



Produtividade atual e futura da cultura da soja em Goiás, Brasil

José Bonifácio MARTINS FILHO *¹ , Lineu Neiva RODRIGUES ^{1,2} 

¹ Programa de Pós-Graduação em Engenharia Agrícola, Universidade Estadual Paulista, Botucatu, SP, Brasil.

² Embrapa Cerrados, Brasília, DF, Brasil.

*E-mail: boni.martins@outlook.com

Submetido em: 09/09/2025; Aceito em: 13/06/2026; Publicado em: 05/08/2026.

RESUMO: O presente estudo teve como objetivo estimar as quebras de produtividade da soja cultivada em regime de sequeiro nos municípios de maior rendimento de Goiás, considerando cenários climáticos atuais e futuros (RCP4.5 e RCP8.5) nos períodos de 2040-2069 e 2070-2099. Para isso, foram aplicados o balanço hídrico climatológico de Thornthwaite e Mather e o modelo de Doorenbos e Kassam, calibrado conforme metodologia proposta por Monteiro et al. (2017). Foram avaliadas duas datas de semeadura (15 de outubro e 10 de novembro), e a validação do modelo foi realizada com séries históricas de produtividade (2005-2022) do IBGE, com alta precisão ($R^2 = 0,99$; $MAE = 89 \text{ kg ha}^{-1}$). Os resultados indicaram sazonalidade hídrica marcada, com intensificação dos déficits e redução dos excedentes nos cenários futuros, o que acarretou um aumento expressivo das quebras de produtividade, sobretudo no cenário RCP8.5 e para o plantio em novembro no final do século. Conclui-se que a soja de sequeiro em Goiás tende a tornar-se ainda mais vulnerável às mudanças climáticas e que ajustes no calendário de semeadura, embora relevantes, podem não ser suficientes para mitigar as perdas projetadas.

Palavras-chave: déficit hídrico; mudanças climáticas; quebra de produtividade.

Current and future soybean productivity in Goiás, Brazil

ABSTRACT: This study aimed to estimate yield losses of rainfed soybean in the main producing municipalities of Goiás, considering current and future climate scenarios (RCP4.5 and RCP8.5) for the periods 2040–2069 and 2069–2099. The Thornthwaite and Mather climatological water balance and the Doorenbos and Kassam model, calibrated according to the methodology proposed by Monteiro et al. (2017), were applied. Two sowing dates (October 15 and November 10) were evaluated, and model validation was performed using historical yield data (2005–2022) from IBGE, showing high accuracy ($R^2=0.99$; $MAE=89 \text{ kg ha}^{-1}$). The results indicated marked water seasonality, with intensified deficits and reduced surpluses in future scenarios, leading to a significant increase in yield losses, especially under RCP8.5 and for November sowing at the end of the century. It is concluded that rainfed soybean in Goiás tends to become even more vulnerable to climate change, and that adjustments in the sowing calendar, although relevant, may not be sufficient to mitigate the projected losses.

Keywords: water deficit; climate change; yield gap.

1. INTRODUÇÃO

O Brasil está entre os maiores produtores mundiais de alimentos, respondendo por cerca de 6,4% das exportações agrícolas mundiais (WTO, 2023). Com seus 200 milhões de hectares, o Cerrado é fundamental para a economia brasileira, respondendo por mais da metade da produção agrícola nacional (IBGE, 2024). O êxito da atividade agrícola neste ecossistema decorre principalmente de investimentos significativos em tecnologia, em estratégias de manejo e na aplicação de insumos agropecuários.

A agropecuária é uma das principais atividades econômicas no Cerrado e, em especial, no estado de Goiás, sendo responsável por 11,4% do PIB estadual e por empregar cerca de 300 mil pessoas (IMB, 2022). Nesse contexto, o principal cultivo de interesse econômico em Goiás é a soja, que ocupa cerca de 4,8 milhões de hectares de área plantada (IBGE, 2025). A área cultivada de soja em Goiás é predominantemente de sequeiro (ANA, 2020). Nesse

contexto, a produtividade da sojicultura goiana depende das condições climáticas. Por exemplo, o déficit hídrico no solo pode aumentar o estresse e reduzir o rendimento da cultura (APARECIDO et al., 2020).

Compreender as razões pelas quais as culturas agrícolas não atingem seu rendimento máximo tem sido um objetivo central de diversas pesquisas ao redor do mundo. Estudos indicam que o déficit hídrico é um dos principais fatores responsáveis por essas perdas. Segundo Edreira et al. (2017), a soja cultivada em regime de sequeiro na Carolina do Norte, nos Estados Unidos, apresentou redução de produtividade de até 28%. No Brasil, Battisti et al. (2018) destacam que essa perda pode chegar a 46% em áreas de cultivo de soja. Enquanto isso, na China, Wang et al. (2023) relatam que a perda de produtividade causada pelo déficit hídrico pode atingir 45% nesta cultura.

O aumento da variabilidade climática tem aumentado as incertezas na produção de alimentos. Nas próximas décadas,

espera-se que diversos setores da economia sejam afetados pelas mudanças climáticas, especialmente a agricultura (THAYER et al., 2020). O prolongamento da estação seca e a concentração das chuvas em períodos curtos poderão aumentar o estresse hídrico das culturas e, consequentemente, a demanda por irrigação no cultivo de soja.

Tal cenário pode se intensificar caso as projeções climáticas para o estado de Goiás se confirmem, as quais sugerem um aumento da temperatura, o prolongamento da estação de seca e uma redução na disponibilidade hídrica (CHOU et al., 2014; RODRIGUES et al., 2024).

Um dos principais parâmetros empregados na avaliação dos impactos das condições climáticas sobre a produtividade agrícola é a quebra de produtividade. Esse indicador é definido como a diferença entre o rendimento potencial e a produtividade efetivamente alcançada no campo (FAO; DWFI, 2015). Sua relevância se destaca no âmbito da sustentabilidade dos sistemas de produção agrícola, pois sintetiza e expressa, de forma integrada, os três pilares fundamentais: o ambiental, o econômico e o social.

No aspecto ambiental, reduzir a perda de produtividade é um objetivo crucial para mitigar a necessidade de expansão e de abertura de novas áreas para fins agrícolas, contribuindo para a preservação dos ecossistemas naturais (ZHAO et al., 2023). Sob a ótica econômica, esse aumento produtivo possibilita a otimização de recursos financeiros, a redução de custos operacionais dos produtores agrícolas (SETIYA et al., 2022). Por fim, no âmbito social, o aumento da eficiência agrícola promove maior disponibilidade de alimentos, reforçando a segurança alimentar, favorecida por safras mais expressivas e com vistas a atender às demandas de uma população global em constante crescimento (VISSES et al., 2018).

Diante do exposto, este trabalho teve como objetivo estimar a quebra da produtividade atual e futura da soja nos municípios com as maiores produtividades de soja do estado de Goiás.

