

## **A INFLUÊNCIA DA VARIABILIDADE CLIMÁTICA NA PRODUTIVIDADE DE SOJA DO MATO GROSSO**

THE INFLUENCE OF CLIMATE VARIABILITY ON SOYBEAN YIELD IN MATO  
GROSSO.

Helizani Couto Bazame<sup>1</sup>  
Gabriel de Ávila Marcolino da Silva<sup>2</sup>  
Juliana Maria Amabile<sup>1</sup>  
Débora Curado Jardim<sup>1</sup>

<sup>1</sup>Docentes do curso de Agronomia do UNIVAG. e-mail: [helizani@univag.edu.br](mailto:helizani@univag.edu.br);  
[juamabile@univag.edu.br](mailto:juamabile@univag.edu.br); [debora.jardini@univag.edu.br](mailto:debora.jardini@univag.edu.br).

<sup>2</sup> Discente do curso de Agronomia do UNIVAG. e-mail: [gabrielavila012@gmail.com](mailto:gabrielavila012@gmail.com)

### **RESUMO**

A soja é uma leguminosa de grande interesse na economia mundial e de grande importância na alimentação humana. A variabilidade climática tem grande influência na estimativa da produtividade agrícola, pois a ausência ou excesso de precipitação, e/ou baixas ou elevadas temperaturas durante o ciclo da cultura podem atrapalhar o seu desenvolvimento no campo. Os modelos agrometeorológicos tem sido utilizado para a realização da simulação de produtividade, prevendo o desenvolvimento da cultura antes e durante a sua implantação no campo. O objetivo deste estudo foi estimar as datas de plantio de soja e a produtividade correspondente em todo estado do Mato Grosso para as safras cujos plantios se dão de 2000 a 2023. O início do plantio da soja no Mato Grosso varia ano a ano em função especialmente do início da estação chuvosa, porém, outros fatores como, a intenção do plantio de milho safrinha, podem estimular fazendeiros a plantar a soja mais cedo. A queda de produtividade em 2023 foi exacerbada pelo modelo, o que pode estar relacionado à dificuldade de dados de precipitação de baixa resolução em representar para cada pixel de soja as respectivas chuvas esporádicas ou muito localizadas. O modelo agrometeorológico desempenhou de forma satisfatória na captura dos sinais de quebra de safra de soja frente à variabilidade climática no período estudado.

**Palavras-chave:** Modelos agrometeorológicos; Mudanças climáticas; Modelagem.

### **ABSTRACT**

Soybeans are a legume of great interest to the global economy and of great importance for human nutrition. Climate variability has a great influence on the estimation of agricultural yield, since the absence or excess of precipitation, and/or low or high temperatures during the crop cycle can hinder its development in the field. Agrometeorological models have been used to perform yield simulations, predicting the development of the crop before and during its implementation in the field. The objective of this study was to estimate soybean planting dates

and the corresponding yield throughout the state of Mato Grosso for harvests whose plantings occur from 2000 to 2023. The start of soybean planting in Mato Grosso varies from year to year, especially depending on the beginning of the rainy season. However, other factors, such as the intention of planting second-crop corn, can encourage farmers to plant soybeans earlier. The drop in yield in 2023 was exacerbated by the model, which may be related to the difficulty of low-resolution precipitation data in representing the respective sporadic or very localized rainfall for each soybean pixel. The agrometeorological model performed satisfactorily in capturing the signs of soybean crop failure in the face of climate variability in the period studied.

**Keywords:** Agrometeorological models; Climate change; Modeling.

## Introdução

A soja é uma leguminosa de grande interesse na economia mundial e de grande importância na alimentação humana em decorrência de suas propriedades nutricionais (Silva et al., 2010). O Brasil é o maior produtor mundial de soja, a safra brasileira em 2023/2024 foi de aproximadamente 147,38 milhões de toneladas (Conab, 2024). A magnitude da participação do Brasil no mercado mundial de soja deixa os produtores fortemente expostos à demanda do mercado externo e às oscilações de preços. A produtividade das culturas agrícolas depende de diversos fatores como manejo, tipo de solo, e clima, sendo o clima fator limitante.

