHWANDNER, F. M.; SUN, Y.; O'DELL, C. W.; FRANKENBERG, C.; TAYLOR, T.; FISHER, B.; OSTERMAN, G. B.; WUNCH, D.; HAKKARAINEN, J.; TAMMINEN, J.; WEIR, B. The Orbiting Carbon Observatory-2 early science investigations of regional carbon dioxide fluxes. *Science*, [s. l.], v. 358, n. 6360, 2017.

FRIEDLINGSTEIN, P.; COX, P.; BETTS, R.; BOPP, L.; VON BLOH, W.; BROVKIN, V.; CADULE, P.; DONEY, S.; EBY, M.; FUNG, I.; BALA, G.; JOHN, J.; JONES, C.; JOOS, F.; KATO, T.; KAWAMIYA, M.; KNORR, W.; LINDSAY, K.; MATTHEWS, H. D.; RADDATZ, T.; RAYNER, P.; REICK, C.; ROECKNER, E.; SCHNITZLER, K.-G.; SCHNUR, R.; STRASSMANN, K.; WEAVER, A. J.; YOSHIKAWA, C.; ZENG, N. Climate–Carbon Cycle Feedback Analysis: Results from the C4MIP Model Intercomparison. *Journal of Climate*, [s. l.], v. 19, n. 14, p. 3337–3353, 2006.

HAKKARAINEN, J.; IALONGO, I.; MAKSYUTOV, S.; CRISP, D. Analysis of Four Years of Global XCO₂ Anomalies as Seen by Orbiting Carbon Observatory-2. *Remote Sensing*, [s. l.], v. 11, n. 7, p. 850, 2019.

JONES, C. D.; CIAIS, P.; DAVIS, S. J.; FRIEDLINGSTEIN, P.; GASSER, T.; PETERS, G. P.; ROGELJ, J.; VAN VUUREN, D. P.; CANADELL, J. G.; COWIE, A.; JACKSON, R. B.; JONAS, M.; KRIEGLER, E.; LITTLETON, E.; LOWE, J. A.; MILNE, J.; SHRESTHA, G.; SMITH, P.; TORVANGER, A.; WILTSHIRE, A. Simulating the Earth system response to negative emissions. *Environmental Research Letters*, [s. l.], v. 11, n. 9, p. 095012, 2016.

KEELING, C. D. The Concentration and Isotopic Abundances of Carbon Dioxide in the Atmosphere. *Tellus*, [s. l.], v. 12, n. 2, p. 200–203, 1960. Disponível em: <<https://www.tandfonline.com/doi/full/10.3402/tellusa.v12i2.9366>>. Acesso em: 19 mar. 2023.

LIANG, A.; GONG, W.; HAN, G.; XIANG, C. Comparison of satellite-observed XCO₂ from GOSAT, OCO-2, and ground-based TCCON. *Remote Sensing*, [s. l.], v. 9, n. 10, 2017.

LIU, H.; VAN OOSTEROM, P.; TIJSEN, T.; COMMANDEUR, T.; WANG, W. Managing large multidimensional hydrologic datasets: A case study comparing NetCDF and SciDB. *Journal of Hydroinformatics*, [s. l.], v. 20, n. 5, p. 1058–1070, 2018. Disponível em: <<https://iwaponline.com/jh/article/20/5/1058/38915/Managing-large-multidimensional-hydrologic>>

LONGO, M.; SAATCHI, S.; KELLER, M.; BOWMAN, K.; FERRAZ, A.; MOORCROFT, P. R.; MORTON, D. C.; BONAL, D.; BRANDO, P.; BURBAN, B.; DERROIRE, G.; DOS-SANTOS, M. N.; MEYER, V.; SALESKA, S.; TRUMBORE, S.; VINCENT, G. Impacts of Degradation on Water, Energy, and Carbon Cycling of the Amazon Tropical Forests. *Journal of Geophysical Research: Biogeosciences*, [s. l.], v. 125, n. 8, p. e2020JG005677, 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1029/2020JG005677>>. Acesso em: 5 abr. 2023.

MORAIS FILHO, L. F. F.; MENESES, K. C. De; SANTOS, G. A. de A.; BICALHO, E. da S.; ROLIM, G. de S.; LA SCALA JR, N. xCO₂ temporal variability above Brazilian agroecosystems: A remote sensing approach. *Journal of Environmental Management*, [s. l.], v. 288, p. 112433, 2021.

NATIVI, S.; CARON, J.; DAVIS, E.; DOMENICO, B. Design and implementation of netCDF markup language (NcML) and its GML-based extension (NcML-GML). *Computers & Geosciences*, [s. l.], v. 31, n. 9, p. 1104–1118, 2005. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0098300405001019>>

OTT, Lesley.; WEIR, Brad. OCO-2 GEOS Level 3 daily, 0.5x0.625 assimilated CO2 V10r. Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC), [s. l.], p. 10, 2022. Disponível em: <https://docserver.gesdisc.eosdis.nasa.gov/public/project/OCO/README_OCO2_GEOS.pdf>. Acesso em: 16 mar. 2023.