2. MATERIAL E MÉTODOS

2.1. Área de estudo

O estado de Goiás, cuja extensão territorial é de aproximadamente 340.242,86 km² (IBGE, 2024), apresenta cerca de 98% de sua área inserida no bioma Cerrado (RODRIGUES, 2024; BOLFE; SANO, 2020). Conforme a classificação climática de Köppen, predomina o clima tropical com inverno seco (Aw); contudo, em determinadas microrregiões do estado, também são identificadas áreas com os tipos climáticos Am, Cwa e Cwb (CARDOSO et al., 2014; NOVAIS, 2020).

Os dados médios mensais de precipitação, ETo e temperatura, provenientes das estações meteorológicas do estado de Goiás, referentes ao período de 1988 a 2022, são apresentados na Figura 1. Historicamente, o estado apresenta uma sazonalidade marcante no regime de chuvas, caracterizada por uma estação chuvosa, de outubro a março, e por uma estação não chuvosa, de abril a setembro. A média mensal no período chuvoso é de 223 mm, enquanto no período seco é de 30 mm.

A ETo apresentou variação ao longo do ano, refletindo as mudanças sazonais típicas das regiões do Cerrado. Os menores valores médios mensais de ETo foram registrados em maio (80,1 mm) e junho (74,7 mm), o que reflete a menor demanda evaporativa associada às temperaturas mais baixas

e à menor incidência de radiação solar no inverno. Em contrapartida, os maiores valores mensais de ETo foram registrados em setembro (114,2 mm) e em outubro (116,7 mm). Esses meses coincidem com temperaturas máximas elevadas, de 32,5 °C e 33,4 °C, respectivamente. O aumento do valor da ETo decorre da intensificação da radiação solar, comum no período de transição para a estação chuvosa no Cerrado, quando a atmosfera apresenta alta demanda evaporativa.




Figura 1. Precipitação média mensal (mm), evapotranspiração de referência (mm), temperatura média máxima e mínima do estado de Goiás a partir dos dados das estações meteorológicas e postos pluviométricos (INMET/ANA) (1988-2022).

Figure 1. Mean monthly precipitation (mm), reference evapotranspiration (mm), and mean maximum and minimum air temperatures in the State of Goiás, derived from meteorological station and rainfall gauge data (INMET/ANA) for the period 1988–2022.

2.2. Base de dados meteorológicos

Para realizar as modelagens, utilizou-se o conjunto de dados Nasa Power (NP). Ele foi desenvolvido com o objetivo de disponibilizar informações meteorológicas aos setores agrícola, de geração de energia e de construção civil, com foco na eficiência energética (STACKHOUSE et al., 2015). O NP é gerado para todo o período e abrange de 1981 até quase o presente. As séries históricas podem ser baixadas gratuitamente no site <https://power.larc.nasa.gov/>.

Foram obtidos em escala diária as séries históricas, para o período de 1988 a 2022, os dados de precipitação (mm), temperatura máxima, mínima e média do ar (°C), umidade relativa (%), radiação solar (MJ m⁻² d⁻¹) e velocidade média do vento a 2 m de altura (m s⁻¹) nos bancos de dados meteorológicos do Instituto Nacional de Meteorologia (INMET/BDMEP) (<https://bdmep.inmet.gov.br/>) e da ANA (Agência Nacional de Águas e Saneamento Básico) (<https://www.snirh.gov.br/hidroweb-mobile/mapa>).

Todos os dados foram validados e submetidos ao procedimento de correção de viés por escalonamento linear (LENDERINK et al., 2007). A avaliação do desempenho da base NP indicou erros médios absolutos variando entre 0,41 e 0,85 mm dia⁻¹ e valores de RMSE entre 0,56 e 1,18 mm dia⁻¹ nos municípios avaliados, acompanhados de coeficientes de correlação entre 0,58 e 0,81 e índices de concordância de Willmott entre 0,62 e 0,88. Com base nessa comparação, os dados observados foram adotados como referência para a aplicação do método de correção de viés por escalonamento linear, visando reduzir os desvios sistemáticos identificados entre as séries observadas e as provenientes da reanálise.

Para estimativa da produtividade futura da cultura da soja foram utilizados os dados climatológicos diários de dois períodos distintos de I) 2040 a 2069 e II) 2070 a 2099 gerados pelo CPTEC/INPE e disponibilizados pela Plataforma PROJETA (Projeções de Mudança do Clima para a América do Sul Regionalizadas pelo Modelo ETA) (<https://projeta.cptec.inpe.br/>), oriundos do modelo HadGEM2-ES, para os cenários RCP8.5 (pessimista) e RCP4.5 (realista) (CHOU et al., 2014).

Dentre os modelos disponíveis, o HadGEM2-ES se destaca por sua ampla utilização em modelagens agrícolas (SRIVASTAVA et al., 2016). No que diz respeito aos cenários, são propostos com base na projeção de emissões de gases de efeito estufa apresentada pelo IPCC (Painel Intergovernamental sobre Mudanças Climáticas) (IPCC, 2013).

2.3. Modelagem da produtividade

O balanço hídrico climatológico foi calculado utilizando a metodologia proposta por Thornthwaite; Mather (1955). Para a estimativa da evapotranspiração de referência, aplicou-se a metodologia proposta no Boletim FAO 56 (ALLEN et al., 1998). A evapotranspiração da cultura foi obtida multiplicando-se a evapotranspiração de referência pelo coeficiente de cultura (K_c), com valores ajustados para o estado de Goiás, correspondentes aos três estágios fenológicos (inicial, intermediário e final): 0,60, 1,10 e 0,40, respectivamente (EMBRAPA, 2021).

A capacidade de água disponível (CAD) dos solos no estado de Goiás é apresentada na Figura 2. Observa-se que mais de 85% dos municípios goianos apresentam valores de CAD superiores a 0,100. Dessa forma, para a realização das simulações, adotou-se o valor específico de CAD correspondente a cada município, visando representar de forma mais realista as características hídricas locais e aumentar a precisão dos resultados obtidos.




Figura 2. Capacidade de água disponível (CAD) no estado de Goiás. Fonte: Elaborado a partir de dados da Agência Nacional de Águas (2020).

Figure 2. Available Water Capacity (AWC) in the State of Goiás. Source: Prepared based on data from the National Water Agency (2020).

A estimativa da quebra de produtividade da soja devido ao déficit hídrico foi realizada com base no modelo proposto por Doorenbos e Kassam (1979), no qual a perda de produtividade (%) é expressa pela equação 1:

$$Q_p = 1 - k_y \cdot [1 - (E_{Tr}/E_{Tc})] \quad (01)$$

em que: Q_p = quebra de produtividade (%); k_y = fator de resposta de rendimento; E_{Tr} = evapotranspiração real (mm) e E_{Tc} = evapotranspiração máxima da cultura (mm).