A variabilidade climática tem grande impacto nas atividades e produtividade agrícola, pois a ausência ou excesso de precipitação, e/ou baixas ou elevadas temperaturas durante o ciclo da cultura podem atrapalhar o seu desenvolvimento no campo (Aparecido et al., 2022). Por exemplo, o “déficit” hídrico proporciona decréscimo da produção da área foliar, fechamento dos estômatos, aceleração da senescência e abortamento, por outro lado, elevadas precipitações pluviométricas podem provocar perdas na cultura, favorecendo a incidência de doenças e problemas radiculares (Gerstemberger et al., 2007). O entendimento do sistema solo-planta-atmosfera por meio da modelagem, vem sendo cada vez mais utilizado pelos pesquisadores para auxiliar na escolha do melhor manejo das culturas auxiliando o produtor no conhecimento científico e suporte na tomada de decisão no campo (Jin et al., 2014).

A agricultura moderna se beneficia do uso de modelos agrícolas, que auxiliam na estimativa da produtividade de forma eficiente e precisa (Freitas et al., 2025). Modelos agrometeorológicos que relacionam a produtividade das culturas com variáveis hídricas podem auxiliar na previsão de safra e na identificação de material genético mais tolerante a “déficit” hídrico. Esses modelos, são ferramentas que permitem gerar cenários, considerando as diversas

combinações dos fatores que influenciam a produtividade das culturas (Gomes et al., 2014). Dentre as vantagens da utilização destacam-se à economia de tempo e a quantidade de recursos para definição de melhores práticas de irrigação, determinação de riscos de déficit hídrico, respostas de culturas à suplementação hídrica, quantificação de impactos ambientais.

Além disso, a volatilidade dos preços causadas por eventos climáticos extremos podem afetar toda a cadeia da cultura da soja que possui uma grande participação na matriz alimentícia do planeta. Por isso, a modelagem e o entendimento da relação entre a variabilidade do clima e a economia possui papel fundamental tanto para os produtores quanto para toda a população que consome os produtos agrícolas (Schemes, 2018). O objetivo deste estudo foi estimar datas de plantio de soja e a produtividade correspondente em todo estado do Mato Grosso para as safras cujos plantios se dão de 2000 a 2023.

## **Material e métodos**

Para se estimar o impacto da variabilidade climática no cultivo de soja do estado do Mato Grosso utilizou-se o modelo agrometeorológico SSM-iCrop2 (Soltani e Sinclari, 2012; Soltani et al., 2020). Para se estimar a produtividade das safras de soja de 2000 a 2023, este modelo requer dados meteorológicos diários de precipitação, temperatura, umidade relativa e radiação solar. Além disso, para uma melhor estimativa da produtividade por parte do modelo, levou-se em consideração a localização geográfica dos cultivos de soja, bem como as suas respectivas características de solo e datas de plantio. Nas seções a seguir serão detalhadas a parametrização do modelo SSM-iCrop2, as fontes de dados meteorológicos, de solos, e de áreas de cultivo de soja, e a metodologia utilizada para estimativa das datas de plantio. Para facilitar o processamento computacional, o território do estado do Mato Grosso foi dividido em células de  $0.25^\circ \times 0.25^\circ$ . Essa divisão é apresentada na Figura 1A junto a alguns dos dados utilizados neste estudo (Figura 1B-D).




Figura 1. (A) Tiles do produto MODIS 13Q1 utilizados e subdivisões em células de 0.25° x 0.25°. Célula vermelha em destaque para resumo de dados da Figura 1B-D. (B) Máscara de soja da Coleção 9 do Projeto MapBiomass para o ano de 2023 para a célula em ênfase em 1A. (C) NDVI médio da safra de 2023 para célula em ênfase em 1A. (D) Série temporal de temperatura e precipitação para célula em ênfase em 1A.

### *Parametrização do modelo agrometeorológico*

O modelo SSM-iCrop2 é um modelo baseado em processos (simulação dinâmica) para representação do sistema solo-planta com clima e conta com submodelos de fenologia, de desenvolvimento foliar, de produção de matéria seca, e balanço hídrico. Apesar das inúmeras variedades e cultivares de soja adotadas no Mato Grosso, para esta simulação adotou-se como referência o cultivar BRSGO 8360, cujo ciclo médio é de 115 dias, espaçamento entre linhas de 0,50m e densidade de plantio de 14 plantas/m (EMBRAPA, 2013).