PARK, S.-W.; KUG, J.-S. A decline in atmospheric CO2 levels under negative emissions may enhance carbon retention in the terrestrial biosphere. *Communications Earth & Environment*, [s. l.], v. 3, n. 1, p. 289, 2022.

RAUPACH, M. R.; GLOOR, M.; SARMIENTO, J. L.; CANADELL, J. G.; FRÖLICHER, T. L.; GASSER, T.; HOUGHTON, R. A.; LE QUÉRE, C.; TRUDINGER, C. M. The declining uptake rate of atmospheric CO2 by land and ocean sinks. *Biogeosciences*, [s. l.], v. 11, n. 13, p. 3453–3475, 2014. Disponível em: <<https://bg.copernicus.org/articles/11/3453/2014/>>

RIAH, K.; R. SCHAEFFER; J. ARANGO; K. CALVIN; C. GUIVARCH; T. HASEGAWA; K. JIANG, E. K.; R. MATTHEWS; G.P. PETERS; A. RAO; S. ROBERTSON; A.M. SEBBIT; J. STEINBERGER; M. TAVONI; D.P. VAN VUUREN. Mitigation pathways compatible with long-term goals. In: P.R. SHUKLA; J. SKEA; R. SLADE; A. AL KHOURDAJIE; R. VAN DIEMEN; D. MCCOLLUM; M. PATHAK; S. SOME; P. VYAS; R. FRADERA; M. BELKACEMI; A. HASIJA; G. LISBOA; S. LUZ; J. MALLEY (Eds.). IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, UK and New York, NY, USA: Cambridge University Press, 2022. p. 295–408.

SANTOS, G. A. de A.; MORAIS FILHO, L. F. F.; MENESES, K. C. De; SILVA JUNIOR, C. A. Da; ROLIM, G. de S.; LA SCALA, N. Hot spots and anomalies of CO2 over eastern Amazonia, Brazil: A time series from 2015 to 2018. *Environmental Research*, [s. l.], v. 215, p. 114379, 2022. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0013935122017066>>. Acesso em: 5 abr. 2023.

TANS, P.; KEELING, R. Mauna Loa CO2 monthly mean data. 2023.

TAYLOR, T. E.; ELDERING, A.; MERRELLI, A.; KIEL, M.; SOMKUTI, P.; CHENG, C.; ROSENBERG, R.; FISHER, B.; CRISP, D.; BASILIO, R.; BENNETT, M.; CERVANTES, D.; CHANG, A.; DANG, L.; FRANKENBERG, C.; HAEMMERLE, V. R.; KELLER, G. R.; KUROSU, T.; LAUGHNER, J. L.; LEE, R.; MARCHETTI, Y.; NELSON, R. R.; O'DELL, C. W.; OSTERMAN, G.; PAVLICK, R.; ROEHL, C.; SCHNEIDER, R.; SPIERS, G.; TO, C.; WELLS, C.; WENNBERG, P. O.; YELAMANCHILI, A.; YU, S. OCO-3 early mission operations and initial (vEarly) XCO₂ and SIF retrievals. *Remote Sensing of Environment*, [s. l.], v. 251, p. 112032, 2020.

WUNCH, D.; WENNBERG, P. O.; OSTERMAN, G.; FISHER, B.; NAYLOR, B.; ROEHL, C. M.; O'DELL, C.; MANDRAKE, L.; VIATTE, C.; KIEL, M.; GRIFFITH, D. W. T.; DEUTSCHER, N. M.; VELAZCO, V. A.; NOTHOLT, J.; WARNEKE, T.; PETRI, C.; DE MAZIERE, M.; SHA, M. K.; SUSSMANN, R.; RETTINGER, M.; POLLARD, D.; ROBINSON, J.; MORINO, I.; UCHINO, O.; HASE, F.; BLUMENSTOCK, T.; FEIST, D. G.; ARNOLD, S. G.; STRONG, K.; MENDONCA, J.; KIVI, R.; HEIKKINEN, P.; IRACI, L.; PODOLSKE, J.; HILLYARD, P. W.; KAWAKAMI, S.; DUBEY, M. K.; PARKER, H. A.; SEPULVEDA, E.; GARCÍA, O. E.; TE, Y.; JESECK, P.; GUNSON, M. R.; CRISP, D.; ELDERING, A. Comparisons of the Orbiting Carbon Observatory-2 (OCO-2) X_{CO_2} measurements with TCCON. *Atmospheric Measurement Techniques*, [s. l.], v. 10, n. 6, p. 2209–2238, 2017. Disponível em: <<https://amt.copernicus.org/articles/10/2209/2017/>>. Acesso em: 26 nov. 2023.