Os valores de k_y utilizados nas simulações foram de acordo com os estádios fenológicos da soja, conforme recomendado por Farias et al. (2024): $k_{y1} = 0$ (emergência até V2), $k_{y2} = 0,12$ (V2 a R1), $k_{y3} = 0,36$ (R1 a R5) e $k_{y4} = 0,57$ (R5 a R7). A quebra de produtividade foi projetada para o período futuro (2040–2099) com base nos cenários climáticos RCP4.5 e RCP8.5, gerados pelo modelo HadGEM2-ES, e comparada ao período histórico (1988–2022).

Para a calibração do modelo tradicional, utilizou-se a metodologia de Monteiro et al. (2017), que propôs o uso da produtividade potencial tecnológica (PPT), equivalente à produtividade potencial máxima teórica obtida pelo modelo de Doorenbos; Kassam (1979). A produtividade potencial tecnológica foi calculada a partir da tendência histórica da produtividade observada (T_p), obtida por regressão linear da produtividade real (Pr) ao longo do tempo, com base nos dados do IBGE. As variações observadas nos valores de T_p decorrem de diversos fatores, como o clima, a disponibilidade hídrica no solo e o manejo agrícola. A PPT foi calculada pela equação:

$$PPT = T_p \cdot \alpha_p \quad (02)$$

em que: α_p é o coeficiente de produtividade máxima tecnológica ajustado (adimensional).

Uma inovação proposta por Monteiro et al. (2017) na modelagem foi a introdução do fator de resposta ajustado (K_y^*), que reflete a sensibilidade da cultura ao déficit hídrico. Quando $K_y^* > 1$, a cultura apresenta maior resposta ao déficit hídrico; quando $K_y^* < 1$, a resposta é reduzida. Assim, a produtividade real (Pr) é estimada pela equação:

$$Pr/PPT = Q_p = 1 - (k_y \cdot K_y^*) \cdot [1 - (E_{Tr}/E_{Tc})] \quad (03)$$

Para calibrar o modelo, os valores iniciais de k_y^* e α_p foram fixados em 1, sendo ajustados progressivamente (aumentando ou diminuindo) para elevar o coeficiente de determinação e o índice de concordância, além de minimizar o erro absoluto médio e a raiz do erro quadrático médio. Portanto, o procedimento de calibração consistiu em ajustes iterativos dos parâmetros α_p e K_y^* , tendo como referência a metodologia proposta por Monteiro et al. (2017). Nesse sentido, a produtividade relativa é dada pela razão Pr/PPT , enquanto a quebra de produtividade corresponde à redução percentual em relação à produtividade potencial tecnológica.

Este estudo utilizou dados de produtividade média dos 20 municípios com maior produção de soja no estado de Goiás, obtidos no portal SIDRA-IBGE (<https://sidra.ibge.gov.br/home/lspa/brasil>). O modelo foi calibrado com dados de produtividade municipal de 2005 a 2014 e validado com dados de 2015 a 2022. Cada município teve sua calibração específica de α_p e de K_y^* , garantindo uma análise individualizada das condições locais.

Considerando que a janela usual de plantio no estado de Goiás se estende por aproximadamente 60 dias, entre meados de outubro e meados de dezembro, foram identificadas as épocas de semeadura predominantes com base nos levantamentos anuais da CONAB. A partir dessa análise, selecionaram-se duas datas representativas para a realização de simulações de modelagem da produtividade com base no déficit hídrico: 15 de outubro e 10 de novembro. As estimativas foram realizadas considerando os vinte

municípios mais produtivos do estado de Goiás (Caiapônia; Niquelândia; Acreúna; Goiatuba; Santa Helena de Goiás; Padre Bernardo; Bom Jesus de Goiás; Luziânia; Piracanjuba; Campo Alegre de Goiás; Silvânia; Chapadão do Céu; Mineiros; Ipameri; Catalão; Montividiu; Paraúna; Cristalina; Jataí; Rio Verde) (IBGE, 2024).

Cabe ressaltar que as estimativas de perda de produtividade obtidas neste estudo refletem exclusivamente os efeitos do déficit hídrico sobre o desempenho da cultura. Essa simplificação constitui uma limitação inerente ao modelo, uma vez que a produtividade observada em campo resulta da interação entre fatores climáticos, edáficos, biológicos, tecnológicos e gerenciais. Assim, eventos relacionados à incidência de pragas e doenças, deficiências nutricionais, práticas inadequadas de manejo, limitações operacionais e decisões gerenciais dos produtores não são explicitamente considerados nas simulações. Consequentemente, os resultados devem ser interpretados como uma estimativa do impacto potencial do estresse hídrico, e não como uma representação completa das perdas efetivamente observadas nos sistemas de produção (SENTELHAS et al., 2016; MONTEIRO et al., 2017).

3. RESULTADOS

3.1. Balanço hídrico atual e futuro

Nas Figuras 3 a 7 são apresentados os extratos dos balanços hídricos climatológicos médios dos 20 municípios com maior produção de soja no estado de Goiás, com base nos dados de referência (1988-2022), para os períodos de 2040 a 2069 e de 2070 a 2099, a partir dos cenários RCP4.5 e RCP8.5.

No período de referência (1988-2022), observaram-se excedentes hídricos em janeiro, fevereiro, março, abril, novembro e dezembro. Em média, o excedente hídrico nesses meses foi de 100,2 mm. O maior excedente hídrico foi observado em dezembro, o que representou 25% do total. O menor excedente hídrico, que representou 2% do total, foi observado em abril.

Os déficits hídricos no período de referência, de maio a outubro, apresentam média de 77,8 mm. O mês de agosto apresenta o maior déficit hídrico mensal, de 84 mm, o que corresponde a 30,9%, enquanto o menor foi observado em outubro, de 0,2% do total.

Para o cenário RCP4.5 e o período de 2040 a 2069, observou-se a concentração dos excedentes hídricos nos meses de dezembro, janeiro, fevereiro e março. Em comparação com o período de referência, houve uma redução de dois meses de excedente (novembro e abril). Nesse cenário, o déficit hídrico se estende por sete meses, começando em abril, com intensidade baixa (0,7% do déficit total) até outubro (9,5%). Destaca-se uma atenuação do déficit em agosto, com 121,2 mm, o que corresponde a 24% do total.

Considerando o mesmo cenário, para o período de 2070 a 2099, observou-se uma diminuição considerável do excedente hídrico estimado para o mês de dezembro, que passou a ser de 48,7 mm, o que representa cerca de 16,2% do déficit hídrico anual estimado e corresponde a 68% a menos em comparação com o mês de dezembro do período de referência. Além disso, os maiores déficits hídricos foram observados em julho (109,4 mm) e em agosto (126,8 mm). Essas maiores intensidades de déficit foram, respectivamente, de 20,2% e 23,4% do total de déficit anual projetado pelo modelo.