Devido ao ciclo semiprecoce do cultivar, ajustou-se o comprimento (em graus dias) da fase da emergência ao florescimento (R1) sendo 25% mais curto que em ciclos normais (ciclo médio de 130 dias). Dessa forma, a duração das fases, em unidades térmicas (graus dias), foi de 70 entre plantio e emergência (SOWEMR), 712.5 (ciclo semiprecoce = 950 \* 0.75) entre emergência e término de crescimento das folhas na haste principal (EMRTLTM), 190 do e

término de crescimento das folhas na haste principal até o fim do crescimento dos grãos (TLMBSG), 700 do início ao fim do enchimento dos grãos (BSGTSG) e 240 do fim do enchimento de grãos à maturidade de colheita (TSGMAT). Adotou-se o fotoperíodo crítico como 12.1, de acordo com o grupo de maturidade de 8.3 deste cultivar. Para os demais parâmetros utilizados pelo modelo, adotou-se os padrões apresentados em Soltani e Sinclair (2012). Para o módulo de balanço hídrico, adotou-se o número da curva (CN), relacionado ao parâmetro de retenção de água do solo, como 78,7 para a soja cultivada no Cerrado (Oliveira et al., 2016).

#### *Dados meteorológicos*

Os dados diários de precipitação, temperatura, umidade relativa e radiação solar foram obtidos do projeto Prediction of Worldwide Energy Resources (POWER) do Langley Research Center (LaRC) da National Aeronautics and Space Administration (NASA) (NASA, 2025b). Os dados diários de precipitação, temperatura e umidade relativa são provenientes do modelo GMAO MERRA-2 (NASA, 2022), com resolução de 0.5° x 0.625°, e o dado diário de radiação solar proveniente do modelo CERES SYN1deg (NASA, 2025a), com resolução espacial de 1° x 1°.

#### *Dados de solo*

Os dados de solo foram obtidos da base SoilGrids250m (Hengl, 2017) para as frações volumétricas (%) de água disponível à capacidade de campo (pF 2.5), no ponto de murcha permanente, e na saturação do solo. Os dados estão disponíveis para diferentes profundidades do solo e foram ponderados pela profundidade respectivas até 1,2m de profundidade, que é a profundidade máxima das raízes da soja adotado nesse estudo.

#### *Mapeamento de histórico de soja*

A localização das áreas plantadas de soja para as safras de 2000 até 2023 foram obtidas da Coleção 9 da série anual de mapas de uso da terra do Brasil do projeto MapBiomas (MAPBIOMAS, 2025; Souza, 2020), cuja acurácia no nível 1 da classificação hierárquica: 93.09%. O dado está disponível em resolução de 30m x 30m.

### *Datas de plantio da soja*

Após a obtenção dos mapas anuais de soja do estado do Mato Grosso, as respectivas datas de plantio dos campos de soja de cada safra foram estimadas à nível de pixel utilizando-se séries temporais do índice de vegetação NDVI (Normalized Difference Vegetation Index) do produto MODIS 13Q1 v6.1 (Didan, 2021). Os dados possuem resolução espacial de aproximadamente 250 m, e resolução temporal de 16 dias. Filtraram-se os pixels de NDVI com valores de confiabilidade de 0 (dados bons) e 1 (dados marginais/úteis). Como máscara para cada safra utilizou-se os mapeamentos de soja anuais reamostrados para a resolução espacial do MODIS. Para redução dos ruídos na série temporal de NDVI, suavizou-se a série para resolução diária com kernel smoother em janela temporal de 1.5x a resolução temporal (24 dias). Para determinar a data de plantio de cada pixel, observou-se a data mais próxima em que o NDVI atingiu o valor de 0,60 e subtraiu-se 45 dias (Figura 2). Essa diferença de 45 dias é observada como a média de dias aproximada que a soja leva para atingir o NDVI de 0,60 para séries temporais de MODIS em diferentes estudos (Farias, et al. 2023, Shammi e Meng, 2021).




Figura 2. Estimativa da data de plantio através da série temporal de NDVI. (A) Série temporal de NDVI do produto MODIS 13Q1 para um pixel aleatório da célula em destaque na Figura 1A. (B) Curva de plantio obtida para célula em destaque na Figura 1A.

## **Resultados e discussão**

### *Datas de plantio da soja*

As estimativas aproximadas de datas de plantio da soja por meio de séries de NDVI apontam um plantio cada vez mais rápido ao longo dos anos no estado do Mato Grosso (Figura 3A). Além disso, a estimativa de data de plantio também nos permite investigar as regiões que,

em média, plantam a soja mais cedo ou mais tarde no estado (Figura 3B). O início do plantio da soja no Mato Grosso varia ano a ano em função do vazio sanitário, mas especialmente em função do início da estação chuvosa. Porém, outros fatores, como a intenção do plantio de milho safrinha, podem estimular fazendeiros a plantar a soja mais cedo. No Mato Grosso, o milho é cultivado predominantemente como safrinha, e sua área plantada cresceu em aproximadamente 1814% de 1990 a 2020, enquanto a área de soja cresceu em apenas 552% no mesmo período (SEDEC, 2021). Esse grande crescimento do plantio de milho safrinha pode explicar por que vemos a soja plantada cada vez mais cedo.