Figura 3. Balanço Hídrico - Período de referência (1988-2022).
Figure 3. Water Balance during the reference period (1988-2022).




Figura 4. Balanço Hídrico - RCP4.5(2040-2069).
Figure 4. Water Balance under the RCP4.5 scenario (2040-2069).




Figura 5. Balanço Hídrico - RCP4.5(2070-2099).
Figure 5. Water Balance under the RCP4.5 scenario (2070-2099).




Figura 6. Balanço Hídrico - RCP8.5 (2040-2069).
Figure 6. Water Balance under the RCP8.5 scenario (2040-2069).




Figura 7. Balanço Hídrico - RCP8.5 (2070-2099).
Figure 7. Water Balance under the RCP8.5 scenario (2070-2099).

No cenário RCP8.5, projeta-se que o déficit hídrico se estenda a quase todos os meses, de abril a novembro. O déficit atinge valores superiores a 100 mm entre julho e agosto, com agosto registrando o percentual mais alto, de 21,5% do total anual. Este valor representa um aumento de 57% em relação ao déficit observado em agosto no período de referência.

Além disso, há excedente hídrico somente no primeiro trimestre do ano, sendo 20,5%, 46,5% e 32,5% distribuídos, respectivamente, nos meses de janeiro, fevereiro e março. Nesse contexto, em comparação ao período de referência, observou-se uma redução marcante no excedente hídrico, com diminuições de 78% em janeiro, 42% em fevereiro e 57% em março, evidenciando a redução da disponibilidade de água em períodos tradicionalmente caracterizados por volumes de precipitação mais expressivos.

Ao avaliar o armazenamento de água no solo projetado para o período de 2070 a 2099, no cenário RCP8.5, observou-se uma conjuntura mais severa, caracterizada pela intensificação da redução do armazenamento hídrico no solo, especialmente em julho (15,8%), agosto (19,3%) e setembro (17,8%). Os menores déficits foram observados em abril (2,4%) e em novembro (5,8%). No primeiro trimestre do ano, os excedentes hídricos mensais foram inferiores a 50 mm, o que indica uma redução relevante da quantidade de água no solo em relação ao período de referência. Sendo o maior excedente no mês de março, com 45,4% do total de excedente hídrico.

Os resultados indicam uma modificação consistente no balanço hídrico climatológico para os períodos futuros projetados pelo modelo HadGEM2-ES, com aumento do déficit hídrico e diminuição do excedente hídrico, o que reflete uma provável alteração nos padrões de precipitação e de evapotranspiração ao longo do tempo. A intensificação desses fenômenos sugere que, em ambos os cenários, as mudanças climáticas acarretariam um aumento da ET_o e uma diminuição das precipitações nos meses mais críticos, comprometendo o armazenamento de água no solo ao longo do ano, com volumes inferiores a 100 mm.

Ao se comparar os cenários RCP4.5 e RCP8.5 para o período de 2040 a 2069, as projeções do cenário RCP4.5 indicam condições relativamente mais amenas, uma vez que preveem maior armazenamento de água no solo e menor intensidade do déficit hídrico durante os meses secos, em comparação com o cenário RCP8.5. Enquanto janeiro é o mês com o maior excedente hídrico no cenário SSP2-4.5, com 114,2 mm, no cenário RCP8.5, o maior excedente ocorre em fevereiro, com apenas 73,1 mm. Ambos os cenários apontam para agosto como o mês com o maior déficit hídrico; no cenário RCP8.5, a intensidade desse déficit é ligeiramente maior, com um aumento de aproximadamente 9% em relação ao cenário SSP2-4.5.

Para o período de 2070 até o final do século XXI, o cenário de emissões RCP4.5 projeta um incremento no excesso de água disponível em março de 93,2 mm, enquanto, em agosto, há um déficit hídrico de 126,8 mm. Em comparação, o cenário RCP8.5 prevê um aumento mais moderado na disponibilidade de água em março, atingindo 42,7 mm, e um déficit mais acentuado em agosto, de 139,3 mm. A diferença entre os cenários RCP4.5 e RCP8.5 em relação ao excedente e ao déficit hídrico evidencia a influência do grau de emissões de gases de efeito estufa na dinâmica climática e na gestão dos recursos hídricos no final do século XXI.

3.2. Quebra da produtividade atual e futura

A Figura 8 apresenta a penalização da produtividade da soja causada pelo déficit hídrico, considerando uma frequência de excedência de 20%, em diferentes datas de semeadura. Os dados foram obtidos para os cenários climáticos RCP4.5 e RCP8.5, projetados para o período de 2040 a 2099, em comparação com o período de referência histórico (1988-2022).




Figura 8. Quebra de produtividade (Qp) da cultura da soja (%) em função do déficit hídrico nos 20 municípios de Goiás, para as semeaduras em 15 de outubro e 10 de novembro, para o período de referência (1988-2022), Figuras (a) e (b); para o cenário RCP4.5 períodos 2040-2069, Figuras (c) e (d), e 2070-2099, Figuras (e) e (f); cenário RCP8.5 períodos 2040-2069, Figuras (g) e (h), e 2070-2099, Figuras (i) e (j).

Figure 8. Soybean yield gap (YG, %) due to water deficit in the 20 municipalities of Goiás for sowing dates on October 15 and November 10. Panels (a) and (b) represent the reference period (1988–2022); panels (c) and (d) represent the RCP4.5 scenario for 2040–2069; panels (e) and (f) represent the RCP4.5 scenario for 2070–2099; panels (g) and (h) represent the RCP8.5 scenario for 2040–2069; and panels (i) and (j) represent the RCP8.5 scenario for 2070–2099.

A quebra potencial de produtividade na semeadura em 15 de outubro, observada no período de referência, foi, em média, 24% inferior à projetada no cenário RCP4.5 (2040-2069) e 34,5% menor no mesmo cenário no período de 2070 a 2099. No cenário RCP8.5, a redução foi ainda mais acentuada, sendo 57,6% inferior no período de 2040 a 2069 e 64,8% menor entre 2070 e 2099. Portanto, esses resultados indicaram que, no período histórico, a penalização pelo déficit hídrico é menor e que há um aumento sucessivo na quebra potencial da produtividade da semeadura em 15 de outubro nos cenários futuros de mudança climática, especialmente sob condições mais extremas (RCP8.5).

A análise da Qp para a semeadura em 10 de novembro revelou que, no período de referência, os valores médios foram 30,3% inferiores aos projetados para o cenário RCP4.5 no intervalo de 2040 a 2069 e 57% inferiores no intervalo de 2070 a 2099. No cenário RCP8.5, essa diferença tornou-se ainda mais expressiva, com a Qp 66,7% menor entre 2040 e 2069 e atingindo 80% de redução no período de 2070 a 2099, em comparação à quebra de produtividade observada entre 1988 e 2022.

Para o período de referência, os menores valores de Qp ocorreram nas datas de semeadura de 15 de outubro (6,9%) e de 10 de novembro (4,1%), no município de Montividiu. Os maiores valores foram observados em Padre Bernardo, com plantio em 15/out (15,38%), e em Luziânia, com plantio em 10 de novembro (11,55%).

O cenário SSP2-4.5, que pressupõe estabilização das emissões de gases de efeito estufa, apresenta penalizações crescentes ao longo do tempo. No período 2040-2069, a penalização em várias localidades ultrapassa 15%, como em Cristalina (15,6% em 15/out) e Goiátuba (16,6% em 15/out). Os valores são ligeiramente menores em novembro, reduzindo-se para 14,6% em Cristalina e 15,1% em Goiátuba.

Observou-se um aumento da penalização ao longo do tempo, com valores mais elevados previstos no cenário RCP8.5. Para muitos municípios, as penalizações no período 2070–2099 mais do que dobraram em relação ao período 2040–2069. Em Luziânia, a penalização aumentou de 24,3% (2040–2069) para 66,4% (2070–2099), na data de plantio de 10 de novembro, o que representa um aumento superior ao dobro. Em Campo Alegre, os valores passaram de 46,8% para 48,3% (15/out) e de 34,2% para 54,4% (10/nov), indicando que mesmo em datas mais tardias de plantio, o impacto é expressivo.

É importante destacar que municípios que tradicionalmente apresentam alta produtividade, como Silvânia e Niquelândia, podem enfrentar desafios mais acentuados no período de 2070–2099, com penalizações de 56,1% (Silvânia, 15/out) e 52,8% (Niquelândia, 10/nov), considerando o cenário RCP8.5. Isso demonstra que mesmo regiões com um histórico agrícola mais favorável também estão vulneráveis às mudanças climáticas mais extremas.

No período de 2040–2069, a quebra de produtividade é geralmente maior para a data de semeadura de 15 de outubro, enquanto a Qp em 10 de novembro apresenta penalizações menores, visto que a média da Qp para este período no cenário RCP4.5 é de 14,2% em outubro e 12,1% em novembro, ou seja, uma diferença de 2,1%. No cenário RCP8.5, também se observa essa dinâmica, visto que, em média, a Qp em outubro foi de 26,1% e, em novembro, de 25,4%, o que representa uma redução de 0,7 ponto percentual. Entretanto, ao avaliar as datas de semeadura para o período 2070-2099, ambos os cenários indicaram que a

semeadura em novembro resulta em perdas mais expressivas. A média da Qp no cenário RCP4.5 em 15 de outubro é de 16,9% contra 19,6% em novembro. No cenário RCP8.5, a Qp para semeadura em outubro é de 31,5%, enquanto em novembro é de 41,1%.

Portanto, no período de 2070–2099, as vantagens comparativas, sob a perspectiva da eficiência de água verde, entre as datas de semeadura diminuem. Isso indica que, à medida que as condições climáticas se agravam, a janela de plantio deixa de ser um fator relevante de mitigação. A intensificação dos veranicos, o encurtamento e a concentração das estações chuvosas tornam ambas as datas igualmente vulneráveis.

3.3. Produtividade da soja estimada a partir de dados observados de levantamentos oficiais

Na Figura 9, apresenta-se o desempenho do modelo calibrado para a estimativa da produtividade média da soja (kg ha^{-1}) a partir de dados observados pelo IBGE nos 20 municípios de maior produtividade no estado de Goiás. A relação entre as duas variáveis apresentou um coeficiente de determinação (R^2) de 0,99 ($p < 0,01$), indicando forte aderência entre os valores estimados e os observados.




Figura 9. Desempenho do modelo calibrado para estimativa da produtividade média da soja (kg ha^{-1}) nos 20 municípios de Goiás com maior produtividade de soja.

Figure 9. Performance of the calibrated model for estimating average soybean yield (kg ha^{-1}) in the 20 municipalities with the highest soybean productivity in the State of Goiás.

Os indicadores estatísticos de erro reforçam a robustez do modelo. O erro absoluto médio (MAE) foi de 89,23 kg ha^{-1} , enquanto o erro quadrático médio (RMSE) foi de 94,10 kg ha^{-1} , indicando que as estimativas podem apresentar erros nessa magnitude. O erro médio de viés de -8,92 kg ha^{-1} evidencia que, em média, o modelo tende a subestimar a produtividade, embora o viés seja pequeno. O índice d de Willmott, de 0,95, reforça a forte concordância entre os valores simulados e os observados, demonstrando que o modelo é eficiente na reprodução das condições reais de produtividade levantadas por órgãos oficiais.

As estatísticas apresentadas na Tabela 1 indicam o desempenho do modelo de previsão da produtividade da soja em escala municipal para os municípios de maior produtividade desse grão no estado de Goiás. Pode-se observar, ainda, que o modelo simulou adequadamente a produtividade da soja em todos os municípios, com R^2 superior a 0,84. Os valores de erro médio de viés (MBE) indicaram subestimativa na maioria das localidades analisadas (60%), com destaque para os municípios de Jatá (-118,36 kg ha^{-1}).

ha⁻¹) e Montividiu (-98,15 kg ha⁻¹), nos quais os valores de viés foram mais pronunciados.

Tabela 1. Desempenho do modelo calibrado de estimativa de produtividade da soja (kg ha⁻¹) em municípios de Goiás.

Table 1. Performance of the calibrated soybean yield estimation model (kg ha⁻¹) in municipalities of Goiás.

Município	R ²	MAE	RMSE	MBE	d
AC	0,95*	267,50	268,48	267,50	0,91
BJ	0,97*	13,32	14,46	-13,32	0,97
CP	0,91*	239,60	240,10	239,60	0,90
CA	0,92*	68,90	80,64	-67,50	0,92
CT	0,97*	64,76	68,75	-64,76	0,98
CH	0,96*	65,12	65,14	65,12	0,98
CR	0,93*	81,27	85,20	-81,27	0,98
GO	0,96*	67,90	72,13	-67,90	0,91
IP	0,97*	90,44	90,69	90,44	0,98
JA	0,85*	121,55	137,51	-118,36	0,96
LU	0,99*	126,35	126,56	126,35	0,95
MI	0,87*	98,95	100,50	98,95	0,96
MO	0,97*	98,15	98,15	-98,15	0,98
NI	0,97*	11,86	12,06	-11,86	0,95
PB	0,94*	94,58	113,67	-94,58	0,98
PR	0,91*	80,36	80,42	-80,36	0,94
PI	0,93*	52,13	59,32	47,87	0,93
RV	0,93*	41,73	48,95	23,97	0,97
SH	0,97*	77,39	82,64	-64,71	0,94
SI	0,84*	22,70	35,98	-18,52	0,92

CP= Caiapônia; NI = Niquelândia; AC = Acreúna; GO = Goiânia; SH = Santa Helena de Goiás; PB = Padre Bernardo; BJ = Bom Jesus de Goiás; LU = Luziânia; PI = Piracanjuba; CA = Campo Alegre de Goiás; SI = Silvânia; CH = Chapadão do Céu; MI = Mineiros; IP = Ipameri; CT = Catalão; MO = Montividiu; PR = Paraúna; CR = Cristalândia; JÁ = Jataí; RV = Rio Verde.

em que: R² = coeficiente de determinação, MAE = erro médio absoluto, RMSE = raiz do erro quadrático médio, BEM = erro médio de viés, d = Concordância de Wilmott). *significativo a 5% de probabilidade pelo teste t.

where: R² = coefficient of determination, MAE = mean absolute error, RMSE = root mean square error, BEM = mean bias error, d = Wilmott's index of agreement. * Significant at the 5% probability level by the t-test.