Figura 3. (A) Curva de plantio da soja no estado do Mato Grosso. (B) Data média do plantio de soja para diferentes regiões do estado do Mato Grosso.

O modelo agrometeorológico, aliado de dados climáticos e físico-hídricos do solo, apontou os anos de 2015, 2019, 2020 e 2023 como os de menor produtividade média da soja ao longo dos anos observados (Figura 4A-B). Corroborando com esses resultados temos dados que também apontam quebra nesses anos, como por exemplo a menor safra 2015 em relação ao ano anterior (Agrolink, 2016), relatórios apontando a apreensão de produtores devido às frequências das chuvas em 2020 (IMEA, 2020) e expectativa de quebra de 21% da safra de 2023 (Aprosoja, 2024).

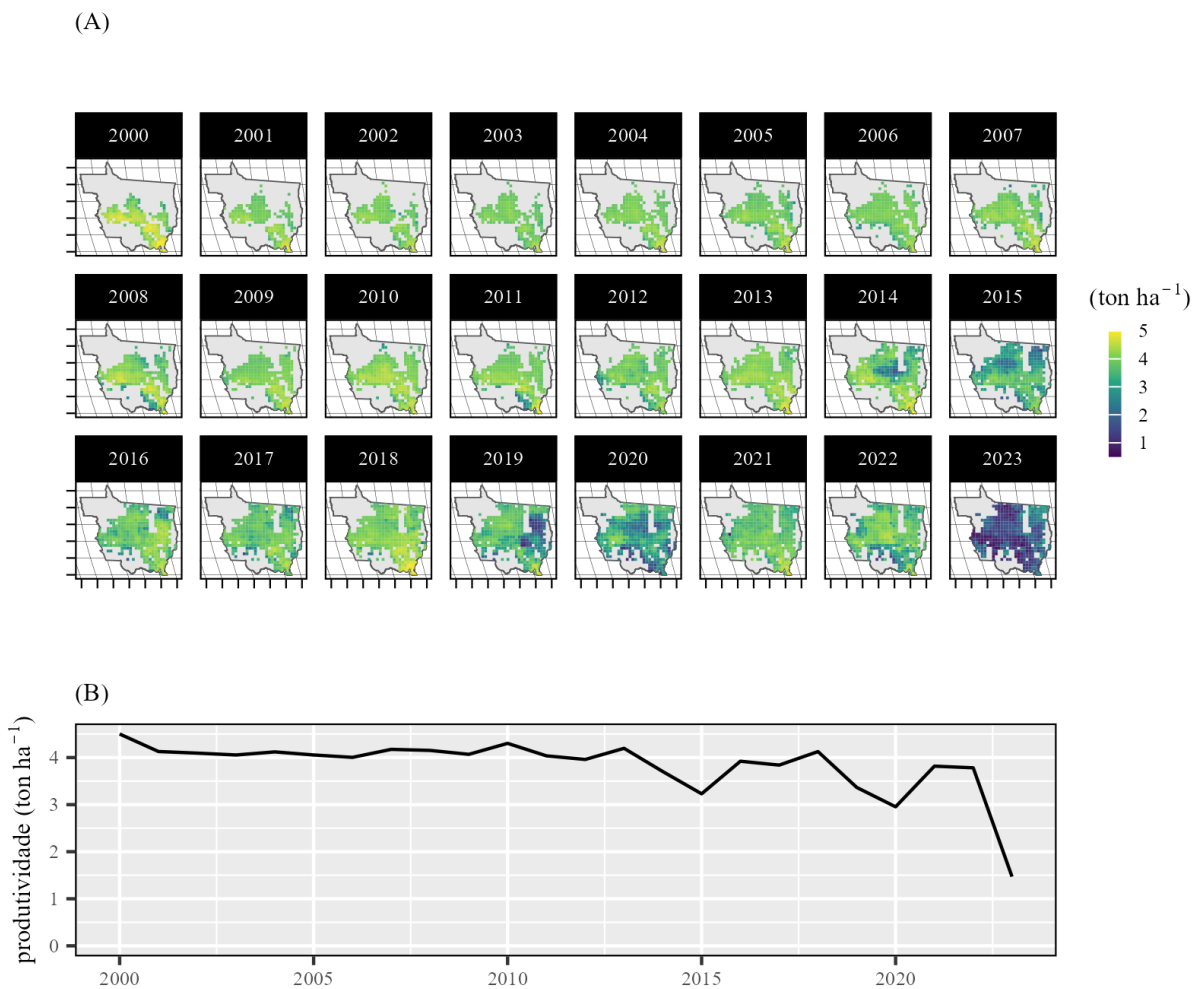


Figura 4. (A) Produtividade espacial da soja ao longo das safras de 2000 a 2023 e (B) sua produtividade média agregada ao território do estado do Mato Grosso.

Vale ressaltar que apesar da quebra de safra documentada, a magnitude da quebra estimada pelo modelo em 2023 não ocorreu, e pode ter sido exacerbada por limitações do modelo e/ou dados utilizados. Os modelos, são ferramentas que permitem gerar cenários, considerando as diversas combinações dos fatores que influenciam a produtividade das culturas agrícolas (Gomes et al., 2014). Dentre as vantagens da utilização destacam-se à economia de tempo e a quantidade de recursos para definição de melhores práticas de irrigação, determinação de riscos de déficit hídrico, respostas de culturas à suplementação hídrica, quantificação de impactos ambientais, entre outros. Por outro lado, devemos também estar atento à suas limitações, que vão desde simplificações de processos fisiológicos da cultura modelada, adoção de um cultivar único ao longo de mais de 20 anos, ignorando aprimoramentos tecnológicos, e problemas relacionados à escala, como a resolução espacial e temporal de dados adotados.

## **Conclusões**

O modelo agrometeorológico desempenhou de forma satisfatória na captura dos sinais de quebra de safra de soja frente à variabilidade climática no período. O modelo pode também elucidar motivos ou condições médias observadas que resultaram no sucesso ou quebra da safra, auxiliando produtores e autoridades a se planejar para o volume produzido no respectivo ano.