Os maiores valores de erro absoluto foram registrados em Acreúna (MAE=267 kg ha⁻¹), seguidos por Caiapônia (MAE=239,60 kg ha⁻¹) e Luziânia (MAE=126,35 kg ha⁻¹), indicando discrepâncias mais acentuadas entre os valores previstos e os observados. Os menores erros absolutos ocorreram em Niquelândia (MAE = 11,86 kg ha⁻¹), seguidos de Bom Jesus (MAE = 13,32 kg ha⁻¹), o que evidencia um excelente desempenho do modelo nesses municípios.

O RMSE, por sua vez, apresentou uma tendência semelhante à do MAE, com os maiores valores em Acreúna (RMSE=268,48) e os menores em Niquelândia (RMSE=12,06). A proximidade entre os valores de MAE e RMSE na maioria dos municípios sugere que os erros não foram significativamente influenciados por outliers, o que reforça a consistência dos resultados obtidos. A análise das produtividades médias de soja no período de 2015 a 2022 permitiu avaliar a diferença entre os valores registrados nos levantamentos oficiais do IBGE, as produtividades estimadas pelo modelo preditivo calibrado com dados climáticos de cada município e a produtividade potencial tecnológica (Figura 10). A quebra de produtividade (Qp, %) é definida como a diferença relativa entre a produtividade potencial tecnológica e a produtividade observada (dados do IBGE).




Figura 10. Produtividades potencial tecnológico médio, produtividades médias observadas (IBGE) e produtividades médias estimadas pelo modelo, para o período de 2015 a 2022.

Figure 10. Mean technological potential yield, mean observed soybean yield (IBGE), and mean soybean yield estimated by the model for the period 2015–2022

CP = Caiapônia; NI = Niquelândia; AC = Acreúna; GO = Goiânia; SH = Santa Helena de Goiás; PB = Padre Bernardo; BJ = Bom Jesus de Goiás; LU = Luziânia; PI = Piracanjuba; CA = Campo Alegre de Goiás; SI = Silvânia; CH = Chapadão do Céu; MI = Mineiros; IP = Ipameri; CT = Catalão; MO = Montividiu; PR = Paraúna; CR = Cristalândia; JÁ = Jataí; RV = Rio Verde.

Entre os municípios analisados, os valores de produtividade média observada variaram de 3.066,2 kg ha⁻¹ (Niquelândia) a 3.647,8 kg ha⁻¹ (Luziânia), indicando uma diferença de cerca de 19% no desempenho produtivo entre os municípios com a maior e a menor produtividade média real de soja. A quebra de produtividade apresentou variação entre os municípios analisados, oscilando de valores próximos de 0,11% a máximos de 12%. O menor impacto de perdas foi registrado em municípios em que a produtividade observada esteve muito próxima da produtividade potencial tecnológica, como Jataí, que apresentou produtividade potencial tecnológica de 3.516,3 kg ha⁻¹ e produtividade real de 3.512,5 kg ha⁻¹.

As maiores quebras ocorreram em localidades em que a produtividade observada ficou consideravelmente abaixo da produtividade potencial, indicando que o déficit hídrico médio no período analisado teve maior impacto sobre o rendimento da soja. Por exemplo, em Acreúna, que apresentou Qp de 12%, observou-se produtividade potencial de 3.740,6 kg ha⁻¹, em comparação à produtividade real de 3.295,1 kg ha⁻¹.

4. DISCUSSÃO

O balanço hídrico para o período de referência (1988–2022) observado no presente trabalho foi semelhante ao observado por Silva Júnior et al. (2020), que, ao analisarem os dados médios mensais do estado de Goiás, para o período de 1960 a 1990, destacaram o baixo armazenamento de água no solo entre os meses de maio e outubro, período caracterizado por déficit hídrico no balanço hídrico climatológico.

A quebra potencial da produtividade atual e futura da cultura de soja nos municípios de Goiás foi estimada por meio de modelos tradicionais, validados em outros biomas; por exemplo, Aparecido et al. (2021) aplicaram essa metodologia para estimar a produtividade da soja no estado de Mato Grosso do Sul com base em variáveis climáticas, identificando o estresse hídrico como um dos principais

fatores responsáveis pela redução do rendimento da cultura. Esse impacto negativo do déficit hídrico na produtividade também foi corroborado por Alves et al. (2021), que destacaram a relevância desse fator como uma limitação crítica ao potencial produtivo da soja.

Os estudos de Battisti et al. (2018) sugerem que uma das estratégias mais promissoras para reduzir a perda de produtividade decorrente do déficit hídrico da soja é o aumento da profundidade do perfil do solo, prática que poderia resultar em incrementos de produtividade de até 2.500 kg ha⁻¹, dependendo das condições locais.

Silva et al. (2020) aplicaram a mesma metodologia para estimar a produtividade do algodão em municípios do Nordeste brasileiro, obtendo erros de estimativa entre 15 e 582 kg ha⁻¹. Segundo os autores, os maiores desvios podem ser atribuídos a fatores não contemplados pelo modelo, tais como surtos de pragas e doenças, o uso de diferentes genótipos e mudanças nas práticas de manejo e de gestão agrícola.

Estudos anteriores validaram a aplicação deste modelo em diferentes regiões do Brasil, demonstrando sua versatilidade e eficácia. Lima et al. (2020) avaliaram o modelo para estimativa da produtividade do milho em municípios do Nordeste brasileiro, enquanto Monteiro et al. (2013) aplicaram a metodologia à cultura do arroz na região Sul. Ambos os estudos destacaram o desempenho satisfatório do modelo, evidenciando baixos erros de estimativa em relação aos dados oficiais do IBGE.

De acordo com Monteiro et al. (2017), ao avaliarem a quebra de produtividade do milho no Brasil, os autores destacaram que as modelagens agrometeorológicas podem apresentar limitações, resultando em subestimações ou superestimações dos rendimentos reais, especialmente quando não são realizados ajustes adequados. Esses autores enfatizaram que a calibração do modelo em escala municipal apresentou desempenho superior às escalas regional e nacional, evidenciando maior precisão na representação das condições locais.