## REFERÊNCIAS BIBLIOGRÁFICAS

APARECIDO, L.E.D.O.; LORENÇONE, J. A.; LORENÇONE, P. A.; TORSONI, G. B.; LIMA, R. F.; MORAES, J. R. S. C. 2022. Predicting coffee yield based on agroclimatic data and machine learning. *Theoretical and Applied Climatology*.

Companhia Nacional de Abastecimento [CONAB]. 2017. Análise do mercado da soja. Monitoramento agrícola- Safra 20. Disponível em: <<https://www.conab.gov.br/info-agro/analises-do-mercado-agropecuário-e-extrativista/analises-do-mercado/historico-de-conjunturas-de-soja/item/14410-soja-conjuntura-semanal-19-10-a-23-10-2020>>. Acesso em: 06 março 2025.

DIDAN, K. 2021. MODIS/Terra Vegetation Indices 16-Day L3 Global 250m SIN Grid V061 [Data set]. NASA EOSDIS Land Processes Distributed Active Archive Center. <https://doi.org/10.5067/MODIS/MOD13Q1.061>. Data de acesso: 2025-05-25.

EMBRAPA. Cultivares convencionais de soja – Macrorregiões 3, 4 e 5. 2013. Acessado em <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/954281/1/CatalogoSoja2013MTRO.pdf>. Data de acesso: 2025-05-25.

FARIAS, G. D. et al. Normalized Difference Vegetation Index (NDVI) for soybean biomass and nutrient uptake estimation in response to production systems and fertilization strategies. *Frontiers in Sustainable Food Systems*, v. 6, p. 959681, 2023. <https://doi.org/10.3389/fsufs.2022.959681>.

FREITAS, C. H.; COELHO, R. D.; COSTA, J. O.; SENTELHAS, P. C. Equationing Arabica coffee: Adaptation, calibration, and application of an agrometeorological model for yield estimation, *Agricultural Systems*, Volume 223, 2025, 104181, ISSN 0308-521X. <https://doi.org/10.1016/j.agry.2024.104181>.

GERSTEMBERGER, E.; SOUZA, J.L.M.; SANTOS, M.J.; ARAUJO, M.A. 2010. Estimativa da produtividade da cultura do milho em diferentes sistemas de cultivo na região de Ponta Grossa-PR, Utilizando modelos agrometeorológicos. In: XVIII Reunião Brasileira De Manejo E Conservação Do Solo E Da Água - Novos Caminhos para Agricultura Conservacionista no Brasil. Teresina, PI, Brasil.