5. CONCLUSÕES

As mudanças climáticas projetadas para os cenários RCP4.5 e RCP8.5 têm potencial para afetar a produtividade da soja em Goiás, especialmente devido ao aumento do déficit hídrico. O modelo agrometeorológico utilizado mostrou-se eficaz para estimar a produtividade da soja em escala municipal, como evidenciado pelos altos coeficientes de determinação (R^2) e baixos erros médios absolutos após a calibração.

Os cenários futuros indicaram penalizações crescentes na produtividade da soja, com destaque para o cenário RCP8.5 no período de 2070-2099, no qual foram observadas perdas superiores a 50% em diversos municípios, como Luziânia e Silvânia. Além disso, as datas de plantio, que atualmente permitem um certo grau de mitigação, tornam-se menos relevantes em cenários futuros.

6. REFERÊNCIAS

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: Guidelines for computing crop water requirements**. Roma: FAO, 1998. 300p. (FAO Irrigation and Drainage, Paper 56). Disponível em: <https://www.fao.org/4/x0490e/x0490e00.htm>. Acesso em: 24 jun. 2022.

ANA_Agência Nacional de Águas. **Uso da água na agricultura de sequeiro no Brasil (2013-2017)**. Brasília: ANA/IBGE, 2020. 63p. Disponível em: https://www.snirh.gov.br/portal/snirh/centrais-de-conteudos/central-de-publicacoes/re_sequeiro2.pdf/view Acesso em: 14 jan. 2021.

APARECIDO, L. E. de O.; TORSONI, G. B.; MESQUITA, D. Z.; MENESES, K. C. de; MORAES, J. R. da S. C. de. Modelagem da produtividade do milho safrinha em função das condições climáticas do Mato Grosso do Sul. **Revista Brasileira de Climatologia**, n. 16, v. 26, p. 155-174, 2020. <https://doi.org/10.5380/abclima.v26i0.69183>

APARECIDO, L. E. de O.; TORSONI, G. B.; MORAES, J. R. da S. C. de M.; MENESES, K. C. de; LORENÇONE, J. A.; LORENÇONE, P. A. Modeling the impact of agrometeorological variables on soybean yield in the Mato Grosso do Sul: 2000-2019. **Environment Development and Sustainability**, v. 12, n. 23, p. 5151-5164, 2021. <https://doi.org/10.1007/s10668-020-00807-w>

ALVES, E. da S.; RODRIGUES, L. N.; OLIVEIRA, R. A. de; LORENA, D. R. Water deficit on the growth and yield of irrigated soybean in the Brazilian Cerrado region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 11, p. 750-757, 2021. <https://doi.org/10.1590/1807-1929/agriambi.v25n11p750-757>

BATTISTI, R.; SENTELHAS, P. C.; PASCOALINO, J. A. L.; SAKO, H.; DANTAS, J. P. de S.; MORAES, M. F. Soybean yield gap in the areas of yield contest in Brazil. **International Journal of Plant Production**, n. 10, v. 12, p. 159-168, 2018. <https://doi.org/10.1007/s42106-018-0016-0>

BOLFE, É. L.; SANO, E. E.; CAMPOS, S. K. (eds.). **Dinâmica agrícola no Cerrado: análises e projeções**. Brasília: Embrapa, 2020. v. 1, 308p.

CARDOSO, M. R. D.; MARCUZZO, F. F. N.; BARROS, J. R.; SILVA, J. J. Classificação climática de Köppen-Geiger para o Estado de Goiás e o Distrito Federal. **Acta Geográfica**, v. 8, n. 16, p. 40-55, 2014.

CHOU, S. C.; LYRA, A.; MOURÃO, C.; DEREZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEIRA, G.; NOBRE, P.; MARENGO, J. Evaluation of the Eta simulations nested in three global climate models. **American Journal of Climate Change**, Boston, v. 3, n. 1, p. 438-454, 2014. <https://doi.org/10.4236/ajcc.2014.35039>

CONAB_Companhia Nacional de Abastecimento. **Calendário de plantio e colheita de grãos no Brasil**. 2022. Disponível em: <http://www.conab.gov.br>. Acesso em: 05 maio 2024.

DOORENBOS, J.; KASSAM, A. H. **Efectos del agua en el rendimiento de los cultivos**. Roma: FAO, 1979. 212p. (Estudio FAO Riego y Drenaje, 33).

EDREIRA, J. I. R.; MOURTZINIS, S.; CONLEY, S. P.; ROTH, A. C.; CIAMPITTI, I. A.; LICHT, M. A.; KANDEL, H.; KYVERYGA, P. M.; LINDSEY, L. E.; MUELLER, D. S.; NAEVE, S. L.; NAFZIGER, E.; SPECHT, J. E.; STANLEY, J.; STATON, M. J.; GRASSINI, P. Assessing causes of yield gaps in