GOMES, A.C.S.; ROBAINA, A.D.; PEITER, M.X.; SOARES, F.C.; PARIZI, A.R.C. 2014. Modelo para estimativa da produtividade para a cultura da soja. *Ciência Rural* 44(1): 43-49.

HENGL, Tomislav et al. SoilGrids250m: Global gridded soil information based on machine learning. *PLoS one*, v. 12, n. 2, p. e0169748, 2017. <https://doi.org/10.1371/journal.pone.0169748>.

IMEA, 2020. 6ª Estimativa de Safra 2020/2021. Instituto Mato-grossense de Economia Agropecuária. Acessado em: <https://imea.com.br/imea-site/relatorios-mercado-detalhe?c=4&s=696277481678307328>. Data de acesso: 2025-05-25.

JIN, X.; FENG, H.; ZHU, X.; LI, Z.; SONG, S.; SONG, X. 2014. Assessment of the AquaCrop Model for Use in Simulation of Irrigated Winter Wheat Canopy Cover, Biomass, and Grain Yield in the North China Plain. *Plos One* 9(1): 1–11.

MAPBIOMAS, 2025. Projeto MapBiomias – Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Acesso em: <https://brasil.mapbiomas.org/>. Data de acesso: 2025-05-25.

NASA, 2022. Global Modeling and Assimilation Office – Modern-Era Retrospective analysis for Research and Applications, Version 2 (MERRA2). Acessado em <https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>. Data de acesso: 2025-05-25.

NASA, 2025a. Clouds and the Earth’s Radiant Energy System (CERES) Synoptic TOA and surface fluxes and clouds (SYN). Acessado em: <https://ceres.larc.nasa.gov/data/#syn1deg-level-3>. Data de acesso: 2025-05-25.

NASA, 2025b. Prediction of Worldwide Energy Resources (POWER) - National Aeronautics and Space Administration (NASA) Langley Research Center (LaRC). Acessado em [NASA POWER | Prediction Of Worldwide Energy Resources](#). Data de acesso: 2025-05-25.

OLIVEIRA, P. T. S., NEARING, M. A., HAWKINS, R. H., STONE, J. J., RODRIGUES, D. B. B., PANACHUKI, E., & WENDLAND, E. (2016). Curve number estimation from Brazilian Cerrado rainfall and runoff data. *Journal of Soil and Water Conservation*, 71(5), 420–429. <https://doi.org/10.2489/jswc.71.5.420>

SEDEC, 2021. Série histórica da produção de grãos no estado de Mato Grosso. Secretaria do Estado de Desenvolvimento Econômico (SEDEC). Acessado em: <https://www.sedec.mt.gov.br/documents/195466/13895647/SÉRIE+HISTÓRICA+DA+PROD+UÇÃO+DE+GRÃOS+NO+ESTADO+DE+MATO+GROSSO/59a0a370-6254-32bd-f68e-ca633f1b488d>. Data de acesso: 2025-05-25.

SHAMMI, Sadia Alam; MENG, Qingmin. Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. *Ecological Indicators*, v. 121, p. 107124, 2021. <https://doi.org/10.1016/j.ecolind.2020.107124>.

SILVA, C.O.; ANDRADE, G.F.; DANTAS, M.I.S.; COSTA, N.M.B.; PELUZIO, M.C.G.; FONTES, E.A.F.; MARTINO, H.S.D. 2010. Influence of processing on the protein quality of new soybean cultivars intended for human food. *Revista de Nutrição*, Campinas 23(3):389-397.

SOLTANI, A.; SINCLAIR, T. R. Modeling physiology of crop development, growth and yield. [S.l.]: CAB International, 2012.

SOLTANI, A. et al. SSM-iCrop2: A simple model for diverse crop species over large areas. *Agricultural Systems*, v. 182, p. 102855, 2020. <https://doi.org/10.1016/j.agry.2020.102855>

SCHEMES, F.K. 2018. Impactos de eventos climáticos no preço da soja em CBOT entre 1988 e 2016. Monografia de Graduação em Ciências Econômicas. Universidade Federal de Santa Catarina, Santa Catarina, SC, Brasil.

SOUZA et al. (2020) – Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine – *Remote Sensing*, Volume 12, Issue 17, <https://doi.org/10.3390/rs12172735>.