- agricultural areas with diversity in climate and soils. **Agricultural and Forest Meteorology**, n. 247, v. 1, p.170-180, 2017. <https://doi.org/10.1016/j.agrformet.2017.07.010>
- EMBRAPA_Empresa Brasileira de Pesquisa Agropecuária. **Planilha para obtenção de coeficiente de cultura (Kc) para culturas de ciclo anual, segundo método FAO, para as condições climáticas brasileiras**. Comunicado técnico 254, Sete Lagoas, MG: Embrapa, 2021, 17p. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1136374/planilha-para-obtencao-de-coeficiente-de-cultura-kc-para-culturas-de-ciclo-anual-segundo-metodo-fao-para-as-condicoes-climaticas-brasileiras>. Acesso em: 20 jun. 2022.
- FARIAS, D. B. dos S.; RODRIGUES, L. N.; ALEMAN, C. C.; CECON, P. R. Estimation of soybean crop water deficit sensitivity index. **Scientia Agricola**, v. 81, n. 2, p. 1-8, 2024. <https://doi.org/10.1590/1678-992X-2023-0103>
- FAO; DWFI. **Yield gap analysis of field crops - Methods and case studies**. Roma: FAO, 2015. (FAO Water Reports, n. 41). 82 p. Disponível em: <https://openknowledge.fao.org/items/683e82e8-2d47-4388-8f0c-2fa6e6a7692c>. Acesso em: 20 jan. 2021
- IBGE_Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal. Tabela 5457 - Área plantada ou destinada à colheita, área colhida, quantidade produzida, rendimento médio e valor da produção das lavouras temporárias e permanentes**. Disponível em : <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 19 out 2025.
- IMB_Instituto Mauro Borges de Estatísticas e Estudos Socioeconômicos. **Goiás em dados 2022**. Disponível em: https://www.imb.go.gov.br/index.php?option=com_content&view=article&id=2361:goias-em-dados2022&catid=19&Itemid=151. Acesso em: 25 out. 2023
- LENDERINK, G.; BUIHAND, A.; VAN DEURSEN, W. Estimates of future discharges of the river Rhine using two scenario methodologies: direct versus delta approach. **Hydrology and Earth System Sciences**, v. 11, n. 3, p. 1145-1159, 2007. <https://doi.org/10.5194/hess-11-1145-2007>
- LIMA, C. I. S. de; SILVA, F. D. dos S.; FREITAS, I. G. F. de; PINTO, D. D. C.; COSTA, R. L.; GOMES, H. B.; SILVA, E. H. de L.; SILVA, L. L. da; SILVA, V. P. R. da; SILVA, B. K. da N. Método alternativo de zoneamento agroclimático do milho para o estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 35, n. especial, p. 1057-1067, 2020. <http://dx.doi.org/10.1590/0102-778635500113>
- MONTEIRO, J. E. B. de A.; ASSAD, E. D.; SENTELHAS, P. C.; AZEVEDO, L. da C. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Pesquisa Agropecuária Brasileira**, v. 52, n. 3, p. 137-148, 2017. <https://doi.org/10.1590/S0100-204X2017000300001>
- MONTEIRO, J. E. B. de A.; AZEVEDO, L. da C.; ASSAD, E. D.; SENTELHAS, P. C. Rice yield estimation based on weather conditions and on technological level of production systems in Brazil. **Pesquisa Agropecuária Brasileira**, v. 48, n. 2, p. 123-131, 2013. <https://doi.org/10.1590/S0100-204X2013000200001>
- NOVAIS, G. T. Classificação climática aplicada ao Estado de Goiás e ao Distrito Federal, Brasil. **Boletim Goiano de Geografia**, v. 40, n. 1, p. 1-29, 2020. <https://doi.org/10.5216/bgg.v40i01.62297>
- RODRIGUES, L. N. (Org.). **Agricultura irrigada no Cerrado: subsídios para o desenvolvimento sustentável [recurso eletrônico]**. 2. ed. rev. e ampl. - Brasília, DF: Embrapa, 2024. 503p.: Disponível 98 em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1165534/1/AgriculturaIrigada-2a-ed-1.pdf>. Acesso em: 17 jan. 2025.
- SENTELHAS, P. C.; BATTISTI, R.; MONTEIRO, L. A.; DUARTE, Y. C. N.; VISSER, F. A. Yield gap - conceitos, definições e exemplos. **Informações Agrônomicas**, n. 155, p. 9-12, 2016.
- SETTYA, P.; SATPATHI, A.; NAIN, A. S.; DAS, B. Comparison of weather-based wheat yield forecasting models for different districts of Uttarakhand using statistical and machine learning Techniques. **Journal of Agrometeorology**, v. 24, n. 3, p. 255-261, 2022. <https://doi.org/10.54386/jam.v24i3.1571>
- STACKHOUSE JR, P.W.; WESTBERG, D.W.; CHANDLER, W.S.; ZHANG, T.; HOELL, J.M. **Prediction of Worldwide Energy Resource (POWER): Agroclimatology methodology, version 1.1.0**. Hampton, VA: NASA Langley Research Center, 2015. 72 p. Disponível em: <https://ntrs.nasa.gov/api/citations/20130013357/downloads/20130013357.pdf>. Acesso em: 16 jun. 2023.
- SILVA, F. D. dos S.; COSTA, R. L.; ROCHA JÚNIOR, R. L. da; GOMES, H. B.; AZEVEDO, P. V. de; SILVA, V. de P. R. da; MONTEIRO, L. A. Cenários climáticos e produtividade do algodão no Nordeste do Brasil. Parte I: calibração e validação do modelo agrometeorológico. **Revista Brasileira de Meteorologia**, v. 35, n. Especial, p. 903-912, 2020. <https://doi.org/10.1590/0102-77863550087>
- SILVA JÚNIOR, J. J.; FURTADO, M. N.; SOUSA, M. B. RAMOS, D. F. Balanço hídrico climatológico normal mensal no Estado de Goiás. In: **Tópicos em Ciências Agrárias**, v. 4. Belo Horizonte: Poisson, 2020. 6p.
- THAYER, A. W.; VARGAS, A.; CASTELLANOS, A. A.; LAFON, C. W.; MCCARL, B. A.; ROELKE, D. L.; LACHER, T. E. Integrating agriculture and ecosystems to find suitable adaptations to climate change. **Climate**, v. 8, n. 1, e10, 2020. <https://doi.org/10.3390/cli8010010>
- THORNTHWAITE, C. W.; MATHER, J. R. The water balance. Centerton: Drexel Institute of Technology. **Climatology**, v. 8, n. 1, p.104-112, 1955.
- VISSER, F. de A.; SENTELHAS, P. C.; PEREIRA, A. B. Yield gap of cassava crop as a measure of food security – an example for the main Brazilian producing regions. **Food Security**, v. 10, n. 6, p.1191-1202, 2018. <https://doi.org/10.1007/s12571-018-0831-2>
- WANG, Y.; LING, X.; MA, C.; LIU, C.; ZHANG, W.; HUANG, J.; PENG, S.; DENG, N. Can China get out of soy dilemma? A yield gap analysis of soybean in China. **Agronomy for Sustainable Development**, v. 43, n. 1, e47, 2023. <https://doi.org/10.1007/s13593-023-00897-6>
- WTO-World Trade Organization. **World Trade Report 2023**. 134p. Disponível em:

https://www.wto.org/english/res_e/booksp_e/wtr23_e/wtr23_e.pdf. Acesso em jun 2023.

ZHAO, J.; WANG, Y.; ZHAO, M.; WANG, K.; LI, S.; GAO, Z.; SHI, X.; CHU, Q. Prospects for soybean production increase by closing yield gaps in the Northeast Farming Region, China. **Field Crops Research**, v. 293, n. 10, e108843, 2023. <https://doi.org/10.1016/j.fcr.2023.108843>


Agradecimentos: à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pela concessão da bolsa de estudo ao primeiro autor (Proc. 88887.638077/2021-00) e ao CNPq pela concessão de bolsa de produtividade em pesquisa do segundo autor (306541/2023-8) e de projetos (404030/2024-6; 404187/2021-8).

Contribuições dos autores: J.B.M.F.: conceituação, metodologia, coleta de dados, processamento e análise de dados, interpretação dos resultados, redação da versão final, revisão e edição; L.N.R.: orientação acadêmica, supervisão da pesquisa e revisão do manuscrito. Todos os autores leram e concordaram com a versão publicada do manuscrito.

Financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

Disponibilidade de dados: Os dados desta pesquisa poderão ser obtidos por e-mail, mediante solicitação ao autor correspondente.

Conflito de interesses: Os autores declaram não haver conflitos de interesses.



Copyright: © 2026 by the authors. This article is an Open-Access article distributed under the terms and conditions of the Creative Commons **Attribution-NonCommercial (CC BY-NC)** license (<https://creativecommons.org/licenses/by/4.0/>).